

**IDENTIFICAÇÃO DE ALVOS AGRÍCOLAS
EM IMAGENS DIGITAIS LANDSAT:
UMA APLICAÇÃO EM GUAÍRA, SP**

José Iguelmar Miranda

REPÚBLICA FEDERATIVA DO BRASIL

Presidente: Fernando Henrique Cardoso

Ministro da Agricultura, do Abastecimento e da Reforma Agrária:
José Eduardo Andrade Vieira

Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA

Presidente: Alberto Duque Portugal

Diretores: Dante Daniel Giacomelli Scolari

José Roberto Rodrigues Peres

Elza Angela Battaglia Brito da Cunha

Centro Nacional de Pesquisa de Monitoramento e Avaliação de Impacto Ambiental - CNPMA

Chefe Geral: Clayton Campanhola

Chefe Adjunto de Pesquisa e Desenvolvimento: Ariovaldo Luchiari Júnior

Chefe Adjunto Administrativo: Rosangela Blotta Abakerli

ISSN 1413-0084



Ministério da Agricultura, do Abastecimento e da Reforma Agrária - MAARA
Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA
Centro Nacional de Pesquisa de Monitoramento e Avaliação de Impacto Ambiental - CNPMA

**IDENTIFICAÇÃO DE ALVOS AGRÍCOLAS EM
IMAGENS DIGITAIS LANDSAT: UMA
APLICAÇÃO EM GUAÍRA, SP**

José Iguelmar Miranda

Jaguariúna, SP
1996

EMBRAPA-CNPMA. Documentos, 4.

Exemplares desta publicação podem ser solicitados à:

EMBRAPA. Centro Nacional de Pesquisa de Monitoramento e Avaliação de Impacto Ambiental - CNPMA

Rodovia SP-340, km 127,5 - Bairro Tanquinho Velho

Caixa Postal 69

13820-000 - Jaguariúna, SP

Fone: (019) 867-5633

Fax: (019) 867-5225

e.mail:postmaster@npma.embrapa.br

Comitê de Publicações: Ariovaldo Luchiari Júnior - Presidente

Cláudio Martin Jonsson - Secretário Executivo

Cláudia Conti Medugno

Celso João Alves Ferreira

Paulo Koji Kitamura

Ivanilde Dispatto

Editoração: Ivanilde Dispatto

Normalização: Maria Amélia de Toledo Leme

Tiragem: 500 exemplares

Diagramação e Impressão: Hortograf, Campinas, SP

MIRANDA, J.I. **Identificação de alvos agrícolas em imagens digitais LANDSAT:**
uma aplicação em Guará, SP. Jaguariúna: EMBRAPA-CNPMA, 1996. 40 pags.
(EMBRAPA-CNPMA. Documentos, 4). ISSN 1413-0084

APRESENTAÇÃO

Em estudos de impactos ambientais, o conhecimento da estrutura e funcionamento dos agroecossistemas, constitui-se em um procedimento fundamental. A estrutura do agroecossistema é definida pelos seus componentes: águas de superfície e/ou subterrâneas, clima, solo, flora, fauna e homem, e seu funcionamento refere-se a forma que os componentes estão relacionados.

Assim, é importante que se conheça a disponibilidade e distribuição dos recursos naturais abióticos, especialmente solos e águas, bem como a dinâmica dos padrões de substituição da vegetação nativa por comunidades de plantas exóticas que compõem os sistemas de produção predominantes em uma determinada área, para que se tenha elementos no estudo das alterações dos ciclos hidrológicos e de energia, causados por sistemas agrícolas.

O sensoriamento remoto utilizado para tais fins constitui uma técnica básica, embora exija certos ajustes, para uma aplicação plena.

O presente trabalho mostra o emprego dessa técnica em estudos agroambientais em área de agricultura irrigada, caracterizada pelo uso intensivo de insumos e forte pressão sobre recursos naturais.

Ariovaldo Luchiari Júnior
Chefe Adjunto de Pesquisa e Desenvolvimento
EMBRAPA-CNPMA

SUMÁRIO

	Página
Resumo.....	07
Abstract.....	07
1. Introdução.....	08
2. Objetivo.....	08
3. Equipamentos e material.....	10
4. Informações da região.....	11
4.1. Geologia e fisiografia.....	11
4.2. Descrição dos solos.....	12
4.3. Clima.....	12
4.4. Economia.....	13
4.5. Distribuição de sistemas de irrigação em Guaíra, SP.....	14
5. Procedimentos.....	15
5.1. Realce e combinação de bandas.....	16
5.2. Seleção de área de treinamento (Training Samples).....	17
5.3. Medidas de separabilidade.....	19
5.4. Análise das medidas de separabilidade.....	21
5.5. Classificação supervisionada.....	23
5.6. Classificação final.....	28
6. Conclusão.....	32
7. Referências bibliográficas.....	33
APÊNDICE.....	35

1. Quadro de assinatura espectral para cultura anual
2. Quadro de assinatura espectral para cana-de-açúcar
3. Quadro de assinatura espectral para solo nu
4. Quadro de assinatura espectral para solo semicoberto
5. Quadro de assinatura espectral para água
6. Quadro de assinatura espectral para floresta
7. Quadro de assinatura espectral para pasto

IDENTIFICAÇÃO DE ALVOS AGRÍCOLAS EM IMAGENS LANDSAT: UMA APLICAÇÃO EM GUAÍRA, SP¹

José Iguelmar Miranda²

Resumo - Uma classificação supervisionada, usando análise discriminante por máxima verossimilhança (maxver), foi usada em uma área do município de Guaíra, SP, para identificar em sete classes diferentes alvos agrícolas: cultura anual, cana-de-açúcar, solo nu, solo semicoberto, pasto, floresta e água, usando imagens do satélite Landsat 5, sensor TM, em formato digital nas bandas 3, 4 e 5 (vermelho, infravermelho próximo e médio, respectivamente). A matriz final de classificação do maxver apresentou performance global de 85%, que é o exato valor mínimo aceitado na literatura. A imagem temática do resultado mostra um bom nível de identificação das classes, onde pode-se confirmar o bom desempenho da técnica de máxima verossimilhança para classificar imagens digitais multiespectral de satélite.

Termos de indexação - sensoriamento remoto, classificação supervisionada, Landsat, município de Guaíra, máxima verossimilhança.

IDENTIFICATION OF AGRICULTURAL SPOTS USING LANDSAT IMAGERY: AN APPLICATION IN GUAÍRA, SP

Abstract - A supervised classification, using discriminant analysis by maxlikelihood (maxver), was applied in Guaíra, 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 matrix final of the maxver classification 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.

Index terms: remote sensing, supervised classification, Landsat, maxlikelihood, Guaíra county.

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

² Matemático, M.Sc. em Ciência da Computação, EMBRAPA-CNPMA, Caixa Postal 69 - 13820-000 Jaguariúna, SP.

1. Introdução

O Anthropological Center for Training (ACT) conta com excelente infra-estrutura, tanto de recursos humanos como material. Sua base física conta com seis Macintosh Iici, quatro 80486 de 50 MHz, todos com ViperCard, uma estação de trabalho HP A7097C, ligada ao Laboratório de Sistemas de Informação Geográfica (GIS Lab) da Faculdade de Políticas Pública e do Meio Ambiente - School of Public and Environmental Affairs (SPEA), uma impressora laser HP LaserJet 4, uma impressora, em cores, jato de tinta HP DeskJet 1200C/PS e uma impressora jato de tinta Tektronic ColorQuick. A base de software conta no ambiente DOS com Windows, QuattroPro, WordPerfect, Idrisi 4.1, Harvard Graphics, Autographix. No ambiente Macintosh com MultiSpec, WordPerfect, Excell e todas as demais facilidades Macintosh. Em Unix, usa-se principalmente o Erdas, software para processamento de imagens.

O treinamento teve suporte de Denis Mudderman, Ph.D. em Sistema de Informação Geográfica (SIG) e Sensoriamento Remoto (SR), e Eduardo Brondízio, estudante de Ph.D. na Universidade de Indiana - SPEA.

A área escolhida para trabalho foi o município de Guaíra, SP (Fig.1). Um dos principais fatores de sua utilização como área teste foi pela disponibilidade de imagens tanto em produto papel fotográfico como em formato digital. Além disto, é uma área de estudo atual do CNPMA, que avalia problemas de impacto ambiental em áreas largamente irrigadas. Guaíra conta com 191 sistemas de irrigação, sendo 176 do tipo pivô central, quinze autopropelido e dez convencional, cobrindo uma área de 10.240 ha, distribuídos entre 129, das 610 existentes no município. Isto representa 21% das propriedades.

2. Objetivo

Classificar imagens de satélite de recursos naturais LANDSAT, em formato digital, através do uso de classificadores automáticos disponíveis no software MultiSpec (LANDGREBE & BIEHL, 1993) em

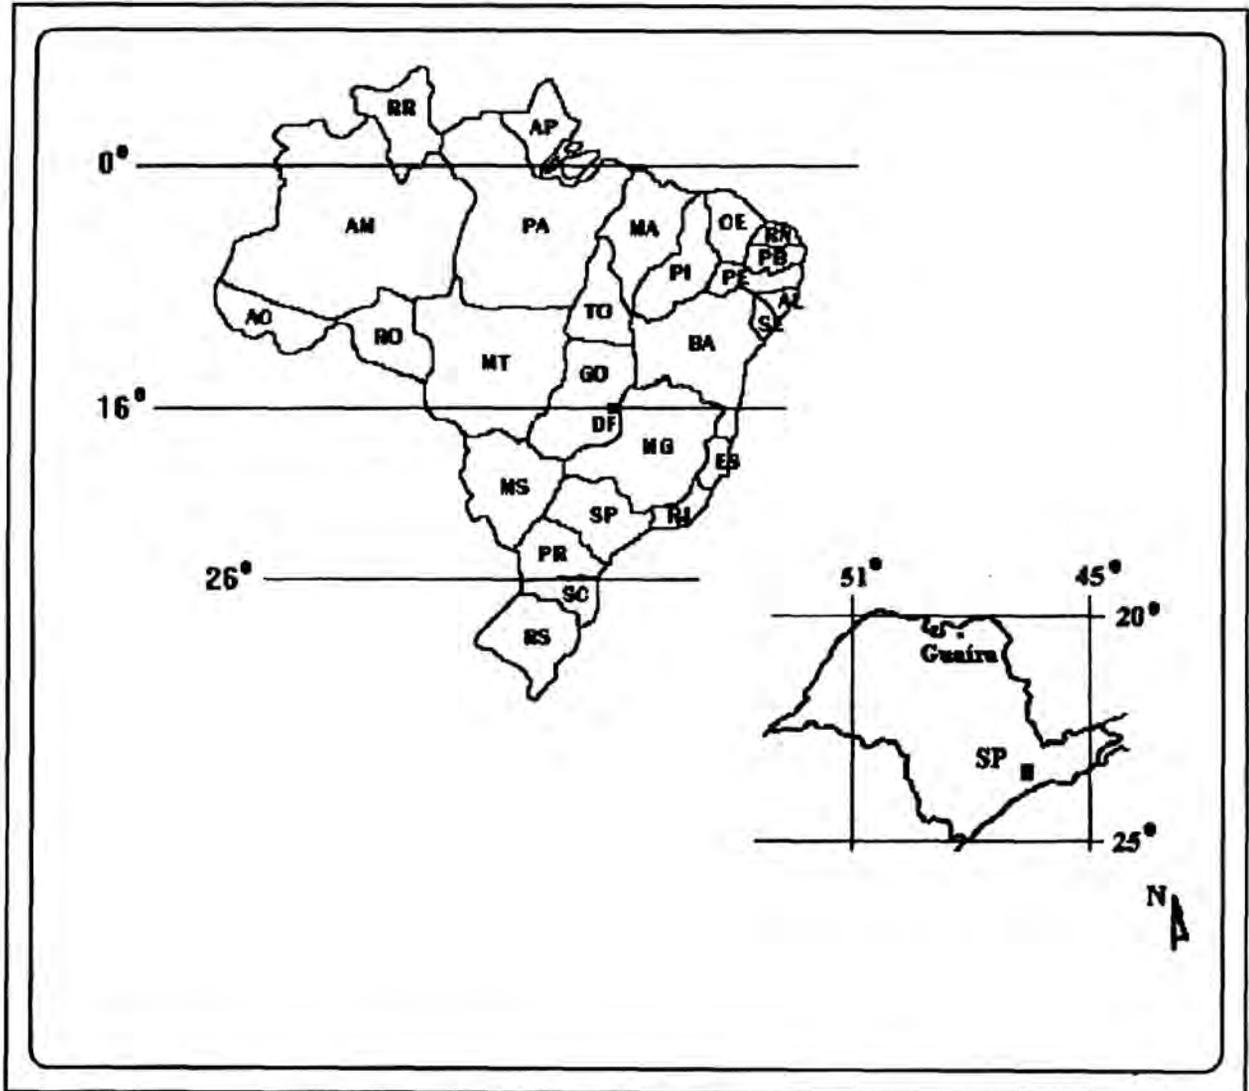


FIG. 1. Localização do município de Guaíra, SP.

microcomputador Macintosh IICI, usando técnicas supervisionada e não supervisionada, a cobertura do solo no município de Guaíra, SP em sete categorias, representativas dos seguintes alvos agrícolas: a) cultura anual; b) cana-de-açúcar; c) solo nu; d) solo semicoberto; e) água; f) floresta; e g) pasto.

Os resultados estão apresentados na forma de mapas temáticos com as áreas classificadas.

3. Equipamentos e material

Microcomputador Macintosh IICI com software de processamento de imagens MultiSpec. Impressora laser HP LaserJet 4. Impressora, em cores, jato de tinta Tektronic ColorQuick.

Imagens do satélite Landsat 5, sensor Mapeador Temático - Thematic Mapper (TM) na forma digital, 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) no formato IDRISI (ASCII/DOS) em disquetes de 3 1/2", 1.44 Megabytes de capacidade, pertencentes à Prefeitura de Guaíra, SP.

Imagem correspondente da área do município em produto papel fotográfico, com três bandas 3(B), 4(G) e 5(R), escala 1:100.000, com mesma data de passagem: 19.07.92, da Prefeitura Municipal de Guaíra, SP.

Mapa temático, escala 1:100.000, com informações sobre interpretação visual baseada na imagem produto papel fotográfico, realizada pelo Centro de Pesquisa Agropecuária do Trópico Semi-Árido (CPATSA), da EMBRAPA.

Carta Pedológica Semidetalhada do Estado de São Paulo, município de Guaíra, (São Paulo, 1991), Carta do Brasil do Departamento de Cartografia do IBGE, Guaíra, 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). 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.

4. Informações da região

4.1. Geologia e fisiografia

Na área ocorrem Rochas Sedimentares e Magmáticas do Período Mesozóico. Estão representadas pelas formações Botucatu (arenitos) e Serra Geral (basaltos). A formação Botucatu é constituída de arenito eólico depositado em ambiente desértico, durante o Jurássico Superior. Caracterizam-se por uma granulação fina e média, por serem muito pouco argilosas, pela boa seleção de grãos (essencialmente quartzosas) e pela estratificação cruzada. Geralmente, as camadas situadas entre derrames magmáticos apresentam-se solidificadas e duras. Este arenito está confinado pelos derrames basálticos sobrejacentes, constituindo um ótimo reservatório de água (DAEE, 1976).

A formação Serra Geral compreende os extensos derrames de basalto que se processaram durante o Triássico-Jurássico na Bacia do Paraná e os arenitos eólicos inter-derrames. Os basaltos têm ocorrência extensiva no vale do Rio Pardo. De um modo geral afloram em faixas estreitas associadas aos vales mais profundos e desenvolvendo solos profundos e férteis, (Latosolo-Roxo), constitui a maior área contínua de “terra roxa” em todo o Estado. Os solos que se desenvolvem a partir destes dois materiais originários, são bastantes influenciados pela granulometria dos mesmos (DAEE, 1976).

A área faz parte da unidade geomórfica Arenito-Basáltico sustentada pelos derrames de basalto que se processaram durante o Triássico-Jurássico. Apresentam relevo levemente ondulado, uniforme e monótono, dando origem às unidades de solo de relevo favorável, vistas no mapa de solo. Estruturadamente a área se caracteriza como um grande monoclinal com as camadas inclinando-se levemente em direção à calha do Rio Paraná. A drenagem é realizada principalmente pelo Rio Pardo e córregos afluentes

que atravessam ou margeiam os limites da área de estudo (DAEE, 1976).

4.2. Descrição dos solos

São identificados três classes de solos: Latossolo-Roxo, Terra Roxa misturada e Solos hidromórficos. Os Latossolos ocorrem na maior parte da área. Latossolo-Roxo desenvolvido predominantemente de rochas eruptivas básicas sendo de textura argilosa (mais de 40% de argila). Terra Roxa origina-se das rochas eruptivas básicas e do arenito Botucatu, textura argilo-arenosa a argilosa (35 a 45% de argila). Apresentam relevo suave, com pequenos riscos à erosão, facilidade de serem trabalhados por máquinas agrícolas, razoável quantidade de água disponível, boa profundidade e drenagem interna e pouca resistência à penetração das raízes. Quimicamente deixam a desejar por causa da baixa fertilidade natural, mas este aspecto é superado pela boa capacidade de reação à aplicação de fertilizantes e corretivos. Os solos hidromórficos ocorrem nas margens do Rio Pardo e dos pequenos córregos. São de pequena dimensão e estão sujeitos a riscos de inundação. Estes solos apresentam um horizonte superficial rico em matéria orgânica e horizontes subsuperficiais de cor cinza- clara, evidenciando um processo de redução química provocada pela presença do lençol freático (DAEE, 1976).

A maior parte das unidades de solo possuem boas características físicas. São bem drenados, com boa porosidade, de textura média a argilosa e com estrutura no horizonte superficial (A) e maçica no horizonte subsuperficial (B). O teor de matéria orgânica é muito baixo nos solos da área (DAEE, 1976).

4.3. Clima

É caracterizado pela estação das águas de outubro a março, e pela estação das secas, de abril a setembro. A média anual de precipitação pluviométrica está por volta de 1.200 mm. A insolação é alta durante todo o ano, com média 7,5 horas dia. A duração do dia durante o ano varia de um máximo de 13,2 horas em dezembro para um mínimo de 10,9 horas em junho (DAEE, 1976).

4.4. Economia

A economia do município de Guaíra é voltada quase que exclusivamente, para o atendimento das necessidades do setor agrícola. Os serviços à montante e à jusante da agricultura desempenham e ocupam um lugar de destaque não só na geração de renda e emprego mas também contribuem decisivamente na receita municipal.

Os dados do Quadro a seguir comprovam esta assertiva ao mostrarem a área total explorada de 117.970 ha, sendo que o município todo conta com 125.801 ha, para um total de 610 propriedades. Destas, há uma distribuição relativamente equitativa em termos numéricos, porém ao se observar a área explorada pela agricultura nota-se que apenas 2% se constituem em minifúndios, 60% em empreendimentos rurais e 38% em latifúndios explorados.

Propriedades

Total nº Área (ha)	Minifúndio nº Área (ha)	Emp. Rural nº Área (ha)	Lat. Explorado nº Área (ha)
610 117.970	144 2.493	281 70.569	185 44.908

Fonte: DAEE, 1976.

O comportamento populacional no município seguiu a tendência ocorrida no Brasil como um todo, quando da fase do grande êxodo rural para o meio urbano ocorrido na década de 70, constatado no Quadro a seguir.

População Urbana e Rural

População	1960	1970
Urbana	7.487	16.866
Rural	14.074	10.017
Total	21.561	26.883

Fonte: DAEE, 1976.

4.5. Distribuição de sistemas de irrigação em Guaíra, SP

Após um longo trabalho realizado pelo Grupo Executivo de Irrigação para o Desenvolvimento Agrícola (GEIDA) do Ministério do Interior, iniciado em 1973, verificou-se que o vale do Rio Pardo era o que oferecia melhores condições de viabilidade para a implantação de um projeto de irrigação complementar. As primeiras propriedades começaram a ser irrigadas em 1976, com uma área de 2.000 ha (Economia, 1979). Em 1992, a disposição dos sistemas irrigantes é conforme quadro que segue.

Tipo	Aparelhos	Prop.	Área(ha)	%
Pivô Central	166	104	9.461,61	92,40
Autopropelido	15	15	646,14	6,31
Convencional	10	10	132,33	1,29
Total	191	129	10.240,08	100,00

Fonte: Casa da Agricultura de Guaíra, 1992.

Pode-se constatar uma predominância das culturas de feijão e milho nestes sistemas de irrigação, como está demonstrado no quadro a seguir.

Cultura	Área(ha)	Área(%)
Feijão	3.605,24	39,11
Milho	2.921,58	31,70
Milho verde	116,16	1,26
Tomate	645,57	7,00
Soja	798,46	8,66
Sorgo	496,57	5,39
Mucuna	190,57	2,07
Trigo	169,03	1,83
Cebola	49,61	0,54
Batata	25,41	0,28
Abobrinha	1,21	0,01
Quiabo	3,63	0,04
Crotalaria	75,62	0,82
Olericultura	2,42	0,03
Capim	116,16	1,26
Total	9.217,24	100

Fonte: Casa da Agricultura de Guaíra, 1992.

5. Procedimentos

O MultiSpec é um programa para processamento de imagens de domínio público, desenvolvido na School of Electrical Engineering, Purdue University, West Lafayette, Indiana (Landgrebe & Biehl, 1993). Purdue tem um passado bastante conhecido na área de Sensoriamento Remoto, quando desenvolveu o programa LARSYS, criado na década de 60. O Multispec inclui todos os conhecimentos quanto a ferramentas de processamento de imagens desenvolvidas até o momento. O seu ponto forte está na parte estatística, facilitando muito o trabalho de separação

de classes espectrais para uma classificação mais eficiente. A interação entre o usuário e o display de imagem é excelente, pois o MultiSpec permite que se tenha mais 200 bandas espectrais na tela. O sistema foi adaptado para o Macintosh, para análise de imagens multiespectrais do Landsat, sensores MSS ou TM, o francês SPOT ou dados que serão produzidos pela próxima geração de sensores de observação da Terra tais como MODIS, para a plataforma EOS, também como dados de aeronaves como AVIRIS.

Os passos metodológicos do trabalho foram: 1) realce e combinação de bandas; 2) seleção de áreas de treinamento - com o objetivo de definir treinadores para a aplicação da técnica de máxima verossimilhança; 3) seleção de bandas ótimas para classificação. Este procedimento, chamado de seleção de atributos, é realizado pelo uso de técnica de separabilidade estatística; 4) análise das medidas de separabilidade para identificar problemas de separação entre classes; 5) classificação supervisionada, usando análise discriminante pela máxima verossimilhança, em duas etapas. Na primeira etapa, gera-se um quadro estatístico que mostra a porcentagem de acerto de cada campo de treinamento escolhido. Uma segunda etapa é necessária para se excluir campos de treinamento que apresentem baixa porcentagem de aproveitamento e incluir novos; e 6) classificação final, com a escolha dos campos de teste. O algoritmo maxver é executado considerando os campos de treinamento da etapa anterior e os campos testes. A saída desta etapa é o produto final de todo o processo: um mapa temático com as classes apresentadas em diferentes cores.

5.1. Realce e combinação de bandas

Os primeiros procedimentos adotados quando se trabalha com imagens na forma digital é quanto à sua apresentação na tela. 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 apresentação, a primeira técnica de processamento de imagens adotada é o realce (enhancement). No MultiSpec existem duas principais: Linear Stretch (LS) e Equal Area Stretch (EAS). A primeira mostra a imagem mais

esmaecida, pelo fato de não cobrir totalmente todo o espectro de 256 níveis de cinza disponíveis, com menos gradientes de cores. A diferenciação entre nuances de cores torna-se imperceptível. De certa forma, só para uma visualização, não há muitos problemas, mas quando se pretende realizar a escolha de áreas para classificação, pode tornar-se um problema.

Já o EAS, por realizar uma equalização maior nos níveis de cinza do histograma, apresenta a imagem mais realçada, com um maior gradiente de tonalidades entre as cores, o que para o objetivo deste trabalho se mostrou melhor. Portanto, o algoritmo de realce usado para o trabalho foi o Equal Area Stretch. A combinação de bandas adotada foi:

Banda TM	Canal Gráfico
3	azul
4	verde
5	vermelho

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

5.2. Seleção de área de treinamento (Training Samples)

Foram selecionadas na imagem locais representativos dos sete alvos agrícolas de interesse de cobertura do solo. Estes locais, em termos teóricos, devem representar a norma estatística 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 umidade. 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 exposto no item 4.2, a área em estudo apresenta uma uniformidade de Latossolo-Roxo.

Uma vez avaliados os fatores de extensão das assinaturas foram escolhidas as áreas para cada classe e coletadas suas devidas estatísticas espectrais. A regra geral é que se dados de treinamento estão sendo extraídos de n bandas, um número mínimo de $n+1$ pixels devem ser extraídos para cada classe. Esta condição permitirá a inversa da matriz de covariância para cada classe a ser calculada. Idealmente, $>10n$ pixels de dados de treinamento são coletados para cada classe (Brondízio, 1993).

Foi realizado um extensivo exercício de coleta de dados para treinamento referente às diferentes classes desejadas. A primeira coleta de dados para estudo do comportamento estatístico apresentou os seguintes resultados:

Classe	Banda TM 3		Banda TM 4		Banda TM 5	
	Média	D.P.*	Média	D.P.*	Média	D.P.*
Cultura anual	22,3	1,0	58,7	4,6	44,7	4,3
Cana-de-açúcar	24,1	1,6	49,0	8,3	39,4	5,0
Solo nu	44,9	5,7	38,4	4,1	77,1	8,2
Solo Semi-ex	31,1	2,8	25,0	2,0	37,8	6,1
Água	20,6	1,9	11,7	1,3	7,1	2,0
Floresta	20,6	1,3	40,5	4,1	38,9	4,5
Pasto	36,8	2,0	36,5	1,9	75,2	4,7

*D.P. = desvio padrão.

Para as classes: cultura anual, solo nu, água, floresta e pasto foram usadas três áreas de treinamento e para cana-de-açúcar e solo semicoberto, quatro. Não há nenhum fato relevante nisto. Uma média de três amostras por classe seria suficiente nestas condições. Ver no Apêndice os gráficos com as assinaturas espectrais para as classes. As classes escolhidas para

cultura anual localizavam-se em pivôs centrais. Conforme consta no item 4.5, há uma predominância das culturas milho e feijão. Tomou-se o cuidado de escolha em pivôs, ou setores de pivôs, que apresentavam a mesma tonalidade de cor, indicativo de uma mesma cultura. A classe floresta, na realidade, representa as últimas áreas de cobertura natural do município. A classe solo semicoberto abrange um espectro maior, podendo representar áreas preparadas para novo plantio, ou pousio, ou mesmo áreas recém-colhidas.

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.

5.3. Medidas de separabilidade

Além das estatísticas já apresentadas, o MultiSpec calcula também para cada classe: valores máximo e mínimo, variância, matriz de variância-covariância e matriz de correlação, não mostrados estes dados aqui por simples economia. Obtidas as estatísticas, adota-se um procedimento para determinar 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 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.

Usou-se a Divergência, uma das primeiras medidas estatísticas de separabilidade usada no sensoriamento remoto e ainda largamente utilizada (Barret et al., 1992). Ela se atém ao problema básico de decidir qual é o melhor subconjunto 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

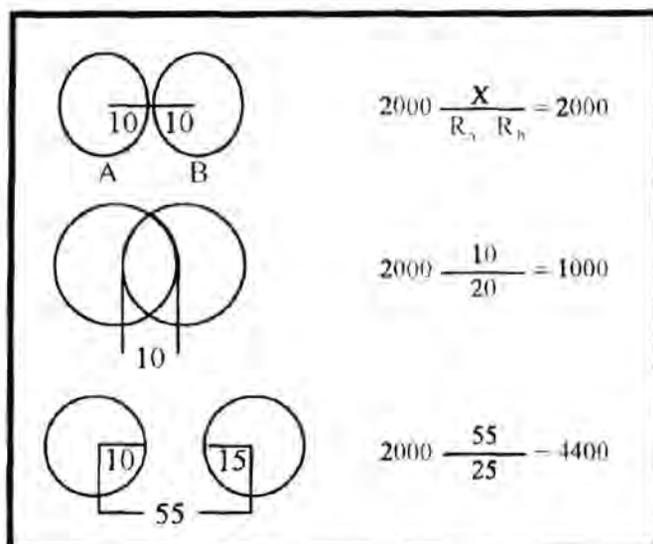
$\text{Tr}[\cdot]$ é o traço da matriz (soma dos elementos da diagonal), V_c e V_d são matrizes de covariância para as duas classes c e d , e M_c e M_d são os vetores média para estas classes. Este cálculo é válido para duas classes. Neste caso, trabalhando com sete classes, o cálculo é computado na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

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

Desta maneira, o subconjunto 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 usada 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, podem estar relacionando classes “extremamente” separadas da mesma maneira que relaciona classes “relativamente” separadas, como o valor 2200, por exemplo.

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



A Figura do lado serve para mostrar como se comporta, em termos práticos, o cálculo de divergência. Os valores apresentados são medidas estatísticas, sendo centrados na média e o raio seria o desvio padrão. No primeiro caso, as classes seriam totalmente divergentes. As amostras escolhidas para cada uma teriam

sido muito boas. 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.

O MultiSpec, dentro do conjunto de opções “Feature Extraction”, apresenta quatro opções de medida de distância: a) Bhattacharyya, b) Transformed divergence, c) Untransformed divergence, d) ‘NonCovariance’ Bhattacharyya.

A opção de trabalho foi a segunda, por indicação da equipe do ACT, considerando sua experiência nos trabalhos realizados em áreas agrícolas.

5.4. Análise das medidas de separabilidade

Nesta primeira fase, os valores apresentados após a execução da opção “transformed divergence” foram: (os valores a seguir representam a combinação das bandas 3, 4 e 5 para cada par de classes, em um 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	2000

Em uma análise rápida, o cálculo de divergência mostra que as classes 1 e 2, cultura anual e cana-de-açúcar, por exemplo, com valor de 1348, não são passíveis de separação total com combinação de bandas 3, 4 e 5. O segundo par de classes com algum grau de “pobreza” de separação de classes é 2 e 6, cana-de-açúcar e floresta, com 1865, porém, acima do valor mínimo, 1700. Isto significa que em uma classificação supervisionada, usando as três bandas 3, 4 e 5, o algoritmo de classificação confundiria as duas primeiras classes, 1 = cultura anual, 2 = cana-de-açúcar, em um grau bem maior do que no segundo caso, 2 = cana-de-açúcar, 6 = floresta. Todas as outras classes seriam bem classificadas. Com esta indicação, pode-se compreender um pouco mais a veracidade desta afirmação ao se analisar o Quadro de valores com estatística básica.

Classe	Banda 3		Banda 4		Banda 5	
	Média	D.P.*	Média	D.P.*	Média	D.P.*
1	22,3	1,0	58,7	4,6	44,7	4,3
2	24,1	1,6	49,0	8,3	39,4	5,0

* D.P. = desvio padrão.

O Quadro apresentado mostra que, considerando os valores de desvio padrão, as duas classe estão próximas. Isto não significa que não haverá um boa separação, pois a maior contribuição para confusão se encontra na banda 3, significando que os índices de fotossíntese para

ambas as culturas, quando da passagem do satélite, estavam muito próximos. Porém a cultura 1, cultura anual, realizava mais fotossíntese. Pelo valor da média, pode-se pensar em um estágio fenológico “maduro” para as amostras coletadas. A explicação é que na banda 3 está mapeado o espectro eletromagnético correspondente à faixa do visível no vermelho. Este comprimento de onda é fundamental para a realização da fotossíntese. Por isso, maior absorção nesta banda, significa mais fotossíntese e plantas mais saudáveis e verdes. A maior separação na banda 4 indica que para a classe 1, cultura anual existe pouco sombreamento, enquanto que para a classe 2, cana-de-açúcar, como era de se esperar, o problema de sombreamento é maior, baixando sua média. Conforme mostrado no item 4.5, há uma predominância das culturas de milho e feijão nas áreas irrigadas. Quando se fez a seleção de áreas de treinamento, as amostras foram selecionadas nestas áreas irrigadas. Considerando que se selecionou em uma das duas, problemas de sombreamento em feijão ou milho é menor que em cana-de-açúcar.

5.5. Classificação supervisionada

Mesmo considerando estes valores, foi executado no MultiSpec uma classificação supervisionada usando o algoritmo de máxima verossimilhança (“maxver”) (Jensen, 1986). 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 quadro, 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. Exemplo de parte deste quadro gerado como impresso pelo programa:

Class number = 1 ‘cultura anual’

Test field number = 23 ‘Field 46’

1111

1111

1111

1112

1221

1116

Field 23 ‘Field 46’ Percent correct 83.3

Neste exemplo, com acerto de 83,3%, cada número representa o valor de um pixel da área de treinamento escolhida. E cada pixel é atribuído a uma classe. A classe 1, cultura anual, predomina, pois é uma amostra desta classe. Percebe-se que a classe 2, cana-de-açúcar, tem três pixels e a classe 6, floresta, tem um pixel. Este é o problema antecipado pela medida de separabilidade, quando previu alguma confusão entre estas três classes.

A performance geral para estas primeiras amostras estão no quadro abaixo.

% Acerto p/classe		#Amostras	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

Na leitura do quadro, considerar as sete classes: 1 = cultura anual, 2 = cana-de-açúcar, 3 = solo nu, 4 = solo semicoberto, 5 = água, 6 = floresta e 7 = pasto. O acerto geral de classificação foi de $(5768/6086) = 94,8\%$. A quantia 5768 é o total de pixels classificados corretamente, 6086 a quantia total de pixels usados. O valor final está muito bom. Na literatura (Brondízio, 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 Fig. 2, pode-se perceber o que o programa de divergência havia previsto, alguma confusão nas classificações entre as classes 1, 2 e 6. O Quadro apresentado diz que 41 pixels da classe cultura anual (1) foi confundido com a classe

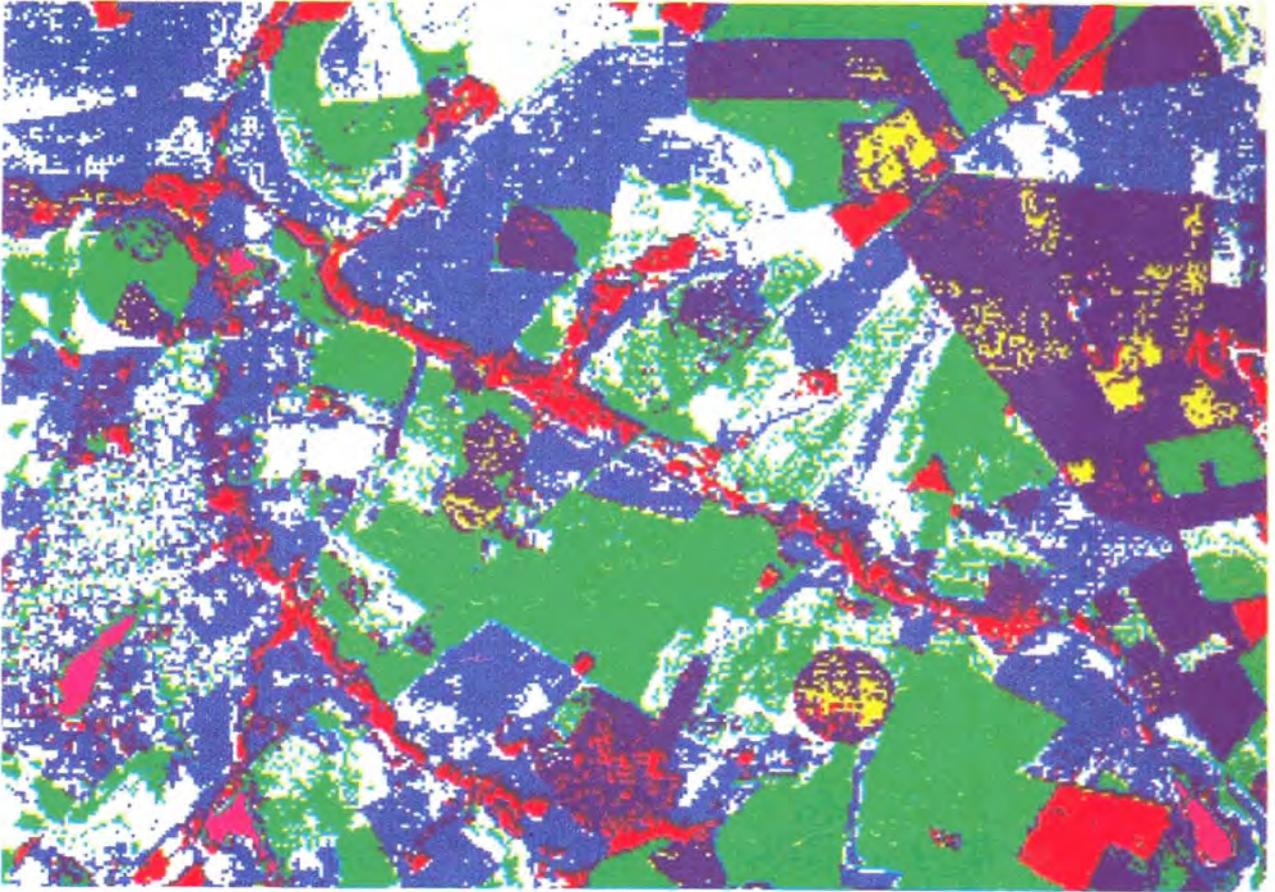


FIG. 2. Classificação supervisionada com campos de treinamento do Projeto 1: bandas 3, 4 e 5.

Classes

	Cultura anual
	Cana-de-açúcar
	Solo nu
	Solo semicoberto
	Água
	Floresta
	Pasto

cana-de-açúcar (2) e 1 com a classe floresta (6). Porém, o maior número de atribuições erradas se encontra na classe cana-de-açúcar (2) com a classe cultura (1), 171 e 7 com floresta (6). A classe solo nu (3) teve 48 pixels confundidos com pasto (7). Outro caso foi da classe pasto (7) com 42 pixels confundidos com solo nu (3), um número menor que o recíproco.

Em uma análise do relatório de dados impressos pelo maxver, foi constatado que duas, das quatro amostras de campo para cana-de-açúcar, foram as que apresentavam menor valor de precisão, conforme listado abaixo:

Classe 2 = cana-de-açúcar.

Campo de treinamento 4, porcentagem de acerto 97,5.

Campo de treinamento 5, porcentagem de acerto 99,3.

Campo de treinamento 6, porcentagem de acerto 69,4.

Campo de treinamento 7, porcentagem de acerto 66,0.

Todos os outros campos de treinamento para as demais classes apresentaram valores acima 90%.

Passou-se então para a segunda etapa de refinamento de amostras para a classificação supervisionada. Dois novos campos de treinamento foram escolhidos para cana-de-açúcar e o número de campos foi limitado a três. Todos os outros campos das demais classes foram conservados. Neste aspecto de interação com a imagem na tela o MultiSpec é efficientíssimo, facilitando bastante o trabalho de reconhecimento das amostras já realizadas.

O novo quadro de estatísticas básicas, nesta segunda fase de refinamento, só sofreu alteração para a classe cana-de-açúcar, razão porque não são apresentadas as outras estatísticas.

Banda	TM 3		TM 5		TM 5	
Classe	Média	D.P.	Média	D.P.	Média	D.P.
Cana-de-açúcar	24,9	1,4	50,4	9,6	43,2	5,4

Novamente, o programa de divergência transformada foi executado para estas novas classes. O resultado para a combinação das três bandas foi:

Mínimo	Média	12	13	14	15	16	17
1551	1960	1551	2000	2000	2000	1973	2000

23	24	25	26	27	34	35	36
2000	2000	2000	1879	2000	1994	2000	2000

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

Pode-se começar a análise pelo número mínimo, agora de 1551 contra 1348. Ainda não é um número que chegue ao mínimo exigido pelo algoritmo como bom (1700), no entanto, alguma confusão haverá, devido a diversas características das culturas, por apresentarem certas similaridades. Este número mínimo é exatamente entre as classes cultura anual e cana-de-açúcar. O outro par de classe problemático, cana-de-açúcar e floresta, com primeiro valor de divergência de 1865, agora subiu para 1879. Pode não representar muito, mas seu efeito na imagem classificada foi bastante interessante.

Nova execução do maxver, e os resultados obtidos para a precisão das amostras da cana-de-açúcar foram:

Classe 2 = cana-de-açúcar.

Campo de treinamento 4, porcentagem de acerto 97,5.

Campo de treinamento 5, porcentagem de acerto 81,5.

Campo de treinamento 6, porcentagem de acerto 94,3.

Estes valores permitiram uma maior separabilidade, observada acima, no cálculo da divergência. Os valores finais apresentados pelo maxver estão no quadro que segue:

% Acerto p/classe		#Amstras	1	2	3	4	5	6	7
1	94	565	535	29	0	0	0	1	0
2	89	741	62	662	0	0	0	17	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	0	0	0	0	481	0
7	97	1429	0	0	39	0	0	0	1390
Total		5893	601	693	1275	1134	253	499	1438

O acerto geral foi de $(5690/5893) = 96,6\%$. Praticamente dois pontos percentuais acima da primeira classificação. Analisando as dois Quadros do maxver, na coluna de porcentagem de acertos, a classe cultura anual subiu também dois pontos percentuais. Classe cana-de-açúcar subiu de 81% para 89%, oito pontos. Solo nu, solo semicoberto, água, floresta e pasto permaneceram com os mesmos valores. Quanto ao nível de confusão entre as classes cultura e cana-de-açúcar baixou de 41 para 29 pixels. Também houve um decréscimo acentuado da classe cana-de-açúcar para cultura anual, de 171 para 62. Mesmo considerando-se que o número de amostras caiu de 946 para 741, contudo, no primeiro caso o erro representava 18%, agora, 8,36%. Ainda há uma mistura com 17 pixels da classe floresta, contra 7 da primeira vez, o que mostra um crescimento. Diminuí também um pouco entre a classe pasto e solo nu, de 42 para 39. Em termos de imagem temática classificada, teve-se uma melhoria, conforme pode-se ver na Fig. 3, a mesma da primeira classificação.

5.6. Classificação final

Para a classificação final, o primeiro passo é a escolha dos campos de teste ("test fields"). Campos de testes são áreas que correspondem às classes escolhidas e são utilizadas para verificar a precisão da classificação desenvolvida, a partir dos campos de treinamento. São áreas

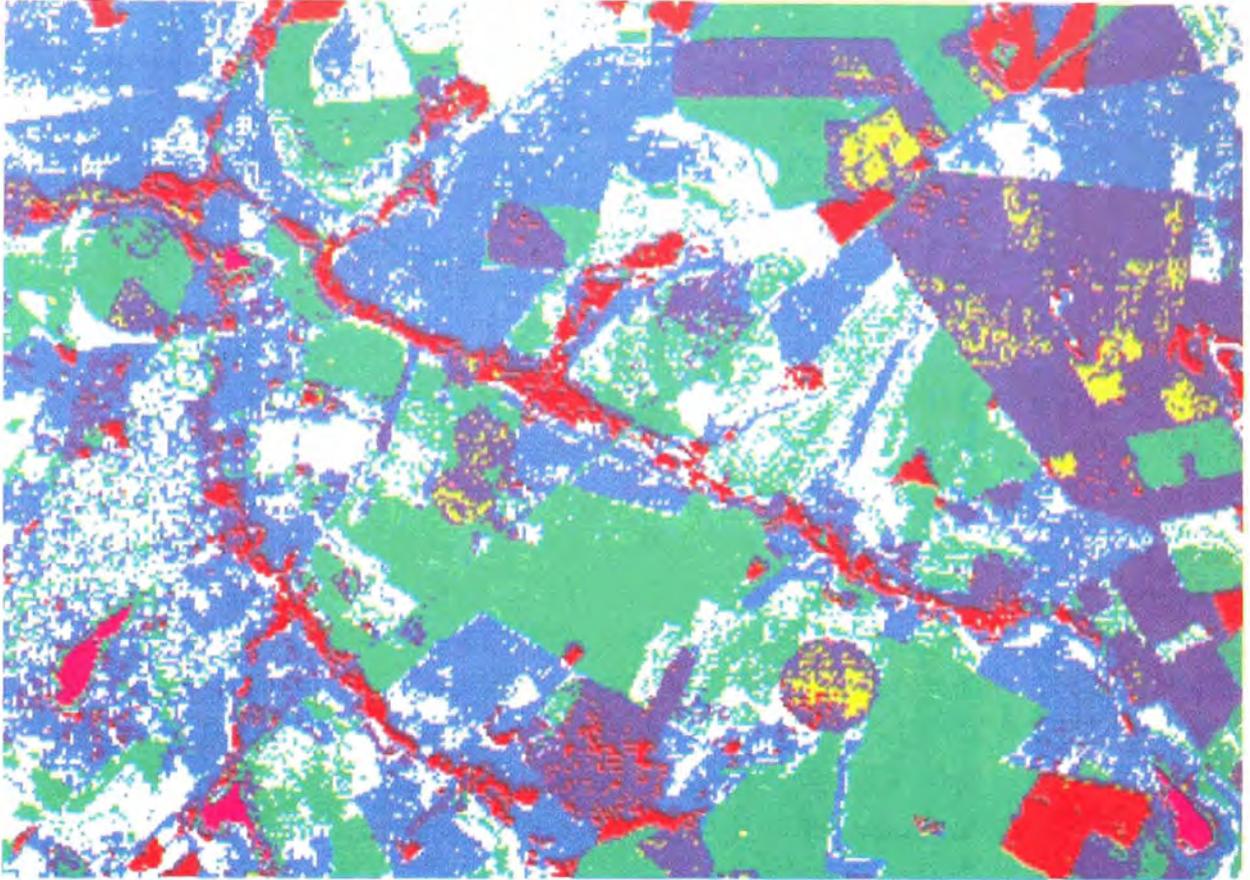


FIG. 3. Classificação supervisionada com campos de treinamento do Projeto 2: bandas 3, 4 e 5.

Classes

-  Cultura anual
-  Cana-de-açúcar
-  Solo nu
-  Solo semicoberto
-  Água
-  Floresta
-  Pasto

de natureza conhecida. São pequenos campos, o mais uniforme possível, e geralmente tomados em locais bem diferentes na área de trabalho, para ter uma representatividade maior. No trabalho, para cada classe, foram escolhidos dois campos de teste. Os campos de treinamento escolhidos foram os da segunda fase, conforme já descritos, pelo seu maior grau de separação em relação às primeiras áreas de treinamento escolhidas.

Após escolhidos os campos testes, o procedimento é executar o maxver, e verificar os novos valores de correção para a classificação das classes. Como primeira abordagem sobre a classificação, o maxver foi executado várias vezes usando diferentes combinações de canais, para se melhor estudar o comportamento intraclasses e interbandas, e assim obter novos parâmetros para se proceder a uma melhor classificação final. Ver no quadro a seguir os valores encontrados. Para esta análise, mostra-se apenas as porcentagens de classificação correta. A primeira coluna corresponde às classes: 1 = cultura anual, 2 = cana-de-açúcar, 3 = solo nu, 4 = solo semidescoberto, 5 = água, 6 = floresta e 7 = pasto. Os números da última linha, PG = performance geral de classificação de cada combinação de bandas.

Pelo quadro, apenas as combinações TM 4+5, TM 3+5 e TM 3+4+5, nesta ordem, poderiam ser usadas para classificação, considerando que o mínimo aceitável é de 85%. Em qualquer uma delas, os valores para a classificação de cultura anual está muito baixo. Na realidade, as áreas testes escolhidas para representar cultura anual foram extraídas dos pivôs, pois a data da imagem disponível, julho, é um mês em que no manejo tradicional, o solo está sendo preparado ou está em pousio. Neste trabalho estas áreas foram classificadas como solo nu. Os solos semidescobertos podem ser cana-de-açúcar em estágio inicial, ou com algum resíduo pós-colheita.

	TM 3	TM 4	TM 5	TM 3+4	TM 3+5	TM 4+5	3+4+5
1	83	100	53	90	57	46	46
2	66	76	0	69	66	68	72
3	100	0	98	100	100	100	100
4	85	100	15	100	100	100	100
5	0	90	92	90	90	92	90
6	52	45	49	100	95	90	100
7	65	44	55	48	83	99	77
PG	68	57	49	78	86	90	85

Foi observado na maioria dos pivôs com cultura a existência de duas cores: verde e amarelo. No momento do trabalho, não havia informação suficiente para dizer com certeza que tipo de cultura cada cor representava. Pelo estudo dos comportamentos espectrais no MultiSpec, concluiu-se que o verde poderia ser milho e o amarelo, feijão, baseado nos dados do Quadro sobre culturas nos pivôs apresentado no item 4.5. Esta informação ficou para ser verificada com a Casa da Agricultura de Guaíra. Ressalta-se que os campos testes foram extraídos das áreas “verdes” da imagem. De qualquer maneira, uma separação entre as duas culturas seria necessário. Por se tratar de área de pivôs, altamente dinâmica na sua rotação de culturas, não houve uma maior preocupação. A classificação da classe cana-de-açúcar apresenta problemas devido à sua confusão com cultura, além do que ela se encontra em vários estádios diferentes de crescimento, dificultando a precisão das áreas de escolha. Esta confusão cana-de-açúcar x cultura também pode ser explicada pelo fato de escolher-se (supostamente) milho. Estas duas culturas, em termos fisiológicos, chegam a ter alguma similaridade.

Das classes 3 a 6, o comportamento foi bom, com um alto grau de precisão na classificação. A classe 7 apresenta algum problema pela sua confusão com as classes 1 e 2. Mas sua pontuação final foi muito boa também.

6. Conclusão

Algumas outras técnicas de processamento de imagens, bem como tratamentos estatísticos não foram realizados, primeiro, pela exigüidade de tempo e também 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 com cinco ou sete bandas. Outra técnica, o cálculo do índice de vegetação (Campbell, 1987) e respectiva geração de banda, também pode auxiliar na solução de algumas áreas problemáticas. Seu principal objetivo é separar áreas da imagem com maior ocorrência de biomassa. Ambas as técnicas foram estudadas durante o treinamento, mas não houve tempo hábil para sua realização nas imagens de Guaíra. Este trabalho pode ser feito no Brasil. 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.

Como orientação futura, foi constatado que a aquisição de um maior número de bandas, pelo menos mais uma, TM 2, ajudaria no processo de diferenciação de cobertura vegetal. Se possível, a obtenção de mais imagens da mesma área em épocas diferentes auxiliaria no estudo da evolução temporal da fronteira agrícola. A utilização do Global Positioning System (GPS), em processo de aquisição pelo CNPMA, é importante para os trabalhos de campo e sua posterior correlação na imagem, na verificação de verdades terrestres.

Outras medidas de separabilidade estatística, constantes no MultiSpec não foram usadas, pois demandaria muito mais tempo e estudo. Contudo, o cálculo da “divergência transformada” se mostrou eficiente para a realização preliminar da escolha de campos de treinamento. O estudo cuidadoso do comportamento espectral das amostras, uma facilidade disponível em tempo real no MultiSpec, se mostrou também uma ferramenta muito útil na fase de aquisição de amostras.

O trabalho de correção geométrica na imagem não foi possível pelo fato de não haver ainda disponível no laboratório da ACT uma mesa digitalizadora. Sua aquisição está sendo realizada, mas não chegou no tempo em que se realizava o treinamento.

Também por falta de tempo, não foi usado o software ERDAS-Unix, para processamento de imagens. É um software muito poderoso, mas de manipulação difícil, exigindo a leitura de pelo menos seis grandes manuais. O MultiSpec, neste aspecto, se mostrou extremamente fácil de aprender e usar, sem deixar nada a desejar nos aspectos relativos a tratamento estatístico e manipulação de imagem.

Deixa-se claro que de maneira nenhuma o exercício aqui conduzido finaliza o trabalho de classificação. Como foi mostrado no Quadro final de classificação, algumas confusões ainda persistem entre algumas classes. Com o material estatístico coletado, e com o mapa temático produzido, o trabalho continuará em Guaíra, com ida a campo para identificação de verdades terrestres e melhoria na performance da escolha das próximas áreas, tanto de treinamento como de teste. A finalização do trabalho será realizada com o software Idrisi, disponível no CNPMA.

7. Referências bibliográficas

BARRET, E.C.; CURTIS, L.F. *Introduction to environmental remote sensing*. 3. ed. London: Chapman & Hall, 1992.

BROND-ZIO, E. *Lista de exercícios*. Bloomington: Indiana University, 1993.

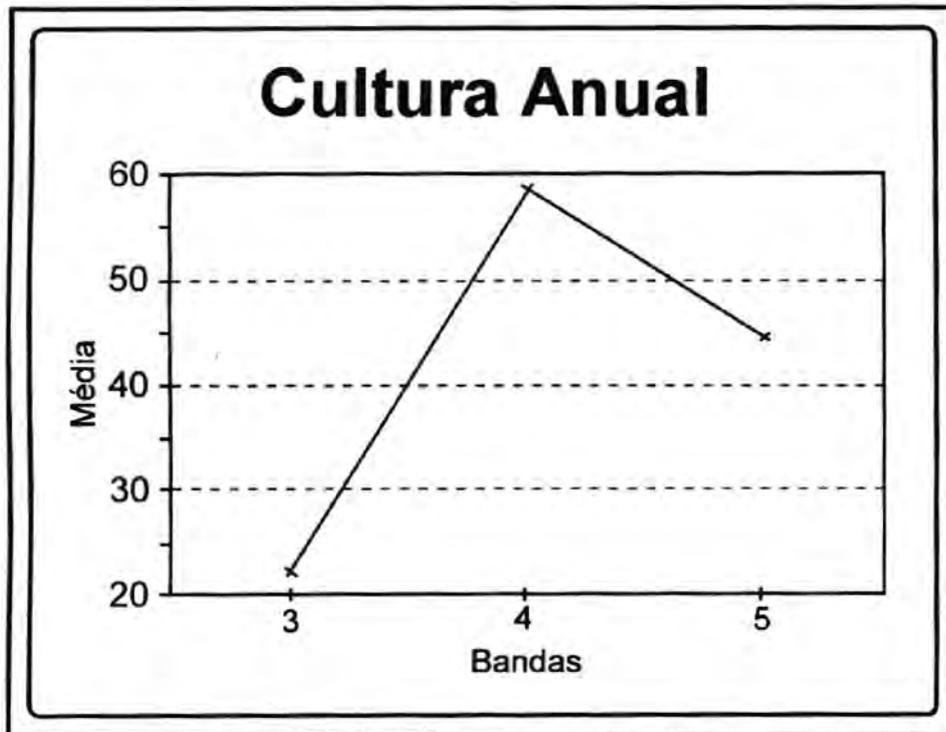
CAMPBELL, J. *Introduction to remote sensing*. New York: The Guilford Press, 1987.

CASA DA AGRICULTURA. Guaíra. Dados não publicados, 1992.

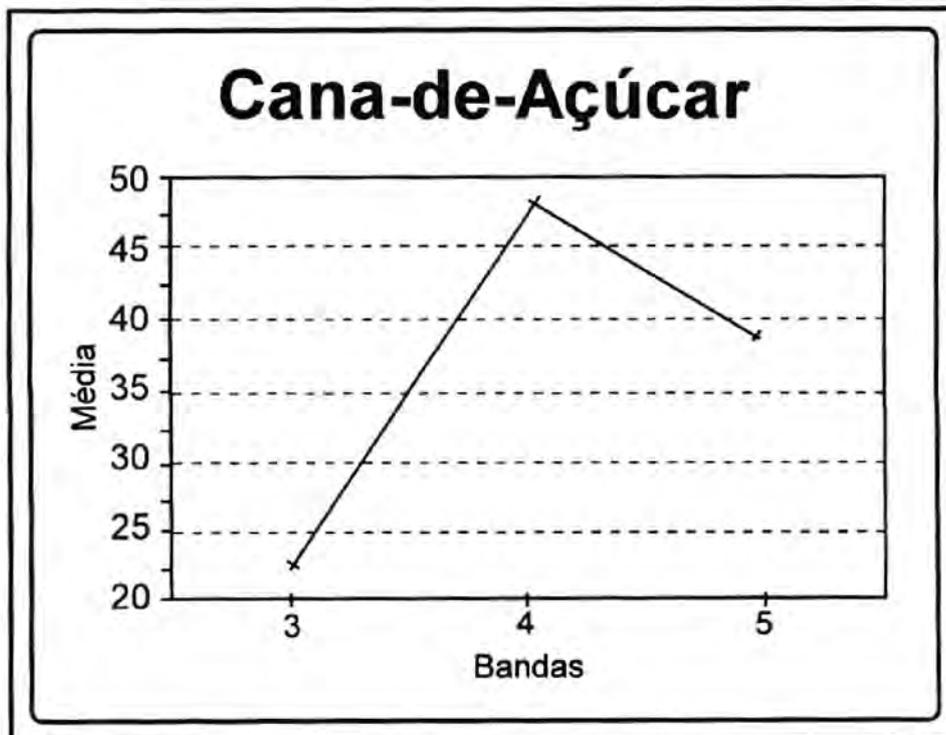
ECONOMIA. In: GUAÍRA ano 50: revista do cinquentenário da cidade. Guaíra: Prefeitura Municipal, 1979. p.4-12.

- IBGE. Departamento de Cartografia. *SF-22-X-B-III-3*: Guaiáira-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*: Miguel^{3/4}polis-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).
- JENSEN, J.R. *An introductory digital imagem processing: a remote sensing perspective*. Englewood Cliffs: Prentice-Hall, 1986.
- LANDGREBE, D.; BIEHL, L. *An introduction to multiSpec*. West Lafayette: School of Electrical Engineering, 1993.
- SÃO PAULO. Secretaria de Obras e do Meio Ambiente. Departamento de águas e Energia Elétrica. *Projeto Guaiáira: estudo de viabilidade técnico-econômica de irrigação*. São Paulo, 1976. 3v.
- 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-Guaiáira. Campinas: IAC,1991. (Esc. 1:100.000).

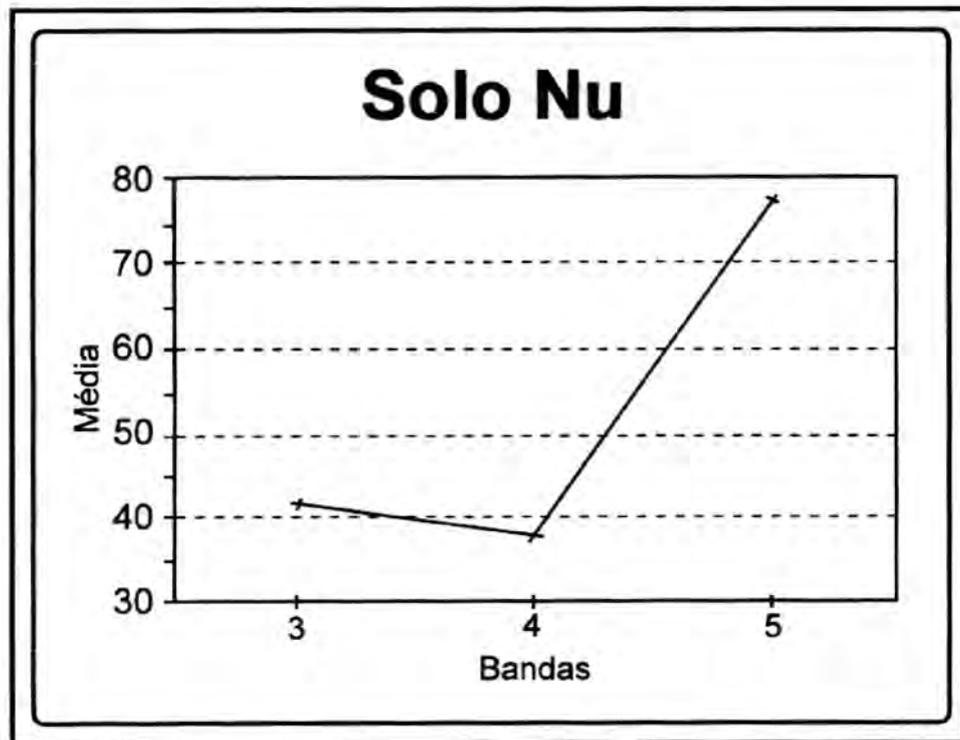
APÊNDICE



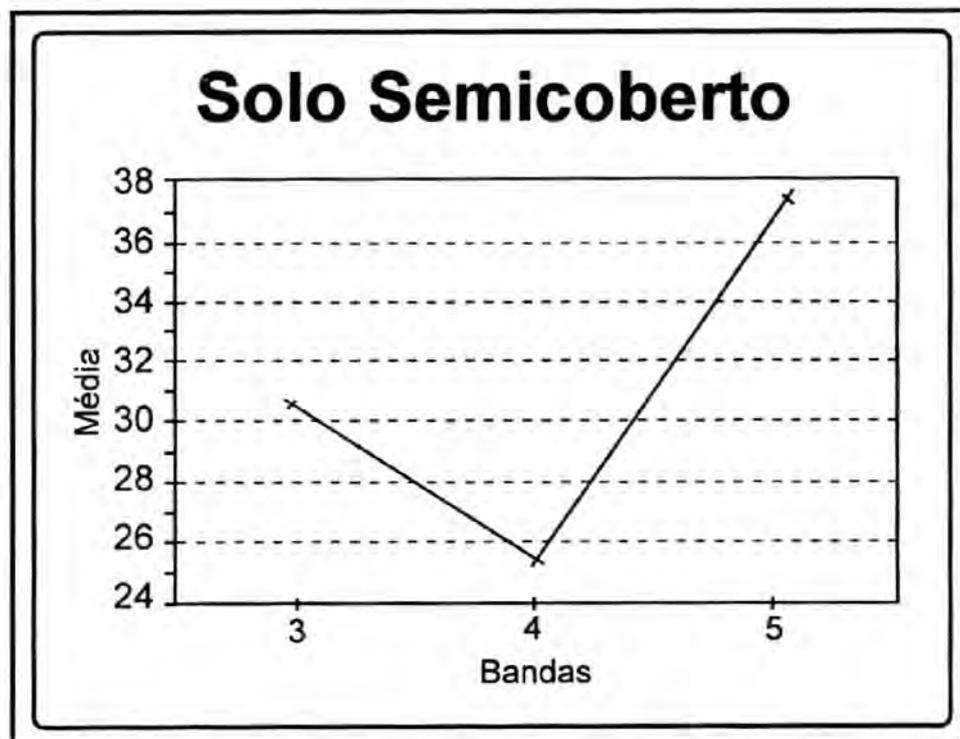
1. Quadro de assinatura espectral para cultural anual.



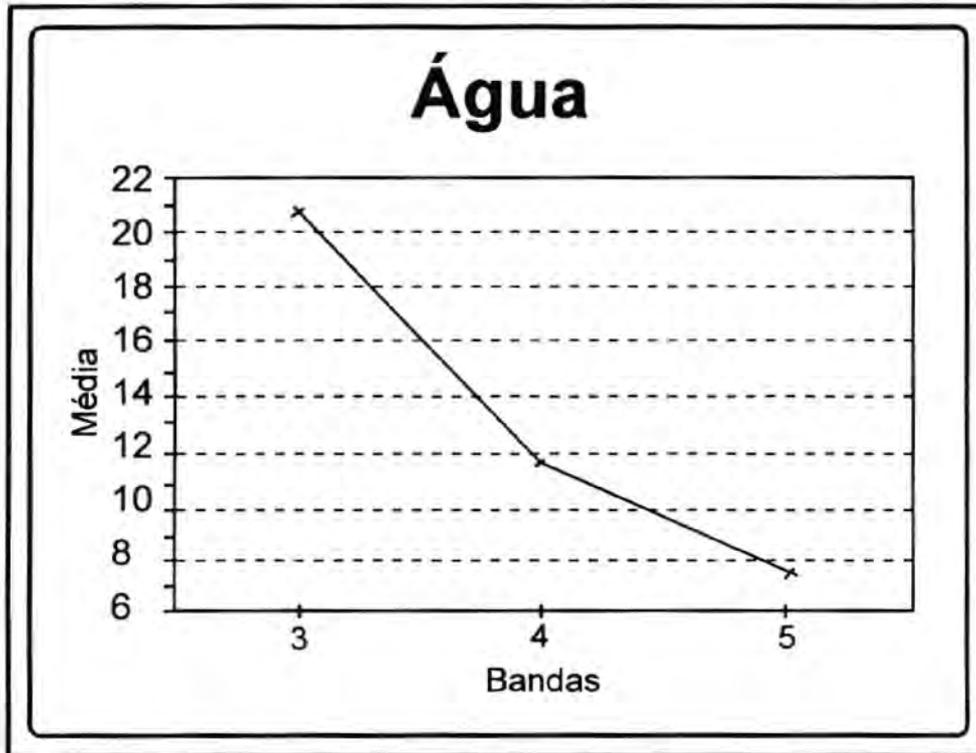
2. Quadro de assinatura espectral para cana-de-açúcar.



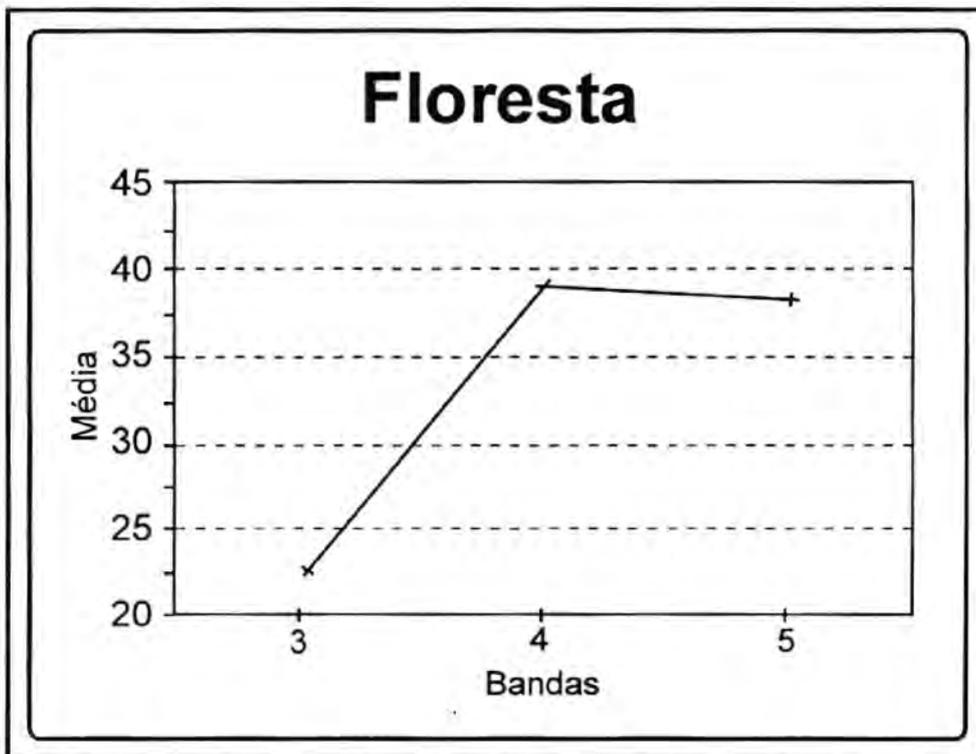
3. Quadro de assinatura espectral para solo nu.



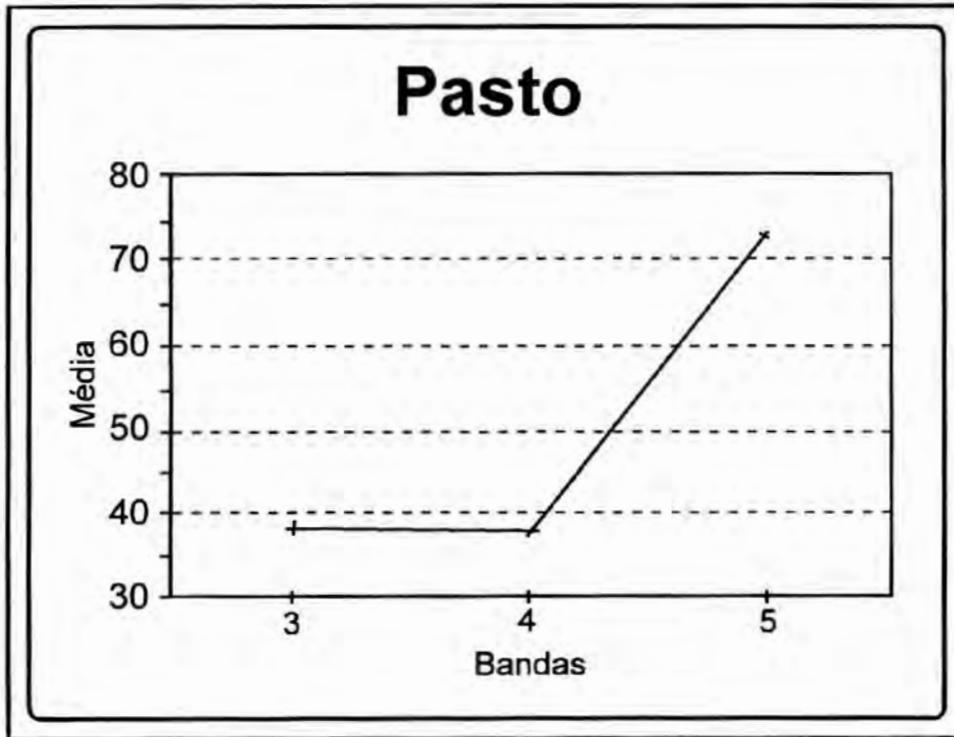
4. Quadro de assinatura espectral para solo semicoberto.



5. Quadro de assinatura espectral para água.



6. Quadro de assinatura espectral para floresta.



7. Quadro de assinatura espectral para pasto.

