

# ANÁLISE DE ACURÁCIA DE MAPA DE USO DO SOLO ORIUNDO DE CLASSIFICAÇÃO DE IMAGEM DE ALTA RESOLUÇÃO

Prof. Dr. Alzir Felipe Buffara Antunes <sup>1</sup>  
Profa. Dra. Christel Lingnau <sup>2</sup>  
Profa. Dra. Márcia Lopes Quintas <sup>3</sup>

<sup>1</sup>Universidade Federal do Paraná – UFPR – Departamento de Geomática – [felipe@ufpr.br](mailto:felipe@ufpr.br)

<sup>2</sup>Universidade Federal do Paraná – UFPR – Departamento de Ciências Florestais – [lingnau@ufpr.br](mailto:lingnau@ufpr.br)

<sup>3</sup>Universidade Federal do Paraná – UFPR – Departamento de Geomática – [mquintas@ufpr.br](mailto:mquintas@ufpr.br)

## RESUMO

Este trabalho apresenta uma discussão sobre a avaliação de acurácia de mapa temático resultante do processo de classificação de imagens de alta resolução. A imagem Ikonos foi segmentada e os objetos classificados por meio de lógica fuzzy. Comparam-se dois métodos de avaliação de acurácia, um primeiro baseado na matriz de erros e coeficiente de concordância *Tau* e um segundo método baseado nas incertezas e ambigüidades oriundo das funções de pertinência.

**Palavras-chave:** Acurácia, Lógica Fuzzy, Imagem de Alta Resolução.

## ACCURACY ASSESSMENT OF LAND USE MAP FROM HIGH RESOLUTION IMAGE CLASSIFICATION

### ABSTRACT

*This paper discusses the accuracy assessment of the thematic map generated by means of high resolution image classification. Multispectral Ikonos image was segmented and the objects classified by fuzzy logic rules. Two methods of accuracy assessment are compared one based on error matrix and Tau coefficient of agreement and the other based on uncertainty and ambiguity's analysis resultant from the memberships values.*

**Key words:** accuracy assessment, fuzzy logic, high resolution image.

## 1. INTRODUÇÃO

Enquanto o sensoriamento remoto teve nas últimas duas décadas um enorme progresso no que se refere à captação de imagens multiespectrais de média e alta resolução espacial, a vasta maioria de aplicações baseia-se em métodos de processamentos desenvolvidos no final dos anos 70. Vários métodos de classificação digital foram recentemente aprimorados (ex.: lógica fuzzy, teoria da evidência, análise de incertezas, etc.), sendo que tal aprimoramento ocorreu em nível de pixel. Quando se considera uma resolução espacial mais alta (de 1 a 4 metros) torna-se provável que um determinado pixel possua características espectrais semelhantes às de seus vizinhos. Desta forma, os algoritmos de classificação podem ser baseados no contexto do pixel, ou seja, considerando-se a vizinhança.

O contexto espacial apresenta um modesto papel quando o processo de classificação baseia-se na categorização de pixels individuais. Estudos recentes mostram que esta limitação é bem menor quando o agrupamento de pixels vizinhos ou objetos são levados em consideração. O uso de técnica baseada em classificar objeto composto por um conjunto de pixels com características similares se apresenta como uma alternativa aos métodos convencionais. Os objetos são resultantes da segmentação da imagem, onde pixels são agrupados por meio de crescimento de regiões apoiado em aspectos espectrais e de forma. Diferentes escalas e tamanhos de objetos podem levar à criação de uma rede hierárquica que relaciona objetos maiores a subobjetos (objetos menores) onde o conhecimento do usuário pode ser inserido. Uma vez que os objetos ou regiões são contextualizados, o conhecimento do mundo real pode ser realizado por meio de lógica fuzzy através de parâmetros espectrais e de forma.

Este trabalho tem o objetivo de apresentar uma discussão de avaliação de acurácia do resultado temático da classificação de objetos ou regiões por meio de lógica fuzzy. Pretende-se comparar a acurácia temática através do uso de coeficientes de concordância *Tau* e por meio da análise de ambigüidade proveniente da função de pertinência fuzzy.

## 2. MATERIAL E MÉTODO

### 2.1- ÁREA TESTE

O trabalho foi realizado sobre uma Imagem Ikonos Multiespectral de resolução espacial de 4 metros, na região de Nova Esperança, Norte do Paraná, sendo que a mesma foi classificada por meio de regras fuzzy. O método proposto é baseado em *FNEA (fractal net evolution approach)* — implementado em 2001 no *software e-cognition* —, o qual permite criar hierarquia entre objetos e inserir o contexto na classificação digital de imagens por meio de regras fuzzy (Figura 1). A imagem foi segmentada em diferentes níveis o que serviu de base ao processo de classificação, pois cada objeto possui parâmetros espectrais, forma e textura.

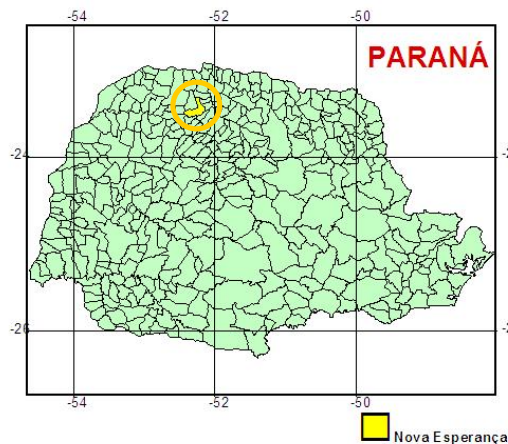


FIGURA 1- Área Teste

### 2.2- CLASSIFICAÇÃO FUZZY DOS OBJETOS

Os métodos de classificação ao nível de pixel mais utilizados como mínima distância e máxima verossimilhança associam sempre pixels a determinada categoria por meio do grau de associação Booleano (0 ou 1). No entanto, classificador Fuzzy apresenta valores intermediários entre 0 e 1, que permite flexibilidade à classificação, ou seja, observar as incertezas. A tendência atual é a utilização deste tipo de classificador, pois a sua principal vantagem reside na possibilidade de expressar diferentes possibilidades à classificação. Em uma imagem tipo Landsat a principal fonte de informação são os valores de níveis de cinza inerentes aos pixels em cada banda, por outro lado, numa imagem de alta resolução devido a um maior quantidade de pixel o conceito espacial pode ser introduzido. Isto significa que pixels adjacentes podem pertencer a uma mesma feição no terreno. Logo, o agrupamento de pixels adjacentes permite a determinação de parâmetros de forma e textura e conseqüentemente, relaciona os objetos as respectivas feições do terreno.

Baseado em aspectos espectrais e na forma dos objetos na imagem pode-se gerar funções de pertinência que refletem o conhecimento (BAATZ & SCHÄPE, 2001). A mais simples regra fuzzy pode ser criada baseada num simples descritor, seja de valores espectrais dos objetos, seja de valores de forma. Por exemplo, um objeto pode ser classificado como *água* utilizando o descritor (valores) média espectral para ser definido como um conjunto fuzzy. Formula-se a regra fuzzy representando o conhecimento por meio da relação entre os valores notáveis do descritor (Equação 1).

$$\text{'Se média\_espectral (objeto) } \in \mu_{\text{média}}, \text{ então, classe}_{(\text{objeto})} = \text{água}' \quad (1)$$

Um objeto pode estar associado a várias classes com diferentes graus de pertinência. O grau de pertinência  $\mu_{\text{soloexposto}} = 0,7$ , exprime a maior possibilidade do objeto pertencer à classe *solo exposto*, logo a decisão adequada seria enquadrar o objeto como membro da classe solo, embora existam evidências menores a favor de outras classes como *agricultura* (0,5) e *várzea* (0,2) (Figura 2).

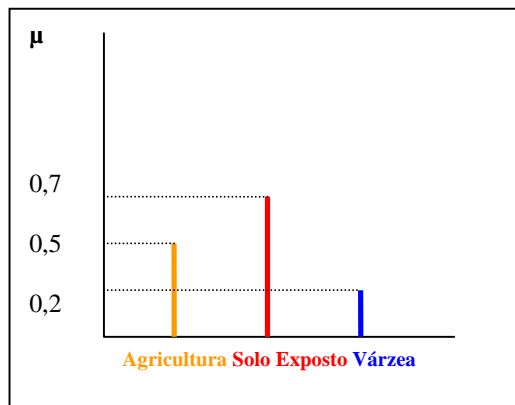


FIGURA 2- Exemplos de graus de pertinência.

### 2.3- CONFIABILIDADE DA CLASSIFICAÇÃO

A imagem classificada resultante está sujeita não só a erros posicionais, oriundos da correção geométrica a imagem, mas também a erros temáticos. Considera-se erro temático como a categorização equivocada de determinado objeto à determinada classe, ou ainda, a discrepância entre a classe do objeto na imagem e o seu status no terreno. A quantificação do erro temático está diretamente associada a processos estatísticos que permitem determinar o grau de concordância entre as classes dos objetos na imagem e as suas classes no terreno. A acurácia e a qualidade das informações representadas na imagem devem ser estimadas, a fim de validar a eficiência do classificador adotado.

Vários métodos de avaliação de acurácia têm sido discutidos na literatura. Os métodos mais utilizados, ainda hoje, são baseados na matriz de confusão ou de erros. A confiabilidade da matriz de erros depende da amostragem dos objetos que devem ser realizadas de maneira randômica (ROSENFELD & FITZPATRICK, 1982; CONGALTON & GREEN, 1999; FOODY, 2002). A matriz de confusão serve para se observar as variações entre a verdade de campo e a imagem classificada. Em classificação de imagem multiespectrais por métodos convencionais a matriz de confusão é amplamente utilizada (CONGALTON & GREEN, 1999). Contudo, FOODY (2002) não descarta totalmente o método convencional de avaliação de acurácia por meio de matriz de confusão, mesmo para classificadores tipo Fuzzy.

Considerando as funções de pertinência oriundas dos conjuntos fuzzy, LABA et al (2002) salienta que cada objeto pode possuir associação parcial a determinada classe, logo, o resultado da classificação pode não ser único. Desta forma, a acurácia deveria ser avaliada em termos de grau de ambigüidade. A ambigüidade neste caso é descrita pela proximidade dos graus de pertinência de um objeto pertencer a duas ou mais classes. Logo quanto maior a proximidade entre os graus de pertinência mais instável é a classificação. A Figura 3 ilustra graus de pertinência próximos entre si o que conduz a uma incerteza da associação do objeto em vermelho ou a classe de várzea ou a classe de agricultura.

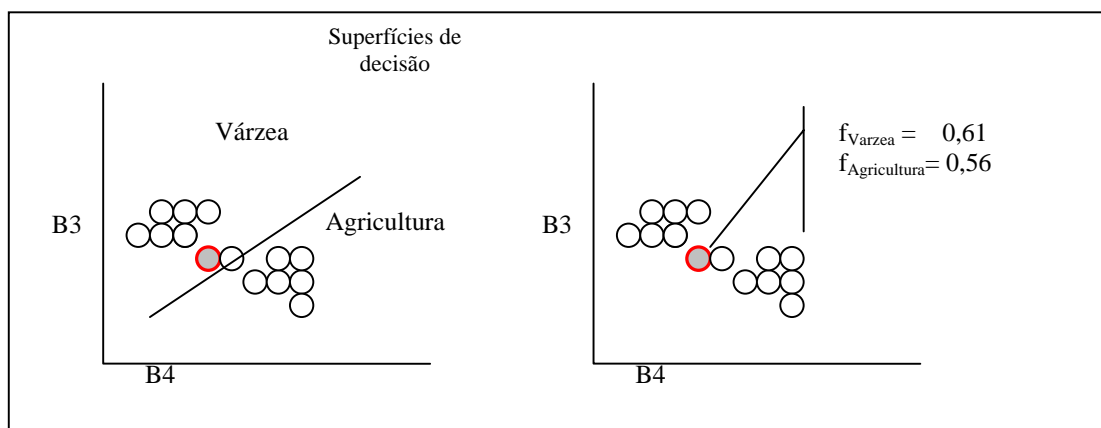


FIGURA 3- Incerteza da classificação Fuzzy

Não existe um consenso na comunidade de sensoriamento remoto sobre qual a melhor maneira de se avaliar a acurácia da classificação oriunda de classificadores Fuzzy (FOODY 2002; LABA et al, 2002). Desta forma, introduz-se, uma metodologia de avaliação da acurácia baseada em dois parâmetros: (a) coeficiente de concordância *Tau* determinado por meio da matriz de erros ou confusão; (b) ambigüidade da classificação levando em conta os graus de pertinência.

### 2.3.1- Coeficiente de concordância *Tau*

Matematicamente a matriz de erros ou confusão é representada por:

|          |          |          |          |
|----------|----------|----------|----------|
| $n_{11}$ | $N_{12}$ | $n_{1k}$ | $n_{i+}$ |
| $n_{21}$ | $N_{22}$ | $n_{2k}$ | $n_{2+}$ |
| $n_{k1}$ | $n_{k2}$ | $n_{kk}$ | $n_{k+}$ |
| $n_{+i}$ | $N_{+2}$ | $n_{+k}$ | $N$      |

$i =$  linhas;  
 $j =$  colunas;  
 $n_{+i} =$  total linhas;  
 $n_{i+} =$  total colunas;  
 $N =$  somatório da diagonal

As  $k$  classes são amostradas de forma independente. Na matriz as linhas representam os objetos classificados e nas colunas os objetos de referência,  $n_{ij}$  denota o número de amostras classificadas na categoria  $i$  ( $i= 1,2,3..k$ ) na classificação da imagem e na categoria  $j$  ( $j= 1,2,3..k$ ) dos dados de referência. A matriz de erros permite a determinação de coeficientes de acurácia ou concordância *Tau* que é uma técnica discreta multivariada e expressa a correlação entre a verdade de campo e as imagens classificadas, baseadas em probabilidades (NAESSET, 1996, ANTUNES & LINGNAU, 1997).

O coeficiente de concordância *Tau* (Equação 2) adotado, é dado por:

$$\tau = \frac{P_o - P_r}{1 - P_r} \quad (2)$$

onde :

$P_o$  é a concordância observada;

$P_r$  é a concordância esperada.

*Tau* baseia-se na probabilidade *a priori* (NAESSET, 1996), ou seja, a concordância esperada ( $P_r$ ) pode ser obtida antes mesmo de elaborar a matriz de erros.  $P_r = 1/k$ , onde  $k$  é número de categorias ou classes.

A concordância observada (Equação 3) é expressa por:

$$P_o = \frac{\sum n_{ii}}{N} \quad (3)$$

onde:

$n_{ii}$  são os elementos corretamente classificados

$N$  é o número total de elementos

Logo:

$$\tau = \frac{\sum n_{ii} - 1/k}{n - 1/k} \quad (4)$$

Neste caso se considera a mesma probabilidade *a priori* para todos os objetos a serem categorizados randomicamente. No caso de diferentes probabilidades,  $P_r$  também pode ser calculado baseado em diferentes probabilidades *a priori*, para cada classe.

NAESET (1996) justifica que *Tau* pode ser interessante como um coeficiente que reflete a acurácia de uma classificação, pois estima as concordâncias ao acaso. Resultados empíricos mostram que *Tau* apresenta valores muito próximos ao coeficiente de concordância *Kappa* também bastante utilizado como índice de acurácia. Estudos mostram que tanto *Tau* quanto *Kappa* apresentam valores muito próximos entre si quando as classes possuem uma mesma probabilidade.

### 2.3.2- Ambigüidades

Como já foi mencionado a matriz de erro pode ser pouco representativa quando as categorias são originárias de classificação baseada em lógica fuzzy. O mapa temático originado a partir de grau de

pertinência pode ser avaliado durante o processo de classificação. O esquema de classificação apresentado possui duas componentes: (1) a semântica; (2) as regras. Trabalha-se com a possibilidade de um objeto  $O_i$  qualquer pertencer a uma classe  $c$ . Os valores de pertinência não são probabilidades. Por esta razão, um alto grau de pertinência para um objeto pertencer a uma classe não significa exatamente sua categorização para esta classe.

No que se refere a confiabilidade da classificação é interessante avaliar os graus de pertinência dos objetos que os associam com determinada classe. Um objeto  $O_i$  qualquer pode possuir diferentes graus de pertinência para diferentes classes. O objeto, geralmente, é associado à classe cujo grau de pertinência é maior. Contudo, graus de pertinência próximos mostram certo grau de incerteza, ou instabilidade, o que pode possibilitar a indução de erros de categorização. Uma prerrogativa da classificação por meio de regras fuzzy é a perspectiva de avaliar imprecisão por meio das diferentes possibilidades de classificar um objeto  $O_i$ . Propõe-se para a determinação do grau de ambigüidade (Equação 5).

$$I_a = (b_{c1} - b_{c2}) / b_{c1} \quad (5)$$

Onde:

$b_{c1}$  = maior grau de pertinência para uma classe  $c_i$  qualquer;

$b_{c2}$  = segundo maior grau de pertinência para uma classe  $c_j$  qualquer;

$c_i \neq c_j$

A instabilidade da classificação pode ser determinada a partir da razão da diferença dos dois maiores graus de pertinência pelo maior grau de pertinência. A Figura 4 mostra os diferentes valores em diferentes situações. Os valores de  $I_a$  variam de 0 a 1. O valor 1 indica que não há incerteza na associação de um objeto a determinada categoria e valor nulo indica total incerteza. Na Figura 4 apresenta as ambigüidades para as classes de *agricultura*, *solo exposto* e *várzea*. A Figura 4 C mostra uma grande incerteza tendo em vista pertinências iguais,  $I_a=0$ , no caso da Figura 4 B o objeto seria atribuído a classe *solo exposto*, com determinada certeza.

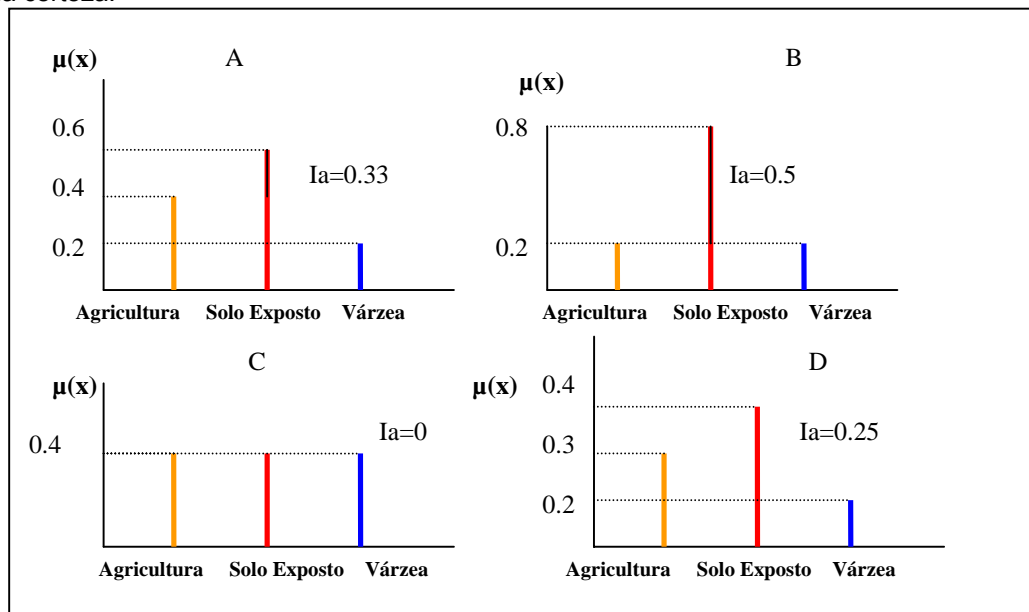


FIGURA 4- Comparação das Pertinências e Incertezas

Fonte: ANTUNES (2003)

### 3. RESULTADOS

A Figura 5 mostra a imagem Ikonos classificada por lógica fuzzy. A análise de acurácia temática desta fonte de dados ocorreu por meio de amostragem estatística da realidade de campo. Neste caso, devido à defasagem temporal entre a tomada da imagem e a classificação, amostras de referência foram coletadas na imagem multiespectral, ou seja, interpretação da imagem realizada de maneira independente.



FIGURA 5- Mapa Temático

Antes de proceder à análise da acurácia, avaliou-se a confiabilidade da interpretação da imagem que serviu de base para a coleta de pontos de referência. A imagem multiespectral foi utilizada como referência, pois havia uma defasagem temporal entre a data da aquisição da imagem e a fase da checagem de campo. Desta forma, considerou-se, então, a interpretação visual da imagem válida como referência. Neste trabalho, considerou-se um baixo índice de acurácia valores para  $Tau$  inferior a 0,5.

A matriz de erros para a imagem classificada de acordo com a estrutura semântica é apresentada na Tabela 1. Foram amostrados aproximadamente 30 polígonos para cada classe de interesse. A acurácia média total é dada pela razão entre os polígonos corretamente classificados e o número total de polígonos amostrados:  $a_i = 180/292 = 0,612$ . A acurácia total teve significância relativa, pois não considerou os erros de omissão e de comissão da matriz de confusão, logo o índice de acerto de 0,612 tem pouca significância.

TABELA 1- Matriz de erros

| MAPA        | Var. | Gal. | Pas. | Flo. | Euc. | Cap. | Sol. | Urb. | Can. | Cul. | $i+$ |
|-------------|------|------|------|------|------|------|------|------|------|------|------|
| Várzea      | 20   | 5    | 3    | 2    |      |      |      |      |      |      | 30   |
| Galeria     | 5    | 18   |      | 1    | 3    | 1    |      |      |      |      | 28   |
| Pastagem    | 1    |      | 16   |      |      | 8    | 3    |      | 3    |      | 31   |
| Floresta    | 2    | 8    |      | 20   | 3    | 2    |      |      |      |      | 36   |
| Eucalipto   | 1    |      | 2    | 3    | 16   |      |      |      | 1    |      | 23   |
| Capoeirinha | 3    |      | 5    | 1    |      | 18   | 1    |      | 4    |      | 32   |
| S. Exposto  | 1    |      | 3    |      |      |      | 21   | 4    | 4    |      | 33   |
| S. Urbano   |      |      | 2    |      |      | 1    | 5    | 15   | 0    |      | 23   |
| Cana        |      |      | 3    |      |      | 4    | 5    |      | 19   | 2    | 33   |
| Culturas    |      |      | 1    |      |      | 2    |      |      | 3    | 17   | 23   |
| $+i$        | 33   | 31   | 35   | 27   | 22   | 36   | 35   | 19   | 34   | 19   | 292  |

É interessante observar na Tabela 1 que existiram objetos que foram atribuídos, erroneamente, a classes. Isto se deve muitas vezes ao fato da sobreposição de funções de pertinência referente aos diferentes conjuntos fuzzy. Tomando como exemplo a classe *eucalipto* (6ª linha), dos 23 objetos coletados, um foi classificado como *várzea* e 2 objetos como *pastagem*, isto pode ser explicado pela detecção em campo de alguns indivíduos em áreas de *pastagem* e próximos ao ambiente ciliar. A Tabela 2 mostra o coeficiente de concordância para as diferentes classes da imagem classificada resultante da matriz de confusão.

Contudo a classificação fuzzy não pode ser adequadamente avaliada unicamente através da maneira convencional (matriz de confusão), uma vez que a regra de classificação adotada permitiu várias possibilidades de categorização a determinado objeto (ANTUNES, 2003).

Propôs-se, então, embasar a confiabilidade da classificação extraindo do próprio classificador fuzzy os diferentes graus de pertinência de um objeto a diferentes classes. Avaliou-se a ambigüidade temática nominal dos objetos por meio de valores discretos.

O método adotado foi uma adaptação do apresentado por TOWNSEND (2000) e LABA et al.(2002) que propõe uma análise fundamentada na observação numa escala lingüística a qual permite avaliar o grau de ambigüidade da classificação.

TABELA 2- Índice Tau para as Classes Individuais

| CLASSE           | TAU          |
|------------------|--------------|
| Várzea           | 0,567        |
| Galeria          | 0,534        |
| Cana             | 0,511        |
| Floresta         | 0,711        |
| Pastagem         | 0,400        |
| Eucalipto        | 0,700        |
| Capoeirinha      | 0,444        |
| Solo Exposto     | 0,560        |
| S. Urbano        | 0,766        |
| Outras Culturas  | 0,883        |
| <b>Tau Geral</b> | <b>0,608</b> |

Partiu-se do pressuposto que a proximidade entre graus de pertinência pode gerar alguma hesitação na associação de um objeto à determinada classe. Quanto mais próximo de zero o índice de ambigüidade,  $I_a$ , menor certeza é observada. Baseado no intervalo de 0 a 1 de  $I_a$ , optou-se pela adoção de uma escala lingüística de acordo com o proposto abaixo (Tabela 3):

TABELA 3- Qualidade da Classificação: ambigüidades

| Índice de Ambigüidade ou Instabilidade | Qualidade   |
|--|-------------|
| 1- $I_a = 0$ ;                         | Inaceitável |
| 2- $0,01 \leq I_a \leq 0,30$           | Ambígua     |
| 3- $0,31 \leq I_a \leq 0,50$           | Aceitável   |
| 4- $0,51 \leq I_a \leq 0,80$           | Boa         |
| 5- $0,81 \leq I_a \leq 1$              | Muito Boa   |

A Tabela 4 apresenta a relação entre ambigüidade e coeficiente de concordância. Existe uma correlação entre a estabilidade do mapa temático e o coeficiente de concordância. As classes com menores valores de *Tau*, em geral, mostraram ser mais ambíguas.

TABELA 4- Relação entre Ambigüidade e Coeficiente de Concordância

| CLASSE          | MAIOR PERTINÊNCIA | 2º MAIOR PERTINÊNCIA | $I_a$ | AMBIGÜIDADE      | TAU $\tau$ |
|-----------------|-------------------|----------------------|-------|------------------|------------|
| Várzea          | 0,572             | 0,202                | 0,646 | <b>Boa</b>       | 0,567      |
| Galeria         | 0,290             | 0,180                | 0,380 | <b>Aceitável</b> | 0,534      |
| Pastagem        | 0,317             | 0,201                | 0,366 | <b>Aceitável</b> | 0,400      |
| Floresta        | 0,570             | 0,120                | 0,780 | <b>Boa</b>       | 0,711      |
| Eucalipto       | 0,699             | 0,179                | 0,743 | <b>Boa</b>       | 0,700      |
| Capoeirinha     | 0,477             | 0,451                | 0,054 | Ambígua          | 0,444      |
| Solo exposto    | 0,310             | 0,299                | 0,036 | Ambígua          | 0,560      |
| Solo Urbano     | 0,701             | 0,150                | 0,786 | <b>Boa</b>       | 0,766      |
| Cana            | 0,331             | 0,322                | 0,002 | Ambígua          | 0,511      |
| Outras Culturas | 0,370             | 0,210                | 0,432 | <b>Aceitável</b> | 0,883      |

Nota-se no resultado da Tabela 4 que algumas classes como *capoeirinha* e *solo exposto* apresentaram certo grau de discrepância entre o coeficiente *Tau* e o índice de ambigüidade. Tomando, como exemplo *solo exposto*  $Tau = 0,560$  e  $I_a = 0,036$ , o índice  $I_a$  relaciona-se à classificação fuzzy, enquanto *Tau* relaciona-se ao mapa temático resultante. Apesar de "*solo exposto*" no mapa temático ter tido um índice de aceitação razoável no processo de classificação fuzzy, este mesmo obteve um valor de pertinência muito próximo a uma segunda classe possível, "*solo urbano*". O índice de ambigüidade da classificação fuzzy nem sempre coincidiu com um índice baixo de concordância entre a imagem classificada e sua interpretação visual. Isto deve-se ao fato, que apesar da incerteza na classificação houve de certa forma objetos corretamente classificados.

Os índices de ambigüidades aferiram apenas o quão dúbio ou instável é a associação de determinado objeto à determinada classe, durante o processo de "desfuzzificação", classificação baseada no maior grau de pertinência de um objeto a determinada classe. Porém a incerteza mostrou apenas a possibilidade de se ter cometido um erro quando se optou por escolher o maior grau de pertinência como critério de associação.

Quando se observa em determinada classe instabilidade, com graus de pertinência próximos entre si, possivelmente esta classe no mapa temático terá também um índice *Tau* mais baixo.

## 5- CONCLUSÃO

Para a análise de acurácia da imagem temática, a determinação da matriz de erros pode não ser suficiente, contudo necessária. Tratando-se de um classificador baseado em regras fuzzy sugere-se a avaliação de ambigüidades a fim de avaliar zonas de incerteza na imagem. Os diferentes graus de pertinência permitem avaliar melhor não só um resultado, mas também um segundo melhor resultado, o que conduz a refinamento da classificação.

Apesar dos métodos apresentados de acurácia serem distintos em seu embasamento estatístico ambos possuem uma certa correlação. Para a maioria das classes as ambigüidades foram diretamente proporcionais ao coeficiente *Tau*. Contudo, observa-se que a análise de ambigüidades está mais de acordo com o método de classificação fuzzy, conseqüentemente, coeficiente *Tau* isoladamente possui significância relativa. Sugere-se que para avaliação da qualidade do dado temático se faz necessário tanto avaliar o processo de classificação através da análise do grau de pertinência e ambigüidades, bem como a geração da matriz de confusão. Os métodos são complementares haja vista que a instabilidade ou incerteza pode ser avaliada durante o processo de classificação e o coeficiente de concordância após a realização do processo. Uma utilização conjunta dos métodos permite ao usuário utilizar o dado de maneira mais confiável.

## 6- BIBLIOGRAFIA

- ANTUNES, A.F.B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. Tese de Doutorado. Pós Graduação em Ciências Geodésicas da Universidade Federal do Paraná. 2003.
- ANTUNES, A.F & LINGNAU, C. **Uso de índices de acurácia para avaliação de mapas temáticos obtidos por meio de classificação digital**. Anais GIS Brasil, Curitiba. 1997. CD-ROM
- BAATZ, M & SCHÄPE, A. **Mutiresolution segmentation: an optimization approach for high quality multi-scale image segmentation**. München. Disponível em <[www.definiens.com](http://www.definiens.com)> Acesso em março 2001.
- BLASCHKE, T, LANG, S, LORUP, E, STROBL, J & ZEIL, P. **Objected oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications**. Environmental information for planning. Vol 2. Metropolis-Verlag. 2000.
- DEFINIENS IMAGING, **ecognition, User's Guide 3.0**. Disponível em <http://www.definiens-imaging.com/documents/index.htm> . Acesso em jan. 2003
- CONGALTON, R; GREEN, K 1999. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Lewis Publishers, USA.1999b.
- FOODY, G. **Status of land cover classification accuracy assessment**. Remote Sensing for Environment, p.185-201.2002.
- GLEMSE, M; FRITSCH, D. **Data uncertainty in hybrid GIS**. IAPRS, Vol 32, Stuttgart. 1998.
- LABA, M et al. **Conventional and fuzzy accuracy assessment of New York gap analysis project land cover map**. In Remote Sensing of Environment. 81 p.443-455. 2002.
- NAESSET, E. **Conditional Tau coefficient for assessment of producer's accuracy of classified remotely sensed data**. ISPRS Journal of Photogrammetry, Elsevier, vol.51, p 91-98. 1996.
- ROSENFELD, G.H; LINS-FITZPATRICK, K. **Sampling for thematic map accuracy testing**. In Photogrammetric Eng. & Remote Sensing. Vol 48, n 1, p131-137. 1982.
- TOWNSEND, P. A. **A quantitative fuzzy approach to assess mapped vegetation classification for ecological applications**. Remote Sensing of Environment, 72, p.253– 267. 2000