

Sensoriamento Remoto na Identificação de Alvos Agrícolas em
Imagens LANDSAT: Uma Aplicação em Guaira, SP.¹

José Iguelmar Miranda²

¹Trabalho realizado no Anthropological Center for Training
and Research on Global Environmental Change - ACT, Indiana
University, IN, USA, Outubro de 1993.

²Pesquisador, EMBRAPA/CNPMA.



RESUMO

Uma classificação supervisionada, usando a técnica estatística de análise discriminante por máxima verossimilhança (maxver), foi usada numa área do Município de Guaira, SP, para identificar em sete classes diferentes alvos agrícolas: cultura anual, cana de açúcar, solo nú, solo semi-coberto, pasto, floresta e água, usando imagens digitais do satélite Landsat 5 sensor TM nas bandas 3, 4 e 5 (vermelho, infravermelho próximo e médio, respetivamente). A matriz final de classificação do maxver apresentou performance global de 85%, que é o exato valor mínimo aceito na literatura. A imagem temática do resultado mostra uma ótima correlação com a realidade, confirmando a eficiência da técnica de máxima verossimilhança para classificar imagens digitais multiespectrais de satélite.

1. INTRODUÇÃO

O presente trabalho foi realizado em Guaira-SP (Figura 1). O Município é alvo de estudo atual do Centro Nacional de Pesquisa de Monitoramento e Avaliação de Impacto Ambiental (CNPMA/EMBRAPA), com o propósito de avaliar problemas de impacto ambiental em áreas largamente irrigadas. Guaira conta hoje com cento e noventa e um sistemas de irrigação, sendo cento e sessenta e seis do tipo pivô central, quinze autopropelido e dez convencional, cobrindo uma área de dez mil e duzentos e quarenta hectares, distribuídos entre cento e vinte e nove propriedades, das seiscentos e dez existentes no município. Isto representa, em termos de propriedades, 21%. O objetivo a ser alcançado foi classificar, através do uso de classificadores automáticos, usando técnica supervisionada, o uso do solo no Município de Guaira em sete categorias: (1) Cultura Anual; (2) Cana de Açúcar; (3) Solo Nú; (4)

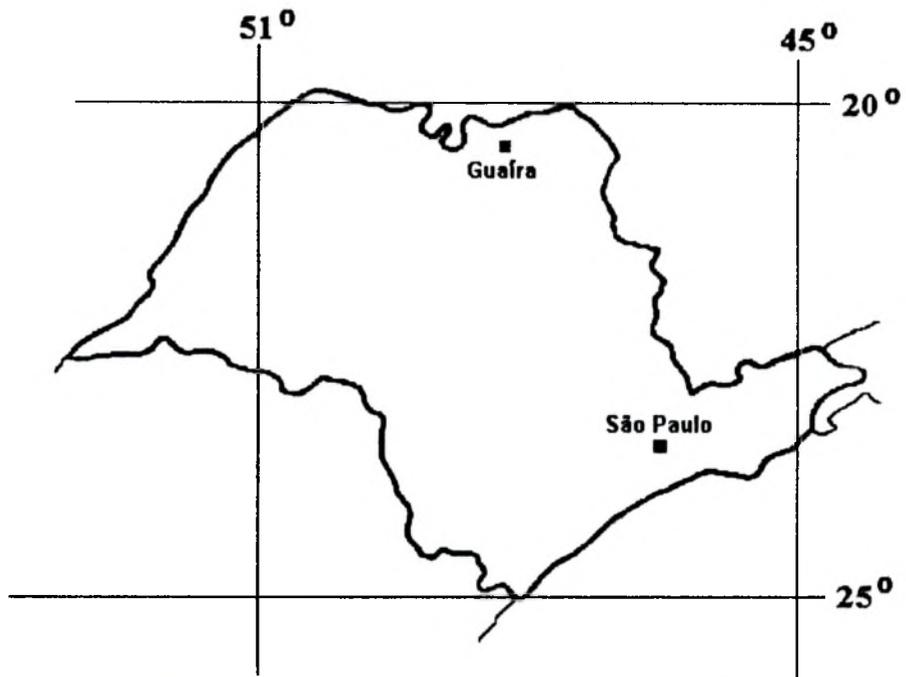


Figura 1 - Localização do Município de Guaíra - SP

Solo Semi-coberto; (5) Água; (6) Floresta; (7) Pasto.

2. MATERIAIS E MÉTODOS

2.1. Materiais

Microcomputador Macintosh IIci, software MultiSpec para processamento de imagens de domínio público, desenvolvido na School of Electrical Engineering, Purdue University, West Lafayette, Indiana (LANDGREBE & BIEHL, 1993), imagem digital Landsat-5 sensor TM, passagem de 19 de Julho de 1992, com três bandas: uma no espectro visível, correspondente ao vermelho (banda 3), duas no infravermelho, sendo uma no próximo (banda 4) e outra no médio (banda 5). Imagem do Satélite Landsat-5, sensor TM, em papel fotográfico, na escala 1:100.000, composição 3(B), 4(G) e 5(R) de 19 de Julho de 1992, de propriedade da Prefeitura de Guaira-SP. Mapa temático do uso atual, escala 1:100.000, com informações de interpretação visual baseada na imagem produto em papel fotográfico, realizada pelo Centro Nacional de Pesquisa do Trópico Semi-Árido (CPATSA/EMBRAPA). Carta Pedológica Semidetalhada do Estado de São Paulo, Município de Guaira, (São Paulo, 1991), Cartas do Brasil do Departamento de Cartografia do IBGE: Guaira-SP (IBGE, 1972a), Jaborandi-SP (IBGE, 1972b), Alberto Moreira-SP (IBGE, 1972c), Ipuã-SP (IBGE, 1972d), Miguelópolis-MG/SP (IBGE, 1972e), Planura-SP/MG (IBGE, 1972f) e Foz do Sapucaí (IBGE, 1972g).

2.2. MÉTODOS

Um processo de classificação padrão pode-se dizer que não existe, existindo tantos quantos analistas existem. Neste trabalho, adotou-se para o processo de classificação os três passos básicos sugeridos por Lillesand & Kiefer (1987): (1) estágio de treinamento, (2) estágio de classificação e (3) estágio de saída.

Precedendo à etapa de classificação, adota-se um procedimento de melhorar a visualização da imagem no monitor do computador. No processo de refinamento do estágio de treinamento alguns tipos de análises são realizadas. O método de expressão quantitativa de separação de categorias foi usado. No estágio de classificação, cada pixel na imagem é atribuído a uma classe de cobertura de solo que mais precisamente é assemelhado. A técnica usada foi a da máxima verossimilhança (maxver).

2.2.1. Realce e Combinação de Bandas.

Os primeiros procedimentos adotados quando se trabalha com imagens na forma digital é quanto à sua apresentação na tela do computador. Os dados das bandas 1 a 3, na forma bruta, geralmente não seriam visíveis, pois são bandas de alta absorção no espectro visível. As do infravermelho próximo e médio se tornam um pouco mais visíveis. Para uma melhor visualização, a primeira técnica de processamento de imagens adotada é o realce (enhancement). O algoritmo de realce usado para o trabalho foi o Equal Area Stretch. A combinação de bandas adotada foi: 3(B), 4(G), 5(R).

Neste tipo de combinação, a vegetação tende a aparecer verde, pois é onde o infravermelho próximo (banda 4) está mapeado, e sua tendência é de refletir em locais de ocorrência de fotossíntese.

2.2.2. Seleção de Área de Treinamento (Training Samples).

Concluído o processo de visualização pelo uso do realce, fica mais fácil a identificação das áreas de treinamento. O objetivo geral do processo de treinamento é montar um conjunto de estatísticas que descrevam o padrão de resposta espectral para cada tipo de cobertura de solo a ser classificado em uma imagem

(Lillesand & Kiefer, 1987). Foram selecionadas na imagem áreas representativas das classes de interesse de cobertura do solo. Estes locais, em termos teóricos, devem representar a norma de cada classe. Os dados de treinamento podem ser avaliados como bons se o ambiente do qual eles foram extraídos for relativamente homogêneo, e.g., se os solos têm a mesma associação, ou condição de humidade. Se há muita variação entre uma extremidade e outra nas condições do solo, é provável que os dados de treinamento adquiridos de um lado da área de estudo não sejam representativos da condição espectral encontrada no outro lado da área. No caso de Guaíra, segundo o mapa de solos do IAC usado, a área em estudo apresenta uma uniformidade de latossolo roxo. Quando usando um classificador estatisticamente baseado como o *maxver*, o limite inferior teórico do número de pixels que devem ser contidos num conjunto de treinamento é $n + 1$, onde n é o número de bandas espectrais (Lillesand & Kiefer, 1987). Esta condição permitirá a inversa da matriz de covariância para cada classe a ser calculada. Na prática, um mínimo de $10n$ a $100n$ pixels é usado desde que a estimativa das matrizes de covariância e vetor médio melhoram à medida que o número de pixels no conjunto de treinamento aumenta (Lillesand & Kiefer, 1987). A Figura 2 mostra os gráficos com as assinaturas espectrais para as classes. Pode-se observar que tais informações não são suficientes para selecionar bandas ótimas para a classificação supervisionada. Por esta razão, freqüentemente usa-se o método de seleção de atributos (bandas), através de técnicas de medidas de separabilidade estatística.

2.2.3. Medidas de Separabilidade

Obtidas as estatísticas (valores máximo e mínimo, variância, matriz de variância-covariância e matriz de correlação), adota-se um procedimento para determinar

Figura 2: Assinaturas Espectrais

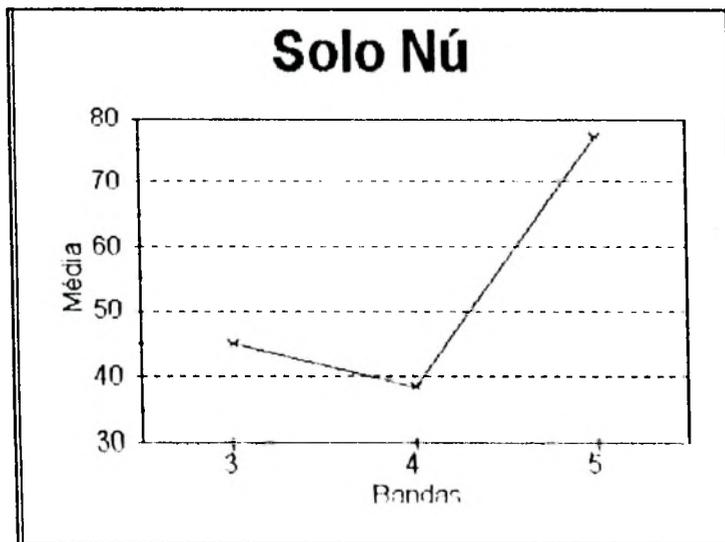
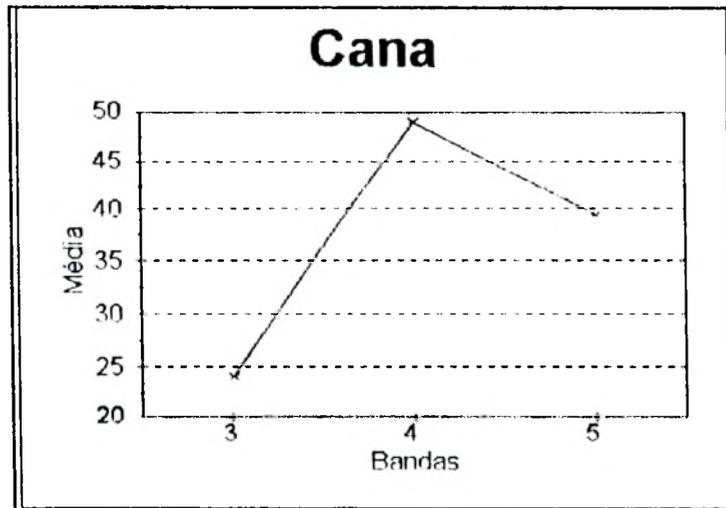
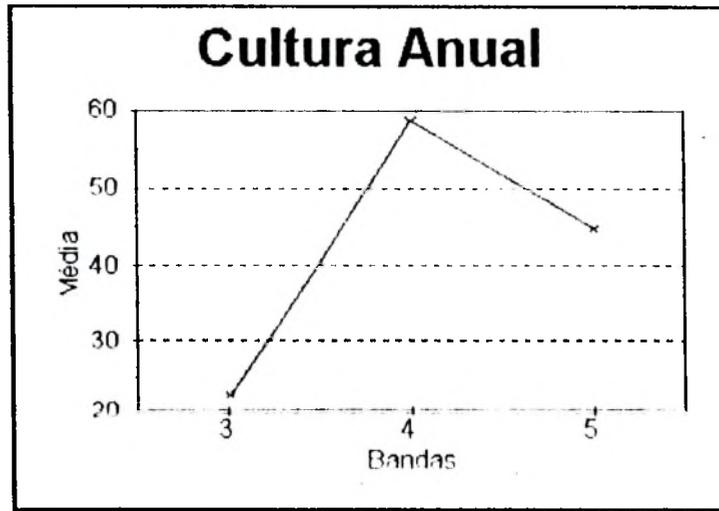
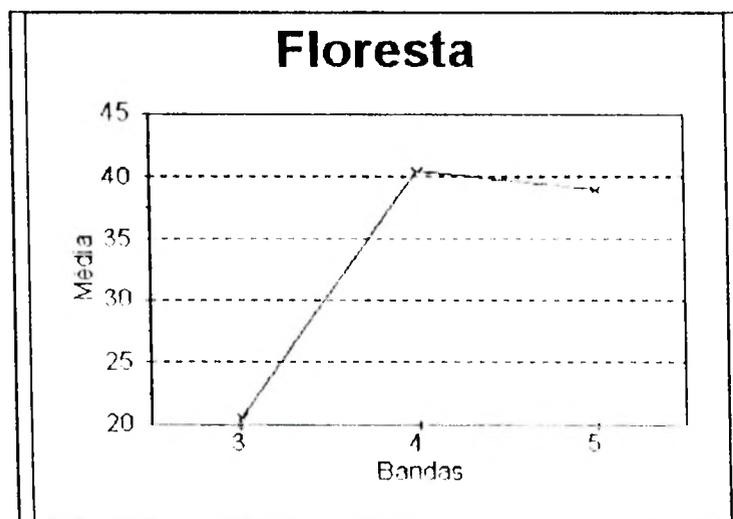
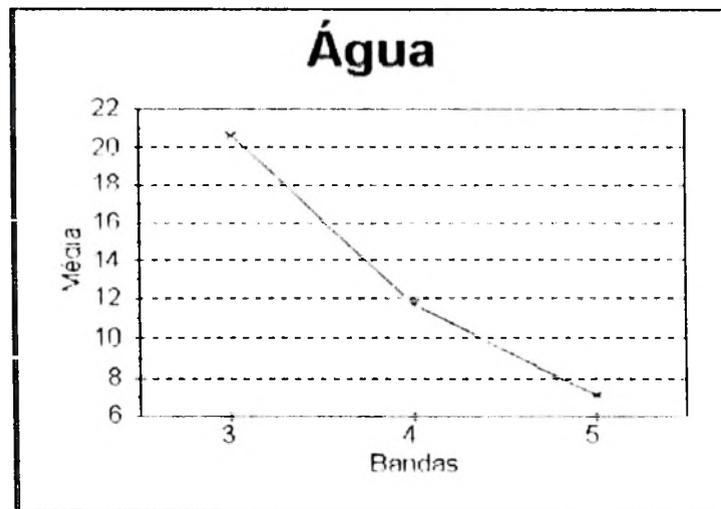
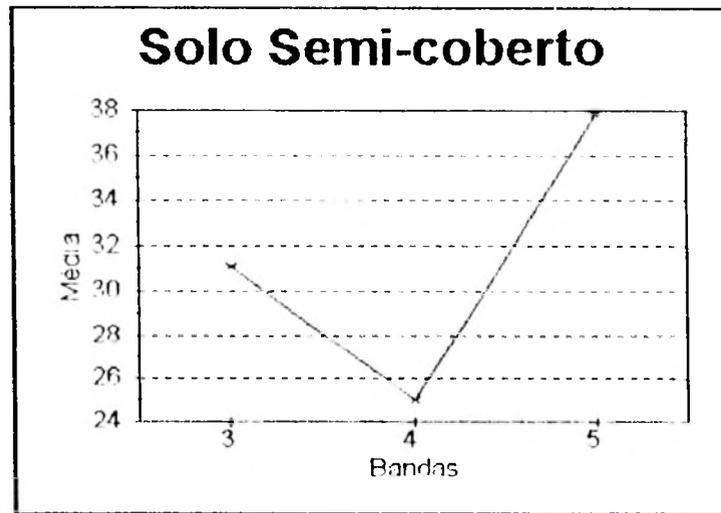


Figura 2: Assinaturas Espectrais



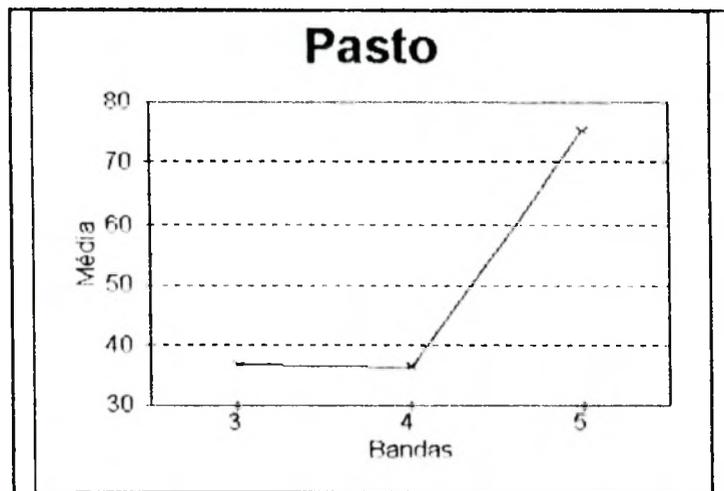


Figura 2: Assinaturas Espectrais

as bandas que são mais efetivas em discriminar cada classe de todas as outras. Este processo é comumente chamado seleção de atributos (Landgrebe & Biehl, 1993). O objetivo é eliminar da análise aquelas bandas que provêm apenas informação espectral redundante. Desta maneira, a dimensionalidade (número de bandas processadas) pode ser reduzida. Medidas estatísticas como divergência e análise discriminante podem ser usadas. O MultiSpec provê tais algoritmos.

Adotou-se a Divergência. Tendo sido uma das primeiras medidas estatísticas de separabilidade usada no sensoriamento remoto e ainda é largamente utilizada (JENSEN, 1986). Lida com o problema básico de decidir qual é o melhor sub-conjunto de q-bandas em n bandas para uso no processo de classificação supervisionada. O número de combinações, C, de n bandas tomadas q por vez é

$$C\left(\frac{n}{q}\right) = \frac{n!}{q!(n-q)!}$$

A divergência é calculada usando a média e matriz de covariância das estatísticas das classes coletadas nesta fase de treinamento. Para duas classes, o grau de divergência ou a "separabilidade estatística entre elas seria calculada pela seguinte fórmula

$$\text{Diver}_{cd} = 0.5\text{Tr}[(V_c - V_d)(V_d^{-1} - V_c^{-1})] + 0.5\text{Tr}[(V_c^{-1} - V_d^{-1})(M_c - M_d)(M_c - M_d)^T]$$

onde

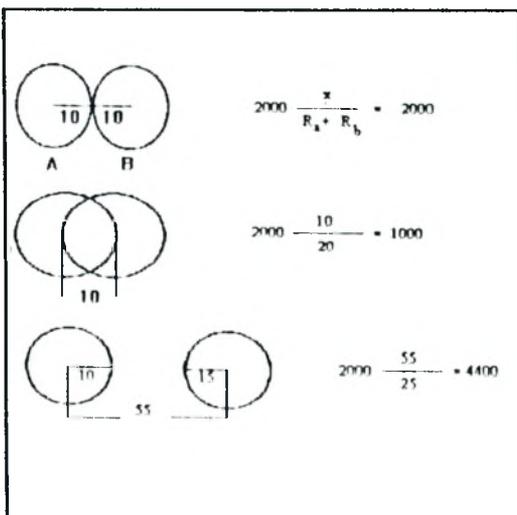
Tr[.] é o traço da matriz (soma dos elementos da diagonal), V_c e V_d são matrizes de covariância para as duas classes c e d, e M_c e M_d são os vetores média para estas classes. Isto é o cálculo para duas classes. Neste caso, trabalhando com sete classes, o cálculo é computado na divergência média, $\text{Diverg}_{\text{med}}$. Computacionalmente, isto é calculado pela fórmula

$$Diverg_{med} = \frac{\sum_{c=1}^{m-1} \sum_{d=c+1}^m Diverg_{cd}}{C}$$

desta maneira, o sub-conjunto de bandas, q, com a maior média de divergência pode ser selecionada no conjunto mais apropriado para classificar as m classes.

A equação abaixo para cálculo de divergência é usado no MultiSpec, que fornece um peso decrescente de ordem exponencial para incrementar distâncias entre classes. Também escala os valores de divergência entre 0 e 2000. Um valor de divergência de 2000 sugere uma excelente separação entre classes. Acima de 1900 a separação é boa, enquanto abaixo de 1700 é pobre. Este valor é só um indicativo de separação. É bom observar que valores muito acima de 2000, como 4000, pode estar relacionando classes "extremamente" separadas da mesma maneira que relaciona classes "relativamente" separadas, como o valor 2200, por exemplo.

$$Diverg_{cd}^T = 2000 \left(1 - \exp \frac{-Diverg_{cd}}{8} \right)$$



A figura do lado serve para mostrar como se comporta, em termos práticos, o cálculo de divergência. Os valores apresentados são medidas estatísticas, sendo centrado na média e o raio seria o desvio padrão. No primeiro caso, as classes seriam totalmente

escolhidas para cada uma teria sido muito boa. No segundo caso, há uma sobreposição nos valores das classes. O terceiro caso, serve para mostrar o caso de classes totalmente separadas, mas seriam classificadas como separadas, sem nenhum senso de medida desta separação.

3. RESULTADOS E DISCUSSÃO

O MultiSpec, dentro do conjunto de opções "Feature Extraction", apresenta quatro opções de medida de distância: (1) Bhattacharyya, (2) Transformed divergence, (3) Untransformed divergence, (4) 'NonCovariance' Bhattacharyya. A opção de trabalho foi a segunda. Nesta primeira fase, os valores apresentados após a execução da opção "transformed divergence" foram:

(Os valores abaixo representam a combinação das bandas 3, 4 e 5 para cada par de classes, num total de 21 combinações.)

Mínimo	Média	12	13	14	15	16	17
1348	1950	1348	2000	2000	2000	1973	2000

23	24	25	26	27	34	35	36
2000	2000	2000	1865	2000	1994	2000	2000

37	45	46	47	56	57	67
1763	2000	2000	2000	2000	2000	2000

Numa análise rápida, o cálculo de divergência mostra que as classes 1 e 2, cultura anual e cana, por exemplo, não são passíveis de separação total com esta

combinação de bandas. O segundo par de classes com algum grau de "pobreza" de separação de classes é 2 e 6, para cana e floresta, porém, acima do valor mínimo, 1700. Isto significa que numa classificação supervisionada, usando as três bandas, o algoritmo de classificação confundiria as duas primeiras classes num grau bem maior do que no segundo caso. Todas as outras classes seriam bem classificadas.

Mesmo considerando estes valores, foi executado no MultiSpec uma classificação supervisionada usando o algoritmo de máxima verossimilhança ("maxver") (BARRET et al., 1992). O programa permite que se gere somente um quadro estatístico do comportamento da classificação. Com isto, economiza-se tempo e pode-se melhor avaliar a precisão das áreas de treinamento. Neste relatório, o programa imprime uma descrição de cada campo de treinamento usado, sua classe, as coordenadas, uma matriz de valores atribuídos à classe, com a devida porcentagem de acerto.

A performance geral para estas primeiras amostras estão no Quadro 1. Considerar: classe 1 = cultura anual, 2 = cana, 3 = solo nú, 4 = solo semi-coberto, 5 = água, 6 = floresta e 7 = pasto.

Quadro 1: Performance das Classes

% Acerto		Amos tras	1	2	3	4	5	6	7
1	92	565	523	41	0	0	0	1	0
2	81	946	171	768	0	0	0	7	0
3	96	1283	0	0	1235	0	0	0	48
4	99	1137	0	2	1	1134	0	0	0
5	100	253	0	0	0	0	253	0	0
6	99	485	4	1	0	0	0	480	0
7	97	1417	0	0	42	0	0	0	1375
Total		6086	698	812	1278	1134	253	488	1423

O acerto geral de classificação foi de $(5768/6086) = 94.8\%$. O valor final está muito bom. Na literatura (Brondizio, 1993), considera-se que o nível de precisão de 85% para pequenas áreas seja suficiente. No entanto, ao pedir a classificação de uma pequena área, como mostrado na figura 3, pode-se perceber o que o programa de divergência havia previsto, alguma confusão nas classificações entre as classes 1, 2 e 6. O Quadro 1 diz que 41 pixels da classe cultura anual (1) foi confundido com a classe cana (2) e 1 com a classe floresta (6). Porém, o maior número de atribuições erradas se encontra na classe cana (2) com a classe cultura (2), 171 e 7 com floresta (6). A classe solo nú (3) teve 48 pixels confundidos com pasto (7). Outro caso foi da classe pasto (7) com 42 pixels confundidos com solo nú (3), um número menor que o recíproco.

6. Conclusão.

Algumas outras técnicas de processamento de imagens, bem como tratamentos estatísticos não foram



Figura 3: Classificação MAXVER da Área de Estudo

realizados, por se tratarem de técnicas complementares a serem usadas. Por exemplo, o uso de componentes principais para a redução da dimensionalidade de bandas com que se vai trabalhar é muito interessante (Campbell, 1987). Entretanto, esta técnica seria melhor aplicada se se trabalhasse com cinco ou sete bandas. Outra técnica, o cálculo do índice de vegetação (Barret et al., 1992) e respectiva geração de banda, também pode auxiliar na solução de algumas áreas problemas. Seu principal objetivo é separar áreas da imagem com maior ocorrência de biomassa. No processo de classificação, estas informações podem ser usadas, em conjunto com as já geradas, e verificar se alguma destas técnicas especiais de tratamento de imagem pode melhorar a classificação da imagem.

SUMMARY

A supervised classification, with the statististician technique of discriminant analysis by Maximum Likelihood (maxver), was applied in Guaira, SP, with the subject to identify in seven classes different agricultural spots: annual cropping, sugar cane, bare soil, semi-bare soil, pasture, forest and water, with the aid of Landsat 5, TM sensor, imagery in digital format using bands 3, 4 and 5 (red, near infrared and medium infrared, respectively). The maxver final classification matrix reached a global performance of 85%, matching the minimum value accepted in the literature. Resulting thematic image set good identification classes, emphasizing a good performance of maxlikelihood technique to classify multispectral satellite imagery.

REFERÊNCIAS BIBLIOGRÁFICA

JENSEN, JOHN R. 1986. Introductory Digital Imagem Processing - A Remote Sensing Perspective. Englewood Cliffs, New Jersey: Prentice-Hall.

CAMPBELL, JAMES B. 1987. Introduction to REMOTE SENSING. New York: The Guilford Press.

BARRET, ERIC C., and CURTIS, LEONARD F. 1992. Introduction to Environmental Remote Sensing. Third Edition. London: Chapman & Hall.

LANDGREBE, D. and BIEHL, LARRY. An Introduction to MultiSpec. School of Electrical Engineering. West Lafayette, In, USA. 1993.

LILLESAND, T. M. & KIEFER, R. W. Remote Sensing and Image Interpretation, New York, John Wiley & Sons, c. 1987, 721p.

BRONDIZIO, E. Lista de exercícios. Indiana University, Bloomington, In, USA. Outubro, 1993.

SÃO PAULO. Secretaria de Agricultura e Abastecimento. SF-22-X-B-III:plano cartográfico do Estado de São Paulo-carta pedológica semi-detalhada do Estado de São Paulo-Guaíra. [S.L.]:IAC,1991. (Esc. 1:100.000).

IBGE. Departamento de Cartografia. SF-22-X-B-III-3: Guaíra-SP [S.L.]:IBGE/DAEE,1972a (Esc.1:50.000).

IBGE. Departamento de Cartografia. SF-22-X-B-VI-1: Jaborandí-SP [S.L.]:IBGE/DAEE,1972b (Esc.1:50.000).

IBGE. Departamento de Cartografia. SF-22-X-B-II-4: Alberto Moreira-SP [S.L.]:IBGE/DAEE,1972c (Esc.1:50.000).

IBGE. Departamento de Cartografia. SF-22-X-B-III-4: Ipuã-SP [S.L.]:IBGE/DAEE,1972d (Esc.1:50.000).

IBGE. Departamento de Cartografia. SF-22-X-B-III-2:
Miguelópolis-MG/SP [S.L.]:IBGE/DAEE,1972e
(Esc.1:50.000).

IBGE. Departamento de Cartografia. SF-22-X-B-III-3:
Planura-SP/MG [S.L.]:IBGE/DAEE,1972f
(Esc.1:50.000).

IBGE. Departamento de Cartografia. SF-22-X-B-III-1:
Foz do Sapucaí. [S.L.]:IBGE/DAEE,1972g.
(Esc.1:50.000).