

# MAPEAMENTO DE CITROS: AVALIAÇÃO DE CLASSIFICAÇÕES POR ÁRVORE DE DECISÃO

*Mapping of Citrus: Assessment of Classifications by Tree Decision*

**Gustavo Felipe Balué Arcoverde<sup>1</sup>**  
**José Carlos Neves Epiphany<sup>1</sup>**  
**Vagner Azarias Martins<sup>1</sup>**  
**Eduardo Eiji Maeda<sup>1,3</sup>**  
**Leila Maria Garcia Fonseca<sup>2</sup>**

<sup>1,2</sup> Instituto Nacional de Pesquisas Espaciais - INPE

<sup>1</sup> Divisão de Sensoriamento Remoto

<sup>2</sup> Divisão de Processamento de Imagens

Av. dos Astronautas, 1758, 12227-010, São José dos Campos (SP); Brasil

gustavo@dsr.inpe.br

epiphani@ltd.inpe.br

vagner@dsr.inpe.br

eemaeda@yahoo.com.br

leila@dpi.inpe.br

<sup>3</sup> University of Helsinki

Department of Geoscience and Geography

Gustaf Hällströmin katu 2, 00014, Helsinki, Finland

## RESUMO

O Brasil possui destaque mundial na produção de citros, e o Estado de São Paulo responde por mais de 80% da produção de laranja. Este fato, aliado à dificuldade de associação de padrão espectral a talhões de citros como um todo, faz com que estudos de técnicas de mapeamento de citros devam ser mais desenvolvidos no país. De forma geral, técnicas de classificação, mediante extração de multi-atributos por objeto, em imagens ópticas de sensoriamento remoto, têm demonstrado bons resultados. Algoritmos de árvores de decisão (AD), como o C 4.5, constituem métodos robustos para trabalhar com multi-atributos. O objetivo deste trabalho foi avaliar classificações de citros em imagens do sensor TM/Landsat-5, segundo duas abordagens: a) por AD a partir de valores de pixel; e b) por AD a partir de atributos de média e de multi-atributos por objeto. Usou-se um classificador mais usual, por máxima verossimilhança (Maxver), usando Mapas de Regras, como referência comparativa. As classificações geradas por AD apresentaram a melhor performance, com exceção da AD a partir de atributos de média por objeto. A classificação Maxver apresentou semelhança significativa com as melhores classificações geradas por AD. A classificação por AD gerada a partir de valores de pixel apresentou o melhor custo/benefício.

**Palavras chaves:** Classificação Orientada a Objeto, Árvore de Decisão, Mapas de Regras, Sensoriamento Remoto, Agricultura.

## ABSTRACT

Brazil is an important citrus producer. São Paulo State is responsible for more than 80% of the orange production in Brazil. This fact, associated with the difficulty to separate citrus from other crops require more technical studies of citrus mapping in the country. Classification techniques using multi-features extraction by object, on remote sensing optical images, have shown good results as a rule. Tree decision algorithms, such as C 4.5, are robust methods for working with multi-features. Here, we evaluate citrus classifications using TM/Landsat-5 remote sensing data generated by tree decision based on pixels values, and based on mean features and multi-features object oriented, with a usual classifier - maximum likelihood -, with a Rules Map approach. Classifications generated by tree decision presented the best performance, except the classification that used mean features object oriented. Maximum likelihood classification

presented significant similarity with the best classifications generated by tree decision. Tree decision classification generated from pixels presented the best cost/benefit relationship.

**Keywords:** Classification Oriented by Object, Tree Decision, Rule Maps, Satellite Remote Sensing, Agriculture.

## 1. INTRODUÇÃO

A partir da década de 1980, o Brasil passou a ser o maior produtor mundial de laranja, sendo que boa parte desta produção tem sido destinada à indústria do suco (HASSE, 1987). Atualmente, apesar da sensível expansão das áreas de cana-de-açúcar, o Estado de São Paulo concentra mais de 80% da produção de laranja (IBGE, 2008a). Na safra de 2006, o Brasil apresentou 921.432 ha de área plantada de citros (considerando laranja, tangerina e limão), o que equivaleu a 20,3 milhões de toneladas de frutos (IBGE, 2008b). Tais dados justificam a importância de estudos de monitoramento e planejamento de lavouras de citros, além de o cálculo de sua área agrícola ser importante para políticas públicas de estoques, preços de produtos, cálculo de impostos municipais, para agentes do agronegócio nas tomadas de decisão, e para a sociedade, pois compõem o conjunto de informações ao mercado sobre a oferta de produtos agrícolas (ADAMI, 2005; PINO, 1999).

A Food and Agriculture Organization (FAO), das Nações Unidas, recomenda o uso de imagens de sensoriamento remoto para o cálculo de áreas agrícolas (FAO, 1996). Técnicas de mapeamento de culturas agrícolas mediante imagens de satélite possuem ampla aplicação e têm demonstrado bons resultados para identificação de culturas agrícolas (GALLEGO, 2004; ORTIZ *et al.*, 1997). Entretanto, os talhões de citros apresentam padrão espectral pouco definido, o que pode ser um empecilho para mapeamentos via classificação automática de imagens de satélite. Esta falta de padrão espectral é justificada pela diversidade dos cultivares de citros, pelos tratamentos culturais aplicados, e pela própria estrutura da cultura em função das cultivares e da idade (SANCHES *et al.*, 2005).

Tendo em vista essas limitações, o uso de atributos que consideram características que são comuns na interpretação visual humana, tais como contexto, formas, bordas e textura (multi-atributos), tem demonstrado melhora em classificações automáticas em imagens de sensoriamento remoto óptico de média resolução (OLIVEIRA *et al.*, 2004; LOCH, KIRCHNER, 1997; BISCHOF *et al.*, 1992). Algoritmos para gerar árvores de decisão (AD), como o C 4.5, são baseados na entropia dos dados e no ganho de cada variável para predição de atributos categóricos, e têm uma abordagem não-paramétrica, que é utilizada para mineração de dados. Em WITTEN E FRANK (2005) e QUINLAN (1996) há uma descrição detalhada do algoritmo C 4.5. Assim, a geração de AD pode ser adequada para obter classificações de citros em imagens de satélite utilizando-se multi-atributos.

Desta forma, o objetivo deste trabalho foi avaliar classificações de citros por árvore de decisão

(AD), e também compará-las com um método tradicional de classificação por máxima verossimilhança (Maxver), utilizando a abordagem sub-pixels por Mapas de Regras, conforme ICHKU e KAMIELI (1996) e ALI (2002).

## 2. MATERIAL E MÉTODOS

### 2.1 Área de Estudo

A área de estudo deste trabalho compreendeu a região dos municípios de Colômbia e Barretos, ao norte do Estado de São Paulo, Brasil (Figura 1). O município de Colômbia foi utilizado como área de treinamento e o município de Barretos como área de teste dos classificadores. Desconsideraram-se as áreas com água. Esses dois municípios têm tradição no cultivo de citros, cuja área se manteve sem grandes alterações até a safra de 2006. No ano de 2007 houve algumas substituições de citros por cana-de-açúcar, fato que tem ocorrido em todo o Estado de São Paulo, justificado pelo incentivo do governo brasileiro para a produção de etanol. A safra de citros em 2006, considerando os dois municípios, atingiu 611.509 toneladas, abrangendo uma área de 27.651 hectares (IBGE, 2008b). Estas cifras equivaleram a aproximadamente 4% da produção e área de citros no Estado de São Paulo em 2006, respectivamente.

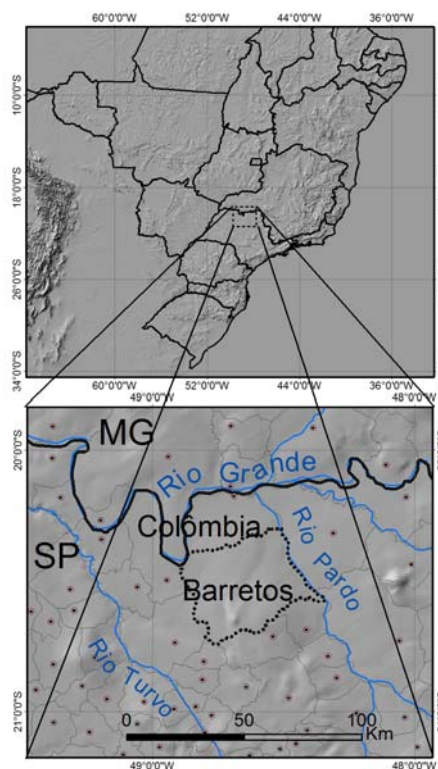


Fig. 1 - Área de estudo, destacando os municípios de Barretos e Colômbia.

## 2.2 Classificações

Para as classificações foram utilizadas imagens do sensor TM a bordo do satélite Landsat-5, particularmente por causa da presença da faixa espectral do infravermelho de ondas curtas, relevante para estudos de vegetação para fins agrícolas. Considerou-se o ano de 2006 como o ano-safra de citros para este estudo. Verificaram-se as imagens de datas com maior probabilidade de estarem livres de nuvens e que tivessem pouca influência de outras culturas, como a cana-de-açúcar. Sendo assim, foram escolhidas imagens de 11 de agosto de 2006 da órbita/ponto 221/74.

As AD foram geradas por extração de atributos por objeto e por pixel. As classificações por Maxver foram geradas a partir da informação por pixel. A seguir, são descritos os pré-processamentos e processamentos que foram levados a cabo para essas classificações.

Como pré-processamento, as imagens foram registradas e restauradas. O registro foi realizado mediante uma imagem base, disponível gratuitamente na Global Land Cover Facility – GLCF – (<http://glcfapp.umiacs.umd.edu:8080/esdi/index.jsp>), que correspondeu à data de 14 de maio 2000. A qualidade da resolução efetiva e espacial das imagens foi melhorada pelo emprego de restauração em todas as bandas, conforme BOGGIONE e FONSECA (2003). Desta forma, os pixels das respectivas imagens foram reamostrados de 30 metros (resolução espacial original) para 15 metros.

O processamento das imagens seguiu os seguintes passos: segmentação, extração de atributos, seleção de amostras, treinamento (geração das AD) e classificações. A segmentação e a extração de atributos foram realizadas somente para os casos de geração de AD por objeto. A técnica de segmentação utilizada foi por multi-resolução do programa DEFINIENS. Esta segmentação, concebida por BAATZ e SCHÄPE (2000), é baseada em um algoritmo baseado no crescimento de regiões, que visa minimizar a heterogeneidade interna dos segmentos gerados. A medição desta heterogeneidade é baseada em critério espectral e espacial. O critério espectral baseia-se nos valores de pixel de cada segmento, cujo cálculo de heterogeneidade interna é proporcional à média ponderada do desvio padrão de cada banda (HAPP et al., 2009). O critério espacial baseia-se na métrica entre proporções de compactação do segmento e suavidade de suas bordas. Outro fator que faz parte deste algoritmo de segmentação é a escala. Trata-se de um limiar estabelecido pelo usuário, que define a heterogeneidade máxima decorrente da união entre dois segmentos. Com base nestas considerações, procurou-se gerar uma segmentação a fim de detectar heterogeneidade de padrões de cobertura da terra na região, e, além disso, evitar que a heterogeneidade de alguma das bandas fosse preponderante sobre outra. Para tanto, anteriormente ao processo de segmentação, foi aplicado realce linear entre as bandas utilizadas para esta

operação - bandas 3, 4 e 5 -, visando ao aumento e à semelhança da variância entre as respectivas bandas espectrais. Como parâmetros da segmentação, foram definidos empiricamente o fator de escala 110, fator cor/forma 0,5/0,5 e fator compactidade/suavidade 0,65/0,45. E para auxiliar a escolha das amostras de treinamento para as classificações e posteriores avaliações, confeccionou-se um Mapa de Referência. Este mapa foi gerado por verificação em campo, realizada em março de 2007. A partir dos segmentos gerados, foram extraídos diferentes atributos. O segmento com informação de atributos passa a ser denominado *objeto*. Os atributos extraídos, utilizando as bandas originais 1, 2, 3, 4, 5 e 7, com respectivas abreviações, foram:

- a) médias (Mean),
- b) brilho (Brightness),
- c) máxima diferença (Max\_dif).

Os atributos extraídos por objeto, a partir das bandas originais 3, 4 e 5, com respectivas abreviações, foram:

- a) desvio-padrão (Stdev),
- b) razão (ratio),
- c) pixel mínimo (Min\_pix),
- d) pixel máximo (Max\_pix),
- e) média de borda interna (Me\_inne),
- f) média de borda externa (Me\_out),
- g) contraste de pixels vizinhos (Con\_nei),
- h) desvio-padrão de pixels vizinhos (Std\_nei),
- i) diferença média de vizinhos (Md\_nei),
- j) diferença média de vizinhos escuros (Md\_dark),
- k) diferença média de vizinhos claros (Md\_brig),
- l) relação de borda de vizinhos claros (Rel\_bri),
- m) diferença média de cenário (Scendif),
- n) razão de cenário (Scenrat),
- o) área (Area), comprimento (Length),
- p) largura (Width),
- q) largura/comprimento (Len\_width),
- r) comprimento de borda (Bord\_leng),
- s) assimetria (Asym),
- t) direção principal (Main\_direc),
- u) densidade (Density),
- v) índice de forma (Shp\_index),
- x) compactidade (Compactness),
- z) arredondamento (Roundness),
- aa) ajuste elíptico (Ellip\_fit),
- ab) raio de elipse circunscrita (Rad\_large),
- ac) raio de elipse inscrita (Rad\_small),
- ad) matriz de co-ocorrência de Haralick de: homogeneidade (Har\_hom), contraste (Har\_con), dissimilaridade (Har\_dis), entropia (Har\_ent), segundo momento (Har\_2mo), média (Har\_mea), desvio-padrão (Har\_std) e correlação (Har\_cor).

Esses atributos apresentaram, com a aplicação nas respectivas bandas espectrais, 90 variáveis de entrada. As fórmulas desses atributos estão detalhadas no Livro de Referência do programa DEFINIENS

(disponível em [http://www.pcigeomatics.com/products/ecog\\_applications/ecog5\\_ReferenceBook.pdf](http://www.pcigeomatics.com/products/ecog_applications/ecog5_ReferenceBook.pdf)).

As AD geradas por objeto foram realizadas a partir da totalidade dos atributos extraídos (multi-atributos) e também a partir de atributos de níveis de cinza médio (Mean). As AD geradas por pixel consideraram as informações das bandas espectrais originais do sensor TM/Landsat-5. As gerações das AD foram realizadas segundo o algoritmo C 4.5, inserido no programa de uso gratuito WEKA (disponível em <http://www.cs.waikato.ac.nz/ml/weka/>). O algoritmo C 4.5 tem o benefício de realizar treinamento com atributos nominais e/ou numéricos.

A geração de árvores de decisão pelo algoritmo C 4.5 baseia-se primeiramente na escolha de variáveis de menor entropia. Isto significa que são ordenadas e escolhidas as variáveis com um ganho maior de informação para a definição das amostras preditivas, ou seja, aquelas que detêm valores com menor variação para a predição de uma amostra de treinamento. Este requisito auxilia na geração de árvores com menos variáveis, e, portanto, árvores menores, além de reduzir o seu processamento. Para variáveis com valores numéricos, o algoritmo C 4.5 realiza limiarizações nelas de forma que resultem dois ramos de valores. Esta limiarização visa alcançar a menor entropia entre os blocos originados para determinada amostra preditiva. As variáveis com maior ganho são alocadas nos primeiros nós de uma AD. Cada nó correspondente a uma variável possui uma chave de decisão que descreve o corte de valores com menor entropia para a classificação de determinada amostra preditiva. Maiores detalhes podem ser verificados em WITTEN e FRANK (2005) e ARCOVERDE (2008).

Outro parâmetro a ser considerado é a poda da AD. O programa WEKA opera com dois tipos de poda de árvore: substituição de sub-árvores (*subtree replacement*) e elevação de sub-árvore (*subtree raising*). A ideia da primeira é a seleção de algumas sub-árvores e reposicionamento delas visando à diminuição do número de folhas. A segunda visa à diminuição de nós pela tentativa de junção das variáveis em poucos nós. A escolha de realizar uma poda de AD será baseada no cálculo de erro em realizar ou não uma poda. Este cálculo pode ser conferido em QUINLAN (1993) e WITTEN e FRANK (2005). Pelo algoritmo C 4.5, no programa WEKA, a poda de árvore é realizada de forma padrão pelo modo de elevação de sub-árvore, o qual foi adotado neste trabalho. Outro modo prático de redução da AD é pelo aumento de amostras mínimas por folha. O algoritmo C 4.5, ao definir uma árvore, estipula um número mínimo de amostras que cada folha pode resolver. Quando este valor mínimo é aumentado, a AD tem a tendência a diminuir e ser mais generalista. Entretanto, com este método, variáveis podem deixar de ser consideradas. Este método pode ser benéfico para casos de AD com muitas folhas e nós, contanto que haja uma manutenção razoável de precisão nas amostras de treinamento e que haja a permanência na AD das variáveis de interesse. Este método de poda também foi

utilizado neste trabalho. Maiores detalhes podem ser verificados em WITTEN e FRANK (2005) e ARCOVERDE (2008).

A geração da AD no WEKA é realizada por amostras previamente conhecidas, que no caso deste trabalho, foram escolhidas de acordo com o Mapa de Referência no município de Colômbia. A partir deste treinamento, foi gerada uma árvore de decisão visual no WEKA, cuja regra de decisão foi aplicada para o município de Barretos, considerando o respectivo conjunto de segmentos no caso da classificação por objeto, ou para os pixels da imagem, no caso da classificação por pixel.

Para a geração das AD por objeto, foram selecionadas 45 amostras de treinamento de “Citros” no município de Colômbia. Em princípio, para que a geração das AD fosse possível seria preciso definir pelo menos uma segunda classe. Desta forma, gerou-se uma classe desconhecida, denominada “Outros”, que não era de interesse, cuja função foi auxiliar a AD definir as amostras “Citros”. A geração da classe “Outros” deu-se de forma aleatória entre as amostras que não tivessem sido indicadas como áreas de “Citros”. O uso da aleatoriedade neste caso não é crítico, pois a geração da AD não sofre influência de distância estatística ou variância entre aglomerados de dados para a delimitação de classes.

Para determinar a quantidade de amostras da classe “Outros”, avaliaram-se treinamentos com diferentes quantidades da classe “Outros”. Estas avaliações basearam-se nos índices kappa do conjunto das amostras de treinamento, gerados através de validação cruzada de fator 5. Na geração de AD por objeto, a quantidade de amostras “Outros” foi testada com três e cinco vezes a quantidade de amostras “Citros”. A quantidade que tivesse o melhor índice kappa seria escolhida. Para a geração da AD por pixel, utilizaram-se como amostras de treinamento da classe “Citros” 500 pixels aleatórios que abrangessem os segmentos definidos como amostras de treinamento “Citros”. A quantidade de pixels aleatórios para as amostras da classe “Outros” seria correspondente a três ou cinco vezes a quantidade definida em relação à classe “Citros”, igualmente ao método estabelecido nas AD por objeto.

A escolha das AD foi baseada na redução do tamanho das AD, tendo em vista o aumento do número mínimo de amostras por folha e a porcentagem de acerto da classe “Citros”. As menores AD associadas à maior porcentagem de acerto de “Citros” seriam escolhidas e avaliadas para a classificação do município de Barretos. As taxas de acerto foram computadas pelo critério de validação cruzada de fator 5.

A classificação por Maxver considerou todas as bandas espectrais em seu estado original. A abordagem adotada para esta classificação foi através de uma análise dos Mapas de Regras por Maxver para a classe “Citros”. Nesta abordagem, é necessário ter a informação de uma classe somente, não sendo necessária a definição da classe “Outros”. Foram

utilizadas as mesmas amostras de treinamento da classe “Citros” empregadas na classificação por AD por pixel. A definição desta classificação foi baseada na limiarização do histograma do Mapa de Regras, através da verificação de vales e picos no histograma, de acordo com MORSE (2000). Para otimização deste processo, os valores do Mapa de Regras foram condensados para a escala de 0 a 255, com o aproveitamento dos valores mais significativos, e aplicou-se uma filtragem por passa baixa a fim de minimizar ruídos no histograma. O resultado desta limiarização teria uma resposta temática sobre os pixels na imagem - a classificação de citros. Devido ao inerente efeito de “salpicamento” que a limiarização do histograma poderia produzir na classificação de citros e, portanto, incoerente com a distribuição espacial desta cultura, foi aplicada filtragem por mediana a fim de minimizar tal efeito. Este procedimento também foi aplicado para o resultado da classificação por AD por pixel. A filtragem por mediana é indicada para valores inteiros, pois será sempre escolhido um dos valores existentes na imagem, além de que a mediana é uma das técnicas mais indicadas para eliminar ruídos e valores extremos, com a vantagem de preservar bordas (MATHER, 1999).

### 2.3 Avaliações

Para a avaliação das classificações, atribuíram-se aleatoriamente 500 pontos amostrais no município de Barretos-SP, excluindo os espelhos d’água, de forma independente para cada classificação. A partir da comparação das classes do Mapa de Referência e das respectivas classificações, foram gerados gráficos de erros de omissão e comissão, e índices kappa. Também, foram realizados testes de hipótese em pares de classificação para avaliar se a diferença entre os índices kappa foi significativa, ou seja, se os índices kappa foram significativamente iguais ou diferentes, de acordo com CONGALTON e MEAD (1983). Como esses testes pressupõem uma distribuição normal padrão, são atribuídos valores z para esse cálculo.

## 3. RESULTADOS E DISCUSSÃO

### 3.1 Classificações

Nos casos de geração de AD, o melhor resultado foi o que se atribuiu a classe “Outros” por três vezes à classe “Citros”. Desta forma, para a geração de AD por objeto, foram delimitadas 135 amostras de treinamento para a classe “Outros”, enquanto que no caso de geração de AD por pixel, este número foi de 1.500 amostras.

A avaliação do tamanho das AD geradas por multi-atributos por objeto deu-se conforme a Figura 2. Os tamanhos das AD apresentaram redução a partir de no mínimo seis amostras por folha, e mantiveram-se estáveis a partir de no mínimo oito amostras por folha. A porcentagem de acerto de “Citros” manteve-se praticamente constante até sete amostras por folha; a

partir de oito amostras por folha houve uma sensível melhora. A variação da porcentagem de acerto a partir de oito amostras por folha, apesar da permanência do tamanho da AD em sete atributos (categóricos ou não-categóricos) deve-se à aleatoriedade do procedimento da validação cruzada em atribuir amostras para treinamento e teste. De acordo com as observações consideradas, a redução da AD não apresentou uma melhora substancial da taxa de acerto da classe “Citros”. Em função disso, optou-se por escolher mais de uma AD para gerar as classificações por multi-atributos. Escolheram-se as AD com, no mínimo, 2, 6 e 8 amostras por folha, sendo denominadas Tree-multi-2, Tree-multi-6 e Tree-multi-8, respectivamente.

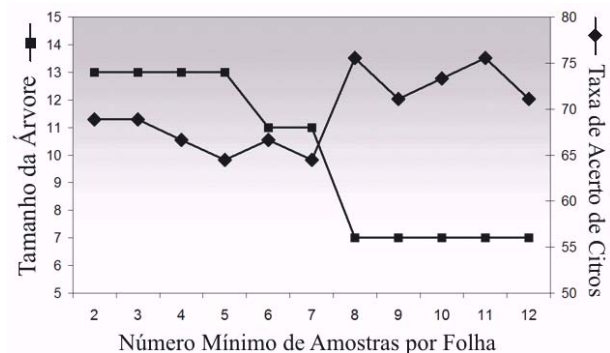


Fig. 2 - Avaliação do tamanho das AD (número de atributos) geradas por multi-atributos por objeto, em relação à taxa de acerto da classe “Citros” (percentual) e número mínimo de amostras por folha.

A avaliação do tamanho das AD geradas por extração de média de níveis de cinza por objeto é apresentada na Figura 3. Percebe-se que com nove amostras por folha houve uma melhora do acerto de “Citros” bastante considerável. Desta forma, esta AD foi escolhida para realizar a classificação de “Citros”. Esta AD denominou-se Tree-DN.




Fig. 3 - Avaliação do tamanho das AD geradas pela média de níveis de cinza por objeto, em relação à taxa de acerto da classe “Citros” e número mínimo de amostras por folha.

A avaliação do tamanho das AD geradas a partir dos valores de pixels originais das bandas espectrais é apresentada na Figura 4. Percebe-se que houve melhora da taxa de acerto para a classe “Citros”

com 90 amostras por folha, o que levou à escolha desta AD. Esta AD denominou-se Tree-Pix. As AD Tree-multi-2, Tree-multi-6 e Tree-multi-8, Tree-NC e Tree-Pix estão apresentadas nas Figuras 5, 6, 7, 8 e 9, respectivamente.

Para a limiarização do histograma do Mapa de Regras, optou-se empiricamente por uma filtragem passa baixa de 9 x 9 pixels. Apesar da retirada dos pixels residuais e da aplicação do filtro, o histograma resultante apresentou ruídos e não se conseguiram vales

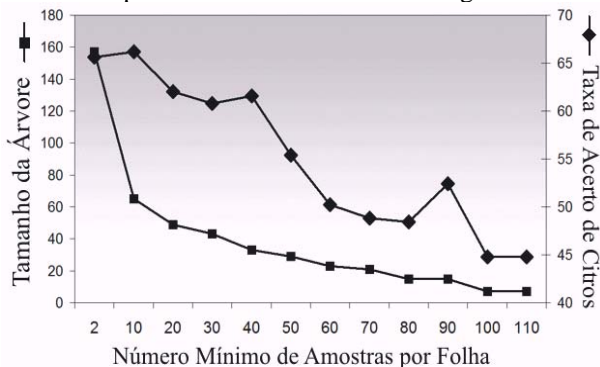


Fig. 4 - Avaliação do tamanho das AD geradas por valores de pixels das bandas originais, em relação à taxa de acerto da classe “Citros” e número mínimo de amostras por folha.

ou picos significativos para a sua limiarização (Figura 10). Portanto, houve a necessidade de uma maior intervenção visual para a verificação da abrangência espacial de “Citros” ao realizar limiarizações no histograma. Assim, verificou-se que um pequeno vale do histograma seria suficiente para a limiarização e consequente classificação. Esta classificação foi denominada Maxver-Pix.

Na Figura 11 são apresentados os resultados das classificações, a imagem de satélite e o mapa de referência utilizados. Percebe-se que as classificações realizadas por segmentos resultam em áreas mais coesas do que aquelas realizadas por pixel, ainda que estas classificações tivessem sido filtradas por filtro de mediana, fato que não é avaliado pelo índice kappa. As maiores confusões dos classificadores por AD foram atribuir algumas áreas de várzea como “Citros”, com exceção da Tree-Multi-8, que, contudo apresentou poucas áreas classificadas como “Citros”. A principal confusão que geralmente ocorre com as classificações de citros é a classificação de áreas de matas como sendo “Citros”; porém, somente as classificações Tree-DN e Maxver-Pix apresentaram mais áreas com este problema. As demais confusões com a classe “Citros” apresentaram-se em áreas rurais, mas sem mostrar uma tendência quanto ao erro. Áreas agrícolas, como cana-de-açúcar, seringais ou áreas com eucalipto foram pouco confundidas com a classe “Citros”.

### 3.2 Avaliações das Classificações

As áreas absolutas classificadas como “Citros” (Figura 12) foram bastante próximas às do Mapa de Referência. Observou-se que a maioria apresentou alguma subestimação em relação à área de “Citros” de referência.

A Figura 13 apresenta os erros de omissão e comissão das classificações. Percebe-se que as classificações por AD utilizando multi-atributos foram as que apresentaram menos erros. No entanto, a classificação utilizando segmentos com variáveis de níveis de cinza foi a que teve maiores erros. Em todos os casos os erros de omissão foram maiores do que os erros de comissão. Isto significa que as áreas classificadas não apresentaram demasiada confusão com a classe “Outros”; porém, proporcionalmente, faltaram mais áreas para serem incorporadas à classe “Citros”.

Os índices kappa resultantes das classificações são apresentados na Figura 14. Com exceção das classificações Tree-Pix e Tree-DN, as classificações puderam ser consideradas como boas, de acordo com os valores de referência indicados por LANDIS e KOCH (1977), cuja interpretação para a língua portuguesa pode ser constatada em LAMPARELLI *et al.* (2008). Apesar de a classificação Maxver-Pix ter apresentado valores de erros de omissão altos para a classe “Citros”, em geral apresentou kappa semelhante às melhores classificações (Tree-Multi-2, Tree-Multi-6 e Tree-Multi-8). Por outro lado, constatou-se que a avaliação da escolha das AD por multi-atributos, segundo as amostras de treinamento, foi pouco rigoroso, haja vista que o desempenho da classificação Tree-Multi-8 apresentou um resultado final ligeiramente inferior às classificações Tree-Multi-2 e Tree-Multi-6, apesar de ter apresentado um melhor desempenho em relação a estas nos treinamentos para a escolha do tamanho da AD. Este fato pode ter ocorrido pela pouca diferença de desempenho que estas três classificações tiveram com as amostras de treinamento, ou pela quantidade de amostras de treinamento não ter sido suficiente para a robustez desta avaliação prévia.

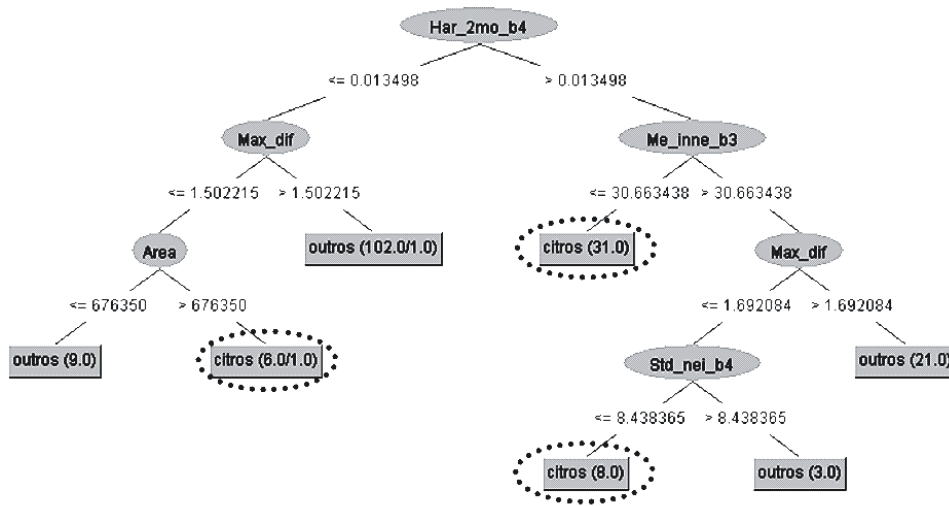


Fig. 5 - Esquema da AD Tree-multi-2.




Fig. 6 - Esquema da AD Tree-multi-6.




Fig. 7 - Esquema da AD Tree-multi-8.

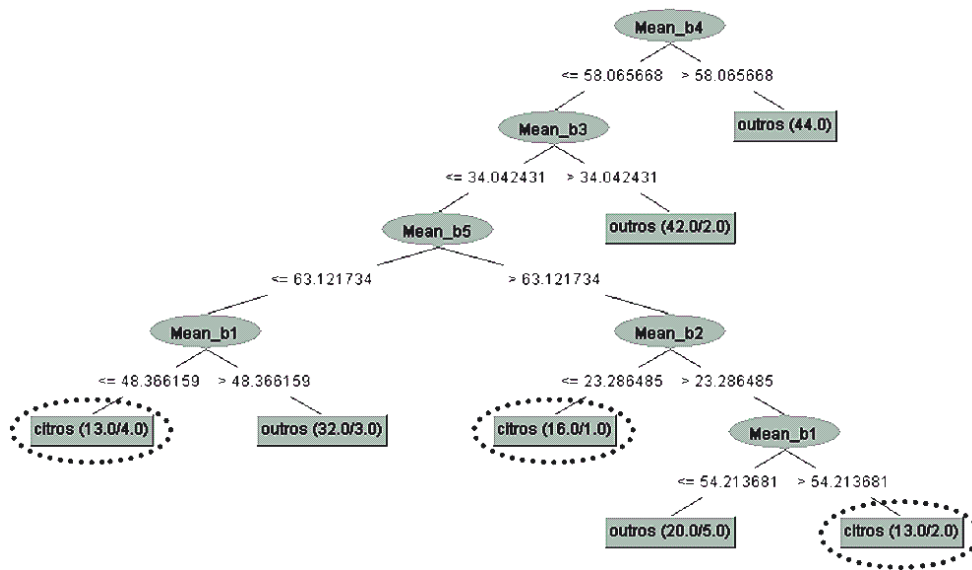


Fig. 8 - Esquema da AD Tree-NC.

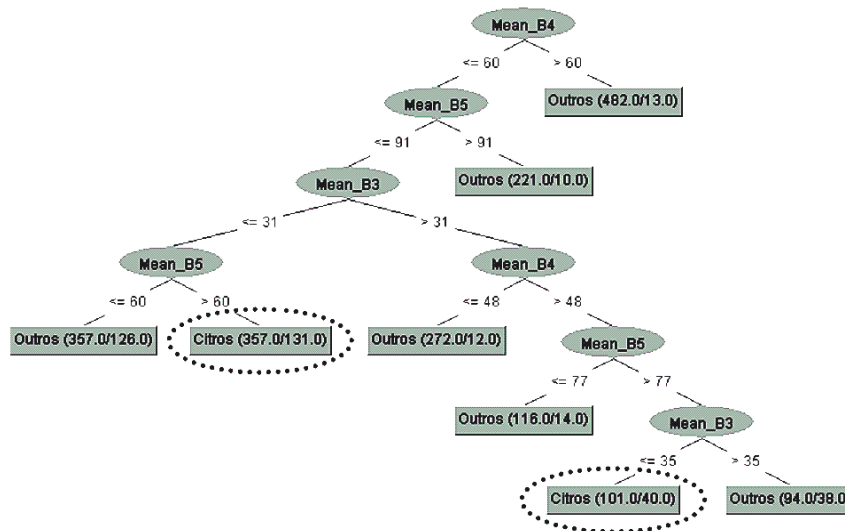


Fig. 9 - Esquema da AD Tree-Pix.




Fig. 10 - Limiarização do histograma do Mapa de Regras por Maxver. Em cinza está a parte aproveitada para a classificação.



Para a realização do teste de hipótese entre os índices kappa, estipulou-se como Hipótese verdadeira (Ho) que a diferença entre os índices kappa fosse igual a zero – classificações significativamente iguais – e como Hipótese falsa (H1) que a diferença entre os índices kappa fosse diferente de zero – classificações significativamente diferentes. Os testes foram realizados com 5% de significância. Este resultado é apresentado na Tabela 1. Observa-se que apenas a classificação Tree-DN foi significativamente diferente, de forma inferior ao restante das classificações, com exceção da classificação Tree-Pix, em que elas foram significativamente iguais.

Por este resultado, as classificações com os índices kappa maiores foram significativamente iguais

entre si, e as classificações piores foram significativamente iguais entre si. Este fato indica que em outras situações o desempenho das classificações que foram iguais entre si podem não guardar esta mesma ordem. Todavia, em termos absolutos, as classificações por AD utilizando multi-atributos tiveram o melhor desempenho.

Não obstante, o resultado pelas AD por multi-atributos contradiz um pouco a expectativa quanto ao desempenho do treinamento das amostras preditivas, uma vez que o desempenho da classificação Tree-Multi-8, apesar de ter apresentado um melhor desempenho em relação às classificações Tree-Multi-2 e Tree-Multi-6,c apresentou resultado final discretamente

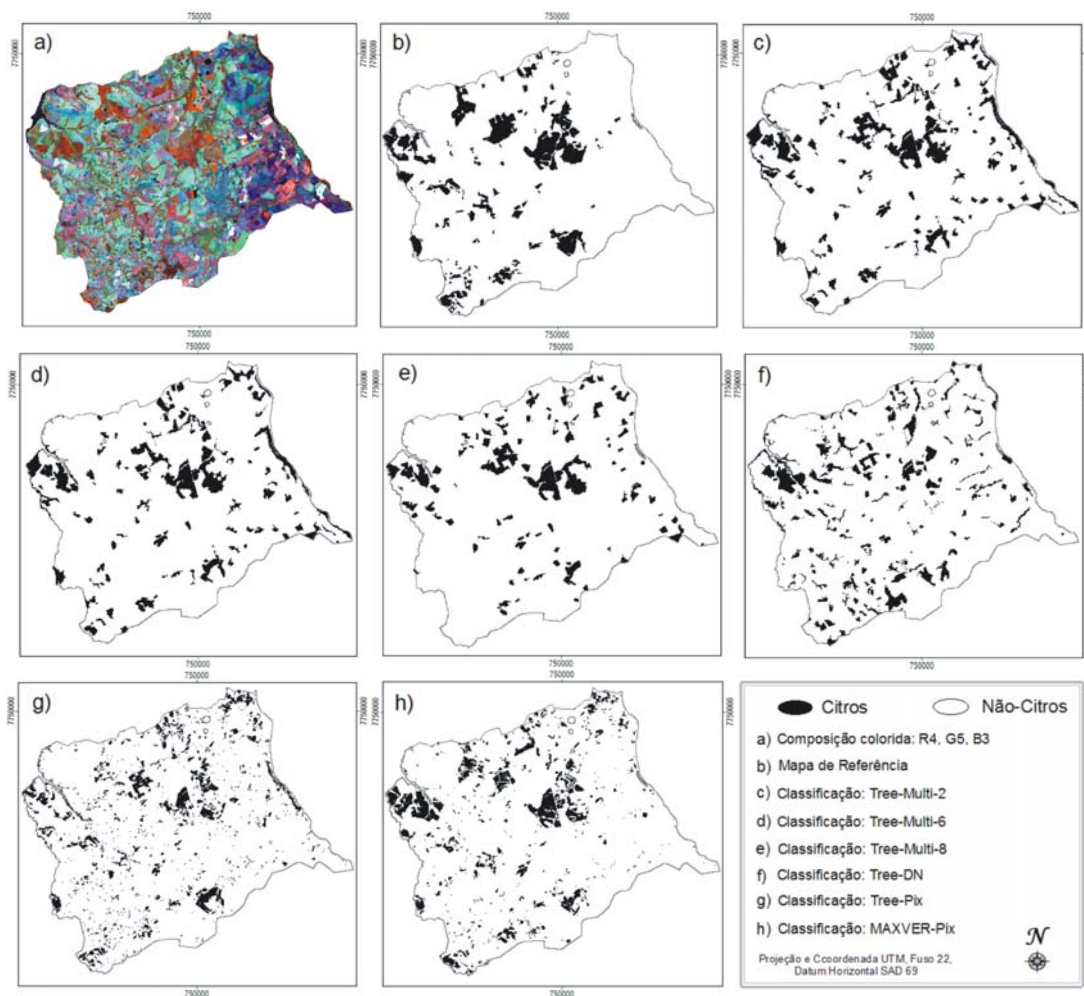


Fig. 11 - Espacialização de uma composição colorida, do Mapa de Referência e das classificações geradas.




Fig. 12 - Área de "Citros" das classificações em relação à área de "Citros" do Mapa de Referência.




Fig. 13 - Erros de Omissão e Comissão da classe "Citros".

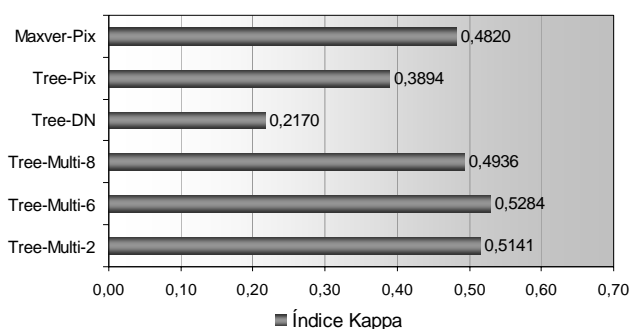


Fig. 14 - Índices Kappa das classificações.

TABELA 1 – Z-Calculado e Teste de Hipótese em considerar os índices kappa significativamente iguais (Ho) ou diferentes (H1), a 5% de significância.

	1	2	3	4	5	6
1	-	Ho	Ho	H1	Ho	Ho
2	0,1739	-	Ho	H1	Ho	Ho
3	0,2370	0,4100	-	H1	Ho	Ho
4	3,3777	3,6084	3,0561	-	Ho	H1
5	1,3921	1,5805	1,1315	1,8467	-	Ho
6	0,3561	0,5240	0,1250	2,8214	0,9702	-

1 - Tree-Multi-2 2 - Tree-Multi-6 3 - Tree-Multi-8  
4 - Tree-DN 5 - Tree-Pix 6 - Maxver-Pix

inferior às demais. Este fato pode ter ocorrido pela pouca diferença de desempenho que estas três classificações tiveram com as amostras de treinamento.

As AD Tree-DN e Tree-Pix foram as mais extensas, o que pode ser explicado pelo menor número de atributos disponíveis para delimitar as classes. Contudo, com o emprego da técnica de redução de árvores realizada neste trabalho, as árvores puderam ser reduzidas de modo a serem utilizáveis sem terem perdido desempenho. Comparativamente, as duas AD, apesar de terem como dados de entrada as mesmas variáveis - níveis de cinza -, a extração da média destes valores por objeto, utilizada na classificação Tree-DN, pode ter deteriorado a informação original necessária para gerar uma árvore com melhor desempenho, como a Tree-Pix.

A Classificação Maxver-Pix, apesar do mesmo rendimento quanto ao índice kappa em relação às AD por multi-atributos, apresentou salpicamento da distribuição das classes - comum em classificações por pixel -, ainda que fosse realizada filtragem por mediana. Também, a técnica de limiarização do Mapa de Regras, para se chegar à classificação, foi pouco robusta devido ao insubstituível empirismo do especialista nesta etapa.

#### 4. CONCLUSÕES

A abordagem empregada por AD foi bastante operacional, não demandando grandes pré-processamentos por parte do algoritmo C 4.5. A técnica de redução de árvore empregada neste trabalho permitiu que árvores de grandes dimensões pudessem ser diminuídas sem perderem precisão. No entanto, quanto ao desempenho em árvores de tamanhos menores, este procedimento não apresentou tão boa correspondência entre as amostras de treinamento e o resultado final da AD - caso das ADs geradas por multi-atributos.

O uso da segmentação para extração de objetos apresentou ganho topológico, em que a distribuição espacial das classes foi mais próxima do real. Por outro lado, a extração de multi-atributos por objeto demanda programas especializados em classificação orientada a objeto, cuja operação de extração é um tanto demorada.

O uso da classificação por AD por objeto somente apresentou ganho ao utilizar multi-atributos, já que a classificação que fez uso das médias de níveis de cinza por objeto apresentou o pior resultado. Não obstante, deve-se analisar melhor em futuros trabalhos, uma análise de substituição de atributos na AD por multi-atributos, segundo a similaridade de atributos. Isto poderia implicar que atributos mais particulares de serem extraídos (exigindo programas mais especializados) pudessem ser substituídos por atributos que fossem mais triviais, sem uma perda significativa do desempenho da AD.

A classificação Maxver, apesar da desvantagem de picoteamento das classes, apresentou desempenho semelhante às AD por multi-atributos. A classificação Tree-pix, por não demandar programas muito especializados, ser a técnica que demandou

menos pré-processamentos, e ter tido semelhança significativa com as melhores classificações, pôde ser considerada a classificação com melhor relação custo/benefício entre as classificações adotadas.

## REFERÊNCIAS BIBLIOGRÁFICAS

ADAMI, M.; MOREIRA, M. A.; RUDORFF, B. F. T.; FREITAS, C. C.; FARIA, R. T. Expansão direta na estimativa de culturas agrícolas por meio de segmentos regulares. **Revista Brasileira de Cartografia**, v. 57, n. 1, p. 22-27, 2005.

ALI, S. **Use of spectral and temporal unmixing for crop identification using multi-spectral data**. 2002. 63 p. Dissertação (Mestrado em Ciência em Geoinformática) – International Institute for Geo-information Science and Earth Observation, Enschede, Holanda, 2002. *On line*. Disponível em: <[http://www.itc.nl/library/papers/msc\\_2002/gfm/samia\\_ali.pdf](http://www.itc.nl/library/papers/msc_2002/gfm/samia_ali.pdf)>.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. In: XII Angewandte Geographische Informationsverarbeitung, Wichmann-Verlag, Heidelberg, 2000. **Proceedings...**

BISCHOF, H.; SCHNEIDER, W.; PINZ, A. J. Multispectral classification of Landsat-images using neural networks. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 3, p. 482-490, May 1992.

BOGGIONE, G. A.; FONSECA, L. M. G. Restoration of Landsat-7 Images. In: **International Symposium on Remote Sensing of Environment**, 2003, Honolulu. International Symposium on Remote Sensing of Environment, 2003. *On line*. Disponível em: <[http://www.dpi.inpe.br/~leila/publications/Restoration\\_of\\_Landsat-7\\_Images.pdf](http://www.dpi.inpe.br/~leila/publications/Restoration_of_Landsat-7_Images.pdf)>.

CONGALTON, R. G.; MEAD, R. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing**. American Society of Photogrammetry and Remote Sensing, v. 49, n. 1, p. 69-74, 1983.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO). **Multiple frame agricultural surveys: current survey based on area and list sampling methods**. Roma, 1996. v. 1.

GALLEGO, F. J. Remote sensing and land cover area estimation. **International Journal of Remote Sensing**, v. 25, n. 15, p. 3019-3047, ago 2004.

HAPP, P. N.; FERREIRA, R. S.; BENTES, C.; COSTA, G. A. O. P.; FEITOSA, R. Q. Segmentação multiresolução: uma abordagem paralela para segmentação de imagens de alta resolução em arquiteturas de múltiplos núcleos. In: **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 6935-6942. DVD, On-line. ISBN 978-85-17-00044-7. Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.18.01.10.13>>.

HASSE, G. **A laranja no Brasil**. Associação Brasileira de Exportadores de Cítricos (ABECITRUS). ABECITRUS. [S.l.]: Duprat & Lobe Propaganda, 1987. *On-line*. Disponível em: <[http://www.abecitrus.com.br/historia\\_br.html](http://www.abecitrus.com.br/historia_br.html)>.

ICHKU, C.; KAMIELI, A. A review of mixture modeling techniques for sub-pixel land cover estimation. **Remote Sensing Reviews**, v.13, p. 161-186, 1996.

INSTITUO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Lavouras**. IBGE. Rio de Janeiro: FIBGE, 2008. *On line*. Disponível em: <<http://www.ibge.gov.br/home/estatistica/indicadores/agropecuaria/lspa/default.shtm>>.

INSTITUO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE), **Sistema IBGE de recuperação automática (SIDRA): área plantada**. Rio de Janeiro: IBGE, 2008. *On line*. Disponível em: <<http://www.sidra.ibge.gov.br/bda/acervo/acervo2.asp?ti=1&tf=99999&e=c&p=PA&v=109&z=t&o=11>>.

LAMPARELLI, R. A. C.; CARVALHO, W. M. O.; MERCANTE, E. Mapeamento de semeaduras de soja (*Glycine max* (L.) Merr.) mediante dados MODIS/TERRA e TM/LANDSAT 5: um comparativo. **Engenharia Agrícola**, v. 28, n. 2, p. 334 -344, 2008. *On-line*. Disponível em: <<http://www.scielo.br/pdf/eagri/v28n2/a14v28n2.pdf>>.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, vol. 33, pp. 159-174, 1977.

LOCH, R. E. N.; KIRCHNER, F. F. Classificação de imagens multiespectrais Landsat TM e feições de textura: mapeamento da cobertura da terra. **Revista Floresta**, v. 27, n. 1/2, p.41-58, 1997. *On-line*. Disponível em: <<http://ojs.c3sl.ufpr.br/ojs2/index.php/floresta/article/viewFile/2297/1917>>.

MATHER, P. M. **Computer processing of remotely-sensed images**. United Kingdom: University of Nottingham, 1999. 294 p.

MORSE, B. S. **Lecture 4: Thresholding**. Brigham Young University. Edimburgo, Escócia: School of Informatics, University of Edimburg, 2000. *On-line*. Disponível em:<  
[http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL\\_COPIES/MORSE/threshold.pdf](http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/MORSE/threshold.pdf)>.

OLIVEIRA, J. A.; DUTRA, L. V.; RENNÓ, C. D. Seleção e extração de atributos para classificação de regiões. In: WORKSHOP DOS CURSOS DE COMPUTAÇÃO APLICADA DO INPE, 4. (WORCAP), 2004, São José dos Campos. **Anais...** São José dos Campos: INPE, 2004. CD-ROM, *On line* . Disponível em:  
<<http://urlib.net/lac.inpe.br/worcap/2004/09.30.19.48>>.

ORTIZ, M. J.; FORMAGGIO, A. R.; EPIPHANIO, J. C. N. Classification of croplands through integration of remote sensing, GIS, and historical database. **International Journal of Remote Sensing**, v. 18, n. 1, p. 95-105, 1997.

PINO, F. A. Área cultivada e ICMS. **Informações Econômicas**, v.29, n.3, p. 7-14, 1999.

QUINLAN, J. R. Improved use of continuous attribute in C 4.5. **Journal of Artificial Intelligence Research**, v. 4, p. 77-90, 1996. *On-line*. Disponível em: <  
<http://www.jair.org/media/279/live-279-1538-jair.pdf>>.

SANCHES, I. D.; GURTLER, S.; FORMAGGIO, A. R. Discriminação de variedades de citros em imagens CCD CBERS-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12. (SBSR), 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. p. 277-284. CD-ROM, *On-line*. ISBN 85-17-00018-8. Disponível em:  
<<http://urlib.net/ltid.inpe.br/sbsr/2004/11.19.19.18>>.