

Classificação espectro-temporal para identificação de extensas áreas de culturas agrícolas empregando imagens MODIS

Alessandra Lopes Braga ¹
Carlos Antônio Oliveira Vieira ²

¹Instituto Federal do Espírito Santo - IFES/Geomática
Avenida Vitória, 1729 - Bairro Jucutuquara - 29040-780 - Vitória - ES, Brasil
{ale}@ifes.edu.br

²Universidade Federal de Santa Catarina - UFSC/CFH/GCN
Caixa Postal 476 - 88010-970 - Trindade - Florianópolis - SC, Brasil
{carlos.vieira}@cfh.ufsc.br

Abstract. A methodology that takes into account a multitemporal multispectral analysis applied to MODIS images in order to classify croplands in a region of Limeira-SP, southeast of Brazil is presented. This paper presents a comparative study of two different classifiers (Artificial Neural Network and Maximum Likelihood), two interpolators (Collocation and Polynomial Trend Surface) and with three reference images obtained using a resampling method, using a digitizing one and neighborhood operation, which consists of the elimination of pixels with neighborhood with high variation on the digital level. The experiment was conducted by applying the Spectral Temporal Response Surface (STRS) approach. Results show that the neural networks give the best results, even with a few reference data of sample. The results also present the importance of generate a high quality reference image.

Palavras-chave: crop classification, spectral-temporal analysis, artificial neural network, classificação de culturas, análise espectro-temporal, redes neurais artificiais.

1. Introdução

Sensoriamento Remoto é a ciência e a arte de se obter informações sobre determinado objeto sem que esteja em contato físico com esse objeto, pela análise dos dados adquiridos por aeronaves e/ou satélites (Lillesand e Kiefer, 1999; Mather, 1999).

Segundo Schowengerdt (1997), importantes são as aplicações para os dados de sensoriamento remoto, dentre elas: agricultura, meteorologia, mapeamento, segurança e monitoramento ambiental. Sendo a agricultura uma das áreas de aplicação com maior demanda de dados de sensores orbitais, por permitem extrair informações de áreas cultivadas em grandes extensões territoriais e possibilita monitorar as culturas ao longo do seu ciclo de crescimento e desenvolvimento. Além disso, as imagens orbitais possuem um custo relativamente baixo, quando comparados às fotografias aéreas.

Na produção agrícola é necessário fazer um acompanhamento periódico, visto que as culturas levam um determinado tempo para se desenvolver. Devido ao caráter global, sinóptico, multiespectral e repetitivo faz com que o sensoriamento remoto com o uso de imagens de satélites, seja uma ferramenta indispensável para acompanhar a dinâmica agrícola principalmente em países de grandes dimensões como o Brasil (Sanches *et al.*, 2005).

Para acompanhar a dinâmica agrícola utiliza-se o procedimento de reconhecimento de padrões espectrais das imagens, gerando-se o mapa temático. Este processo é também conhecido como classificação, que de acordo com Lillesand e Kiefer (1999), tem como objetivo categorizar, por meio de procedimentos computacionais, todos os *pixels* de uma determinada imagem, atribuindo a cada um deles um “rótulo” que os relaciona a uma classe informacional (Mather, 1999).

Muitos algoritmos paramétricos têm sido empregados na classificação de imagens digitais provenientes de sensores remotos, entre eles o algoritmo da Máxima Verossimilhança

(MaxVer). As redes neurais artificiais (*Artificial Neural Network* - ANN) têm sido empregadas com sucesso na classificação de imagens, pois apresentam algumas vantagens sobre os classificadores estatísticos, como por exemplo, o treinamento com um pequeno número de amostras, não ser um método paramétrico, e com grande capacidade de generalização - capacidade de reconhecer com precisão padrões que não participaram do processo de treinamento (Tso e Mather, 2001; Kavzoglu e Mather, 2003).

Segundo Vieira (2000) a maioria dos procedimentos de classificação de imagens fundamenta-se na simples investigação da característica radiométrica do *pixel* (análise multiespectral). Este procedimento assume implicitamente que a cultura possui o mesmo estágio fenológico, o que de fato não ocorre, mesmo considerando uma área homogênea, devido aos diferentes datas de plantio, diferentes tipos de solo e condições climáticas. Outro aspecto importante está relacionado à periodicidade de aquisição de imagens com pouca cobertura de nuvens, pois nas regiões tropicais, a época chuvosa é, em geral, coincidente com o período de desenvolvimento da maioria das culturas agrícolas (Formaggio et al., 2005).

A resposta espectral das vegetações (principalmente culturas agrícolas) muda com o desenvolvimento da planta, desta forma é apropriada à utilização da análise multitemporal considerando as características espectrais das imagens de satélite. Neste contexto, o objetivo deste trabalho é adaptar e utilizar a metodologia da Superfície de Resposta Espectro-Temporal (STRS - *Spectral-Temporal Response Surface*) introduzida por Vieira (2000), que leva em consideração os aspectos multitemporal e multiespectral das imagens MODIS (*Moderate Resolution Imaging Spectroradiometer*) para classificar extensas áreas de culturas agrícolas, podendo ser estimada a área plantada.

2. Metodologia de trabalho

2.1. Área de estudo e dados utilizados

A área de estudo corresponde à abrangência do Escritório de Desenvolvimento Regional (EDR) de Limeira, uma das divisões administrativas da Coordenadoria de Assistência Técnica Integral (CATI) do Estado de São Paulo, compreendendo os seguintes municípios: Porto Ferreira, Pirassununga, Analândia, Santa Cruz da Conceição, Araras, Cordeirópolis, Corumbataí, Ipeúna, Iracemápolis, Itirapina, Leme, Limeira, Rio Claro e Santa Gertrudes. Esta área situa-se a leste no Estado de São Paulo cuja área estimada chega a 497.598,3 ha.

Foram utilizadas as imagens Landsat, que ficam localizadas no encontro de duas órbitas/pontos: 220/75 e 220/76 - para a data de 08/08/2004, para derivar a imagem de referência. No processo de registro dessas imagens foram usadas imagens ortorretificadas disponibilizadas pela NASA do sensor ETM+ do satélite Landsat-7 do ano 2000.

A área teste refere-se a um recorte de imagens MODIS. Para Zhan et al. (2002), este sensor é um radiômetro-imageador com cobertura diária em resoluções espaciais de 250, 500 e 1000 m, contando com 36 bandas espectrais que se estendem do visível ao infravermelho termal. MODIS fornece uma alta resolução radiométrica (16 bits), com uma excelente resposta para cada banda. Dados MODIS já vêm corrigidos dos efeitos atmosféricos e georreferenciados.

Esses dados são disponibilizados na forma de produtos, para esta pesquisa utilizou-se o produto MOD13, com as respectivas bandas: azul, vermelho, infravermelho próximo (NIR), além de uma banda localizada na faixa do infravermelho médio (MIR). As bandas do vermelho e NIR possuem resolução de 250m, as outras duas bandas foram reamostradas de 500m para 250m. Na análise multitemporal foram utilizadas 15 imagens, com 424x309 *pixels*, todas convertidas para 8 Bits.

2.2. Análise Multitemporal

Uma única imagem de satélite pode não fornecer informações espectrais suficientes para permitir identificar todas as culturas plantadas ou até uma mesma cultura em diferentes estágios fenológicos. Entretanto, imagens multitemporais podem fornecer maiores informações sobre a área plantada e indicações sobre o crescimento e desenvolvimento de culturas, os quais podem ser elementos chaves na discriminação espectral de diferentes culturas (Apan e Potgieter, 2002). Vieira (2000) propôs uma metodologia que explora o uso da STRS, para caracterizar o comportamento de cada *pixel* em relação ao tempo de aquisição das imagens e comprimento de onda usados.

Na metodologia STRS cada *pixel* é representado como um ponto no espaço tridimensional onde os eixos X, Y e Z representam tempo, comprimento de onda e reflectância, respectivamente. Tendo essa representação tridimensional, uma superfície analítica é interpolada por esses pontos (pontos de controle), os quais podem ser irregularmente espaçados. Os pontos de controle são extraídos com o auxílio da imagem de referência. Para interpolar essas superfícies podem ser utilizados dois métodos de interpolação: o *Polynomial Trend Surface* (PTS) e o *Collocation*. O método interpolador PTS, normalmente interpola os pontos de controle extraíndo a tendência da superfície, enquanto que o método *collocation*, tenta ajustar completamente a superfície aos pontos de controle.

Uma vez interpoladas essas superfícies (representando as culturas agrícolas) o processo de classificação fica reduzido à comparação da forma dessas superfícies, ou seja, superfícies com as mesmas formas, pertencem ao mesmo tipo de cultura agrícola.

Considerando que os coeficientes das equações, definem a forma das superfícies interpoladas, eles podem ser também usados para extrair os parâmetros das superfícies analíticas. Após essa parametrização das superfícies, os coeficientes podem ser usados como o vetor de entrada para o processo de classificação supervisionada.

2.3. Imagens de Referência

Uma das questões básicas que limitam o uso de imagens de satélite no monitoramento de culturas agrícolas é o período de aquisição, devido à interferência de nuvens. Com as características dos sensores atualmente em uso, há um conflito entre uma redução expressiva na resolução espacial em favor da ampliação da resolução temporal. Assim sendo, coexistem sensores de alta resolução espacial, como o ETM+ do Landsat 7 (30 m x 30 m) e baixa frequência de aquisição com sensores de baixa resolução espacial como o MODIS e alta frequência de re-visita. Devido à baixa resolução espacial das imagens MODIS, foram adquiridas as imagens de referência a partir de imagens Landsat.

Três imagens de referência foram utilizadas. A primeira gerada a partir da imagem temática de Limeira (cedida pelo INPE) com resolução de 30m. Adotou-se o seguinte procedimento: reamostragem: 30 m para 250 m; filtro mediana 3 x 3; remoção de classes informacionais com menos de 1000 *pixels*.

Gerou-se uma imagem de referência com 7 classes informacionais, com as respectivas proporções dispostas na Tabela 3. A segunda imagem de referência foi gerada a partir de amostras coletadas digitalizando-se polígonos aleatoriamente sobre as classes de interesse na imagem, sempre buscando capturar amostras mais homogêneas para representar o máximo possível as características de cada classe informacional (Tabela 3).

A terceira imagem de referência foi gerada a partir da imagem de referência por Digitalização de polígonos homogêneos, usando o desvio padrão do nível de cinza (também denominado nível digital) do *pixel* com os seus vizinhos. Para tal procedimento utilizou-se a ferramenta *Focal Statistics* do ArcGis.

A ferramenta *Focal Statistics* do ArcGis faz diversas operações estatísticas, valor médio, soma, valor máximo, valor mínimo, mediana, desvio padrão, entre outros. Para este trabalho

optou-se pelo desvio padrão, pois esta medida leva em consideração a totalidade dos valores da variável em estudo. Para esta operação de desvio padrão, escolheu-se uma máscara retangular no tamanho 3x3, para efetuar a operação de vizinhança.

A janela móvel percorre toda a imagem (424 linhas por 309 colunas, imagens MODIS). Na Tabela 1, mostra-se um exemplo ilustrativo da operação de vizinhança com apenas (5 linhas por 5 colunas), utilizando a equação de desvio padrão. No lado esquerdo do recorte da imagem e no lado direito o resultado da operação de vizinhança.

Tabela 1: Exemplo ilustrativo da Operação de vizinhança.

	0	1	2	3	4	5	...	308
0	18	22	22	19	18	18	...	
1	18	18	22	14	18	18	...	
2	28	22	22	25	15	19	...	
3	24	25	25	27	23	21	...	
4	25	24	26	21	20	22	...	
...				
423								

→

	0	1	2	3	4	5	...	308
0	x	x	x	x	x		...	
1	x	3,2	3,2	3,6	3,1		...	
2	x	3,3	4,1	4,6	4,4		...	
3	x	1,9	2,0	3,7	3,5		...	
4	x	1,8	3,2	3,4	2,9		...	
...				
423								

Para chegar-se ao produto final, a imagem de referência, foi feita uma operação de sobreposição (*overlay*). Foi utilizado um *overlay* multiplicativo, com a imagem resultante do processo de operação de vizinhança e com a imagem de referência por Digitalização.

A cultura de cana-de-açúcar, a mais representativa da região, possui o período de colheita entre os meses de abril a novembro, desta forma utilizou-se a imagem MODIS na data 21/03/2004 (dia juliano 081), data pouco antes da primeira colheita. A partir desta imagem geraram-se diversas imagens variando o desvio padrão, variando 2, 3, 4 e 5 níveis de cinza (NC), para cada uma das 4 bandas do sensor MODIS (Banda 1, Banda 2, Banda 3 e Banda 6). Na Tabela 2, está indicado a quantidade de *pixels* para cada variação do nível digital, escolheu-se a Banda 2, pois esta banda apresentou a menor variação dos NC.

Tabela 2: Números de *pixel*/classe para cada limiar do desvio padrão do nível de cinza do pixel e sua vizinhança.

Classes	Variação dos Níveis de Cinza (NC)				
	5 NC	4 NC	3 NC	2 NC	1 NC
Cana-de-açúcar	1421	1297	843	302	240
Cítrus	735	661	365	117	99
Mata	733	684	356	116	96
Pasto	304	268	135	49	42
Eucalipto	279	246	161	67	48
Soja	249	223	129	28	26
Milho	222	201	102	32	27
Total	3943	3580	2091	711	578

O ideal seria uma imagem com desvio padrão que não ultrapasse o valor de zero nível de cinza. Valor de zero NC significa dizer que não há variação do nível digital do *pixel* com os seus vizinhos, isso seria o ideal, pois resultaria em amostras homogêneas na imagem de referência. Porém, à medida que diminui o nível de cinza também diminui o número de *pixels* por classe (Tabela 2), resultando assim numa amostragem insatisfatória. Optou-se desta forma, por gerar uma imagem de referência eliminando os *pixels* que possuíssem o desvio padrão da variância do nível de cinza maior que 5 níveis de cinza (Tabela 3).

As imagens de referência foram rotuladas distintamente para fins de comparação das metodologias empregadas na sua obtenção como Reamostragem (Tabela 3) para a imagem de referência 1 (Refer_1), como Digitalização em tela para a imagem de referência 2 (Refer_2) e como Operação de vizinhança para a imagem de referência 3 (Refer_3).

Tabela 3: Classes da imagem de referência.

Classes	Refer_1		Refer_2		Refer_3	
	<i>Pixels</i>	Percentual (%)	<i>Pixels</i>	Percentual (%)	<i>Pixels</i>	Percentual (%)
1	5167	7,01	824	17,70	1421	36,04
2	28327	38,45	1651	35,40	735	18,64
3	4406	5,98	288	6,20	733	18,59
4	3044	4,13	318	6,80	304	7,71
5	9365	12,71	836	18,00	279	7,08
6	22261	30,22	410	8,80	249	6,31
7	1102	1,50	329	7,10	222	5,63
Total	73672	100	4656	100	3943	100

Legenda: (1) Mata; (2) Cana-de-açúcar; (3) Milho; (4) Soja; (5) Cítrus; (6) Pasto; (7) Eucalipto.

2.4. Classificação

Para o processo de classificação multitemporal, foram selecionadas amostras aleatórias para o treinamento e validação dos classificadores MaxVer e ANN. Cada amostra possui:

- Imagem de Referência 1: 99 *pixels*/classe para o treinamento e 33 *pixels*/classe para a validação (total 924 *pixels*);
- Imagem de Referência 2: 96 *pixels*/classe para o treinamento e 32 *pixels*/classe para a validação (total 896 *pixels*);
- Imagem de Refer_3: 96 *pixels*/classe para o treinamento e 32 *pixels*/classe para a validação (total 896 *pixels*).

As imagens foram adquiridas em 15 diferentes datas expressas em dias Juliano (eixo x) e a componente espectral foi caracterizada pelo valor médio do comprimento de onda (eixo y). Desta forma as quatro bandas do sensor MODIS azul (0,459 - 0,479 μm), vermelho (0,620 - 0,670 μm), NIR (0,841 - 0,876 μm) e MIR (1,628 - 1,652 μm), foram representadas 0,469; 0,650; 0,859; 1,640 μm , respectivamente. A propriedade radiométrica foi expressa em reflectância (eixo z).

Foi gerado para cada *pixel*, 60 pontos de controle tridimensionalmente (15 imagens MODIS com quatro bandas espectrais). Antes da fase de interpolação das superfícies, estes pontos de controle foram re-escalados para o intervalo [0, 1], para os três eixos.

Para o interpolador PTS foram utilizados 60 pontos de controle para ajustar a superfície empregando uma função polinomial do terceiro grau (10 coeficientes), considerando as restrições matemáticas no processo de interpolação.

Os mesmos pontos de controle foram utilizados para ajustar a superfície usando o interpolador *Collocation*, gerando-se assim 60 coeficientes. Para ambos interpoladores, os coeficientes foram re-escalados novamente para o intervalo [0, 1], para utilização nas fases de treinamento e teste dos classificadores.

O modelo de arquitetura ANN utilizado foi o *feed-forward*, com múltiplas camadas, com o algoritmo de treinamento para aprendizagem supervisionada *backpropagation*.

Utilizou-se o simulador de redes neurais “*Java Neural Network Simulator*”, desenvolvido pelo Instituto Wilhem-Schickard para Ciência da Computação (WSI) em Tübingen,

Alemanha. Este simulador é baseado no *Stuttgart Neural Network Simulator 4.2* (Zell et al., 1996), com uma nova interface gráfica.

Na etapa de treinamento e validação diferentes arquiteturas foram testadas: variando o nº de neurônios na camada de entrada (10 coeficientes para o PTS e 60 coeficientes para o *Collocation*); variando o nº de neurônios na camada interna e/ou nº de camadas internas; e todas tendo o mesmo nº de neurônios na camada de saída (7 classes informacionais).

Os resultados obtidos com a aplicação do método STSR foram submetidos a procedimentos de avaliação estatística com o intuito de verificar a precisão da classificação. Para tanto, gerou-se uma matriz de confusão, a partir de uma amostragem independente, com os coeficientes de exatidão global, *Kappa* e variância do *Kappa*, para cada classificador e ambos interpoladores. O coeficiente *Kappa* é a medida de como a classificação coincide com a imagem de referência (Congalton e Green, 1999). Os classificadores (ANN e MaxVer) foram comparados para verificar se existem diferenças estatisticamente significantes entre os classificadores. Formulações para o cálculo dessas medidas estatísticas podem ser encontrados em Congalton e Green (1999).

3. Resultados e Discussão

Os procedimentos de classificação multitemporal tiveram a finalidade de estimar áreas de extensas culturas agrícolas, utilizando-se a metodologia STRS. Para tal, foi selecionado um conjunto de amostras aleatórias, tanto para o treinamento quanto para a validação. Para a imagem de referência Reamostragem (Refer_1) foram selecionados 924 *pixels* representados temporalmente e espectralmente, com 132 *pixels* por classe. Já para as outras duas imagens de referência, Digitalização em tela (Refer_2) e Operação de vizinhança (Refer_3), selecionou-se 896 *pixels* representados temporalmente e espectralmente, com 132 *pixels* por classe. Nesta amostragem representaram-se os sete tipos de cobertura mais representativos área de estudo: cana-de-açúcar, cítrus, mata, pasto, eucalipto, soja e milho.

Para as classificações com a imagem de referência Refer_1, foram utilizados 693 *pixels* para o treinamento e 231 *pixels* para a validação. E para as outras classificações com as imagens de referência Refer_2 e Refer_3, utilizou-se 672 *pixels* para o treinamento e 224 *pixels* para a validação. A precisão da classificação foi expressa como porcentagem correta para as amostras independentes de validação. Tanto, em classificações usando o algoritmo ANN como o MaxVer, os *pixels* foram rotulados para a classe informacional que possuía a maior probabilidade.

Todas as classificações geradas foram comparadas usando os índices *kappa* e de exatidão global, para cada interpolador e com os classificadores MaxVer e ANN. Observando-se a Tabela 13, verifica-se que o melhor desempenho da classificação (*Kappa* = 0,589) foi obtido utilizando-se a Refer_2 (D), com o classificador ANN e interpolador COL, e a pior classificação obtida (*Kappa* = 0,197) foi a configuração usando a Refer_1 (R), com o classificador MaxVer e o interpolador COL. Consequentemente, esse resultado evidencia a importância da escolha de polígonos mais homogêneos, quando da geração da imagem de referência, como também confirma a deficiência do método MaxVer em gerar os parâmetros adequados durante a fase de treinamento, quando há limitação no tamanho das amostras de treinamento.

Na classificação pelo MaxVer, obteve-se melhores índices *kappa* e de exatidão global para o interpolador PTS, para as três metodologias de Refer_1, Refer_2 e Refer_3, em relação ao interpolador COL (Tabela 4). A superioridade verificada pelo MaxVer utilizando o interpolador PTS deve-se ao fato de haverem menos coeficientes utilizados como variáveis discriminantes no processo de classificação. Portanto, há que se ter muito cuidado quando o número de amostras for consideravelmente reduzido em relação ao número de variáveis discriminatórias.

Notou-se um melhor desempenho do classificador ANN usando o interpolador COL em relação ao PTS, para as metodologias Refer_2, provavelmente devido às características não-paramétricas desse classificador (Tabela 4). Uma das vantagens da ANN é justamente a possibilidade de se obter um bom resultado com poucas amostras de treinamento. Uma característica importante no desempenho deste classificador é a definição da arquitetura da rede, pois redes menores generalizam melhor.

No caso da metodologia Refer_3, esperavam-se melhores resultados em comparação com a metodologia Refer_2. O que não ocorreu para nenhum dos interpoladores, COL e PTS, com o algoritmo MaxVer, possivelmente deve-se ao fato das amostras presentes nesta imagem de referência não seguirem a distribuição multinormal (tem-se como premissa do classificador MaxVer para imagens de sensoriamento remoto: a maioria das feições segue distribuição multinormal).

Problema de “*pixels de mistura*” ocorre em imagens de Sensoriamento Remoto, devido à resolução espacial dos sensores, onde permite que um elemento da cena (correspondente a um *pixel* da imagem) inclua mais de um tipo de cobertura do terreno. Este problema observado no processo de classificação, “*pixels de mistura*”, deve-se a resolução espacial das imagens MODIS (250 m) utilizadas nesta dissertação. Este tipo de problema ocorre principalmente nas fronteiras entre os diferentes alvos, como por exemplo, na fronteira entre cana-de-açúcar e pasto.

A imagem temática que serviu de base para a geração da imagem de referência Reamostrada, Refer_1, foi feita uma classificação supervisionada (segmentação com a posterior utilização do algoritmo ISOSEG) seguida de uma interpretação visual. Nesta classificação realizou-se apenas uma avaliação qualitativa, não foi quantificado o erro agregado, avaliação quantitativa. Assim, não foi possível verificar o erro agregado antes da classificação pela metodologia Refer_1.

Tabela 4: Índices derivados da matriz de confusão.

		MaxVer		ANN		
		PTS	Coll	PTS	Coll	
Metodologia	Refer_1	Global(%)	45,5	31,2	51,5	46,8
		<i>Kappa</i>	0,364	0,197	0,434	0,379
		Variância	0,001329	0,001204	0,001471	0,001268
	Refer_2	Global(%)	63,8	42,0	54,9	64,7
		<i>Kappa</i>	0,578	0,323	0,474	0,589
		Variância	0,001338	0,001288	0,001460	0,001360
	Refer_3	Global(%)	60,3	40,6	62,9	59,8
		<i>Kappa</i>	0,536	0,307	0,568	0,531
		Variância	0,001401	0,001313	0,001370	0,001425

4. Conclusões

Uma metodologia que leva em consideração os aspectos multitemporal e multiespectral das imagens MODIS (*Moderate Resolution Imaging Spectroradiometer*), foi utilizada para classificar com sucesso extensas áreas de culturas agrícolas numa região de Limeira.

A abordagem multitemporal e multiespectral produziu resultados significativamente mais precisos do que a abordagem multiespectral, para realizar a classificação de culturas agrícolas em imagens de sensoriamento remoto. Esta análise foi comparada com os resultados da classificação usando o algoritmo MaxVer, para as metodologias Digitalização de polígonos homogêneos e Operação de vizinhança.

A eficiência da metodologia de aquisição das imagens de referência é promissora, tanto para a Digitalização de polígonos homogêneos em tela quanto para a metodologia de Operação de vizinhança.

Considerando as dificuldades para obter um número significativo de amostras para treinamento e validação, devendo-se ao fato da resolução das imagens MODIS, sugere-se a repetição desses experimentos para uma amostragem compatível com o número de variáveis discriminantes (30 x número de coeficientes x número de classes informacionais).

O relevo, em alguns casos, torna-se uma variável importante para classificação de culturas. Assim, propõe-se a utilização de atributos do terreno derivados de um modelo digital de elevação (MDE) para auxiliar na melhora da precisão da classificação.

Sugere-se também, uso de uma classificação contextual antes da classificação multitemporal propriamente dita, onde se eliminaria as áreas com classes informacionais diferentes (ex. estradas, área urbana, etc...) daquelas 7 classes usadas na classificação temporal.

Referências

- Apan, A.; Potgieter, A. **Using satellite imagery in determining winter crop area planted in support of regional commodity forecasting: a case study of the Darling Downs, Queensland**. Toowoomba, Australia: Faculty of Engineering and Surveying, University of Southern Queensland, 2002. 31 p. Disponível em: <http://www.usq.edu.au/users/apana/cropforecasting_finalreport.pdf>. Acesso: 20 jan. 2006.
- Congalton, R. G.; and Green, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. New York: Lewis Publishers, 1999.
- Formaggio, A. R.; Martins, S. P.; Gurtler, S.; Campos, R. C.; Fiorio, P. R.; Lemos, C. Avaliação de dados MODIS 250m para áreas de agricultura intensa. In: Simpósio Brasileiro de Sensoriamento Remoto, (SBSR), 12., 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 135-142. CD-ROM, On-line. ISBN 85-17-00018-8. Disponível em: <<http://mar.te.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.25.18.14/doc/135.pdf>>. Acesso em: 20 nov. 2005.
- Kavzoglu, T.; Mather, P.M. The use of backpropagation artificial neural networks in land cover classification. **International Journal of Remote Sensing**, v.24, n.13, p. 4907-4938, 2003.
- Lillesand, T. M.; Kiefer, R. W. **Remote sensing and image interpretation**. 4 Ed. New York: John Wiley & Sons, 724 p, 1999.
- Mather, P. M. **Computer processing of remotely-sensed images: An introduction**. 2 Ed. Chichester: John Wiley & Sons, 292 p, 1999.
- Sanches, I. D. A.; Epiphânio, J. C.; Formaggio A. R. Culturas Agrícolas em Imagens Multitemporais do Satélite Landsat. **Agricultura em São Paulo**. v.52, n.1, p.83-96. 2005.
- Schowengerdt, R. A. **Models and methods for image processing**. San Diego: Academic Press, 2 Ed. 522 pp, 1997.
- Tso, B.; Mather, P. M. Crop discrimination using multi-temporal SAR imagery. **International Journal of Remote Sensing**, vol. 20, no. 12, 2443-2460, 1999.
- Vieira, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. 327p. Thesis (Doctor of Philosophy) – University of Nottingham, Nottingham. 2000.
- Zell, A.; Mamier, G.; Vogt, M.; Mache, N.; Hubner, R.; Doring, S.; Herrmann, K.; Soye, T.; Schmalzl, M.; Sommer, T.; Hatzigeorgiou, A.; Posselt, D.; Schreiner, T.; Kett, B.; Clemente, G.; Wieland, J.; Gatter, J. **Stuttgart Neural Network Simulator v4.2**. University of Stuttgart: Institute for Parallel and Distributed High Performance Systems/University of Tübingen - Wilhelm-Schickard-Institute for Computer Science - Department of Computer Architecture. 1996.
- Zhan, X.; Sohlberg, R. A.; Townshend, J. R. G.; DiMiceli, C.; Carroll M. L.; Eastman, J. C.; Hansen, M. C.; DeFries, R. S. Detection of land cover changes using MODIS 250 m data. **Remote Sensing of Environment**, v. 83, p. 336-350, 2002.