

Uso de imagens hiperespectrais (EO-1 Hyperion) para detalhamento da detecção das formações florestais na bacia do Itajaí

¹Vanessa Fernanda Schramm* & ¹Alexander Christian Vibrans

1. Departamento de Engenharia Florestal, Centro de Ciências Tecnológicas, Universidade Regional de Blumenau, Rua São Paulo 3250 Blumenau/SCBrasil, 89030-000. acv@furb.br

*Bolsista programa PIBIC/FURB – 2006/2007. vaschramm@hotmail.com

Resumo: O presente trabalho tem o objetivo de utilizar imagens hiperespectrais do sensor Hyperion para identificar e descrever a resposta espectral das diversas formas da cobertura vegetal natural e de algumas culturas agrícolas na bacia do Itajaí. Utilizou-se para este trabalho, uma cena do órbita-ponto 220/79 de 18 de junho de 2003, com resolução espacial de 30m. Foram realizados o georeferenciamento da imagem, a sua interpretação visual, a escolha na imagem de áreas de treinamento das diferentes classes de uso do solo, a extração das assinaturas espectrais das respectivas áreas; em seguida foi realizada a análise da separabilidade espectral das classes nas bandas originais e numa série de bandas sintéticas, resultantes de transformações de bandas e, por fim, a classificação supervisionada com uso do algoritmo da máxima verossimilhança (MaxVer). Os resultados mostram que o uso de imagens hiperespectrais possibilita a nítida diferenciação das formações florestais e culturas agrícolas e significa um avanço em relação ao uso de imagens Landsat. Por outro lado, a partir do uso de 40 bandas do sensor Hyperion, não se constatou melhoria na diferenciação dos temas analisados. Apesar da boa separabilidade dos temas, a classificação supervisionada não mostrou resultados suficientes devido à dificuldade de identificar pixels puros da maioria dos temas numa imagem com resolução espacial de 30 metros e numa paisagem onde lavouras, pastagens e florestas secundárias formam um mosaico composto por componentes muito pequenos, muitas vezes com poucos hectares. Futuros estudos devem procurar áreas com elementos maiores de paisagem para facilitar a interpretação e processamento das imagens, como áreas nas planícies do Alto Vale do Itajaí, nas sub-bacias do Rio Trombudo ou do Rio Pombas.

Palavras-chave: Sensoriamento remoto hiperespectral; Hyperion; resposta espectral, cobertura vegetal, transformações de bandas.

1. Introdução

Para analisar, mapear e monitorar a cobertura florestal, é indispensável o auxílio de técnicas e recursos do sensoriamento remoto. Esses recursos estão sendo usados para monitorar a cobertura florestal a nível mundial desde a década de 1980.

A estrutura da cobertura vegetal natural é complexa e é resultado da interação de fatores abióticos, bióticos e antrópicos. Junto com os outros elementos, como áreas agrícolas, pastagens, áreas urbanas e corpos d'água, as florestas formam o que é chamado paisagem. Entender e interpretar o seu estado atual e seus aspectos históricos são atividades complexas que dependem do uso de recursos de sensoriamento remoto.

Florestas naturais e seus estágios de sucessão secundária ocupam grande parte da área da bacia do Itajaí, com tendência de aumento. As informações atualmente disponíveis foram obtidas a partir de imagens Landsat, que têm limitações no discernimento de formações florestais tropicais secundárias. O seu detalhamento é necessário para a modelagem hidrológica, devido às diferenças nos processos de interceptação, evapotranspiração e infiltração, exercidos pelos diversos tipos de cobertura florestal natural. Os estágios da sucessão secundária da Floresta Ombrófila Densa (fase pioneira, capoeirinha, capoeira, capoeirão, floresta secundária e primária) apresentam diferenças nas variáveis biofísicas (altura, área basal, diâmetro das copas, grau de fechamento do dossel, volume de madeira e de biomassa), bem como na composição

de espécies, densidade e complexidade da cobertura vegetal, no tamanho e na orientação das folhas e no sombreamento entre as árvores do dossel. Estas variáveis são responsáveis por definir sua resposta espectral (PONZONI, 2001), além de causar diferenças no seu comportamento hidrológico. A presente pesquisa visa avançar no conhecimento das respostas espectrais dos principais tipos de vegetação natural e de algumas culturas agrícolas usando imagens hiperespectrais.

A alta resolução espectral das imagens Hyperion implica num grande potencial para a identificação de diferentes tipos de superfícies, baseado nas características de suas respostas espectrais específicas. Objetivo deste trabalho é utilizar o potencial das imagens hiperespectrais, com suas bandas originais e diversas bandas sintéticas resultantes de diferentes transformações, para identificar e descrever a resposta espectral das diversas formas da cobertura vegetal na da bacia do Itajaí.

De acordo com Alixandrini (2004), dados hiperespectrais tem sido usados para mapear os materiais superficiais há mais de 15 anos. Desde a descoberta de que os vegetais extraem da radiação eletromagnética emitida pelo sol parte da energia que necessitam para viver, a interação entre essa radiação e a vegetação passou a ser estudada detalhadamente (MENESES et al., 2001).

Dados hiperespectrais como os do sensor Hyperion, no entanto, ainda são relativamente pouco utilizados para a caracterização das florestas naturais no Brasil, ao contrário do que ocorre nos Estados Unidos onde existem amplos estudos e bibliotecas espectrais para as principais espécies arbóreas que formam as tipologias da vegetação do país. Shimabokuro et al. (2003) diferenciaram em imagens Hyperion a “capoeira” da floresta primária na Floresta Nacional do Tapajós-PA. Alguns estudos avaliaram o uso de dados hiperespectrais para a discriminação de alvos agrícolas (TISOT et al., 2005; GALVÃO et al., 2005). Ambos obtiveram bons resultados para a diferenciação de alvos mesmo com diferenças espectrais tênues utilizando dados Hyperion.

Segundo Galvão et al. (2005), usando valores de reflectância das bandas do sensor Hyperion, razões de reflectância e índices espectrais potencialmente sensíveis a variações, a discriminação de variedades de cana-de-açúcar pôde ser feita. Neste estudo, os autores defendem a idéia de que, visando diferenciar as variedades com maior similaridade espectral, podem ser aplicados índices espectrais e razões de bandas que caracterizaram a comportamento espectral de

cada variedade nos diferentes comprimentos de onda.

Segundo Accioly et al. (2005), o detalhamento das curvas espectrais do sensor Hyperion permitem uma melhor distinção entre alvos, possibilitando ainda melhorar técnicas de realce o que não é possível com sensores como o Landsat-TM ou Landsat-ETM+.

Sensoriamento remoto é uma técnica de aquisição de dados dos objetos existentes na superfície terrestre, sem que haja contato físico direto entre o sensor e o objeto. Esta aquisição se dá através de um fluxo de radiação eletromagnética (MENESES et al. 2001). Três são os fenômenos que descrevem o processo de interação entre a radiação e o objeto sobre o qual incide certa quantidade de radiação (solar): são eles a reflexão, a transmissão e a absorção. A análise conjunta desses três fenômenos compõe aquilo que denominamos como estudo do comportamento espectral da vegetação. A reflectância é a propriedade de um determinado objeto em refletir a radiação eletromagnética sobre ele incidente e é expressa através de um valor relativo à radiação incidente, variando de 0 a 1. A reflectância, segundo Ponzoni et al. (2007), serve para avaliar as propriedades de reflexão de radiação por parte do objeto ou superfície, independentemente das intensidades de radiação incidentes sobre ele.

Importantes características dos sensores remotos são a sua resolução espectral e espacial. A resolução espacial define o tamanho da superfície equivalente a um pixel da imagem; a espectral define a faixa do espectro eletromagnético que o sensor registra e pode ser larga, como nos filmes das aerofotografias pancromáticas, ou dividida em vários canais, ou bandas, no caso dos sensores multiespectrais. Os sensores chamados hiperespectrais, por sua vez, possuem centenas de canais sensíveis, cada um numa faixa extremamente estreita do espectro.

Para Richards (1993), a assinatura espectral de um objeto ou alvo terrestre designa as características de sua reflectância e, as variáveis de reflectância nas diversas faixas do espectro eletromagnético, são conhecidas como atributos. Um conjunto de atributos define o padrão de uma classe de alvos, de natureza espectral ou espacial.

As feições espectrais de um material correspondem às porções das curvas de reflectância em determinado comprimento de onda, com formas e intensidade muito bem definidas e próprias daquele material (MENESES et al., 2001). Essas feições indicam absorções da radiação eletromagnética pelos constituintes do material. Segundo os mesmos autores, são essas feições de absorção que interessam ao sensoriamento remoto, embora, o que um sensor mede seja a radiação refletida

(reflectância). O sensor mede a intensidade média do fluxo radiante refletido, originado de todas as infinitas intensidades provenientes de cada um dos infinitos pontos existentes na superfície, essa intensidade é denominada radiância (PONZONI et al., 2007). De acordo com o mesmo autor, a radiância é diretamente proporcional à irradiância (radiação eletromagnética emitida pelo sol), ou seja, quanto maior for a intensidade em irradiância, maiores serão os valores de radiância. Muitos processos de tratamento e interpretação de imagens multi- e hiperespectrais aproveitam-se do comportamento espectral peculiar da cobertura vegetal para realçar e distinguir com clareza a vegetação das demais coberturas da terra (RICHARDS, 1993): de sua alta absorção de energia na faixa da radiação visível e por consequência, baixo nível de reflectância nesta faixa e sua baixa absorção e alta reflexão na faixa da radiação do infravermelho próximo. Os mais empregados índices utilizam a informação contida nas reflectâncias de dosséis referentes às regiões do vermelho e do infravermelho próximo, as quais são combinadas sob a forma de razões (MENESES et al. 2001).

Segundo Meneses (2001), o dossel de uma floresta é constituído por diversos elementos tais como folhas, galhos, frutos, flores e sombras. Um fluxo de radiação que incide sobre qualquer um desses elementos está sujeito a processos que resultarão em feições espectrais próprias daquele material exposto a radiação, mostrando resultados diferentes de acordo com as feições de absorção daquele elemento de um mesmo componente.

Quando a radiação incidente toma a proporção de uma estrutura complexa como uma paisagem, interpretar os resultados das feições obtidas torna-se um conglomerado de dados com várias interações. Cada elemento da paisagem tem suas características próprias e desenvolve-se em diferentes tipos de solos sob diferentes condições ambientais.

A perspectiva é de que, com as técnicas de sensoriamento remoto e os sensores hiperespectrais, essas feições se tornem singular quando comparadas ao todo, possibilitando classificar e diferenciar todos os elementos que constituem a paisagem.

Imagens hiperespectrais são muito suscetíveis às interferências atmosféricas e topográficas, o que dificulta a identificação e a quantificação da cobertura vegetal. Assim torna-se fundamental o emprego de técnicas para minimizar a diferença de iluminação causada pela topografia de uma cena ou realçar detalhes de uma cena. Quando se deseja reduzir os efeitos de topografia e melhorar a

visualização de imperceptíveis diferenciações na reflectância de determinados alvos, são usados os índices de vegetação e as transformações de bandas. Entre as operações aritméticas entre os valores de cinza de diferentes bandas, a subtração e as razões de bandas são as mais utilizadas (RICHARDS, 1993). Classificação é chamado o processo de extração de informação em imagens com o objetivo de reconhecer padrões e objetos homogêneos. O processo de classificação consiste de dois passos: primeiro são definidos os padrões de atributos de um certo número de classes, preferencialmente homogêneas do ponto de vista espectral e discerníveis entre si. Em seguida, todos os pixels de uma cena a ser classificada são analisados aplicando-se diversas regras matemáticas para decidir se podem ou não ser atribuídos às classes estabelecidas (RICHARDS, 1993). O mesmo autor ainda cita que, para ambos os passos existem diversas metodologias que deram origem aos diversos tipos de classificação.

2. Material e Métodos

Área de estudo

A área de estudo compreende uma faixa de 7 por 42 km, e cobre parte dos municípios de Ituporanga, Chapadão do Lajeado, Imbuia e Vidal Ramos, localizados no Alto Vale do Itajaí. A região caracteriza-se com o clima temperado com temperatura média anual de 21,5°. C. A escolha da área de estudo se justifica pela existência de informações detalhadas levantadas em outros trabalhos, baseadas em imagens Landsat, e pela existência de ambientes diferentes e representativos para os demais municípios da bacia do Itajaí, em relação a tipo de uso, relevo, topografia e cobertura florestal.

Obtenção dos dados

Foi utilizada uma imagem hiperespectral do sensor Hyperion da cena 220/79 de 18/06/2003, com resolução espacial de 30m, com coordenadas centrais de 27° 56'96''S e 49° 37'92''W. Do total de 242 bandas do sensor, são fornecidas pelo United States Geological Survey (USGS) que distribui as imagens, 198 bandas calibradas, com largura de 10 nm cada. Destas foram utilizadas, no presente estudo, 156 bandas, no intervalo de 426 nm a 2578 nm, sendo excluídas as que cobrem as faixas do espectro influenciadas fortemente pelo vapor d'água.

Os dados Hyperion foram adquiridos junto ao USGS e as imagens foram processadas em estação de

trabalho com uso do software ENVI 4.3 (RSI), licenciado para a Universidade Regional de Blumenau.

Inicialmente a imagem Hyperion foi georeferenciada com base nas imagens Landsat que compõem o banco de dados existentes na instituição.

Os valores de cinza (ou DN, digital number), fornecidos pelo USGS foram convertidos mediante a ferramenta band math do ENVI em radiância e posteriormente em valores de reflectância de acordo com as instruções do próprio USGS, usando os dados de irradiância fornecidos por este órgão e aplicando a equação:

$$\rho_{\lambda} = \frac{L_{\lambda} \pi d^2}{E_{\lambda} \cos \theta_z}$$

onde L_{λ} = radiância na banda λE_{λ} E_{λ} = irradiância solar na banda espectral λ
 ρ_{λ} = reflectância exoatmosférica $\cos \theta_z$ = ângulo zenital solar
 d = distância terra-sol

Diante da ausência de dados atmosféricos correspondentes à data e ao local da captação da imagem, não foi aplicada correção atmosférica dos dados. Para iniciar a caracterização das respostas espectrais, foram carregadas regiões de interesse (ROI - regions of interest), contendo áreas de treinamento identificadas em campo e áreas classificadas com acurácia nas imagens Landsat de 2004, totalizando 600 pixels de cada tema.

Análise dos dados

Após vários testes, incluindo número variável de bandas, foram escolhidas para o processo de interpretação da imagem, 40 bandas do espectro com limites espectrais entre 426 nm e 620 nm; 925 nm e 1003 nm; 1638 nm e 1739 nm. A escolha desta seleção justifica-se pelo resultado satisfatório encontrado, quanto à separabilidade dos temas, ressaltando que ao longo dos testes verificou-se que com aumento do número de bandas selecionadas melhorava a separabilidade espectral, chegando a alcançar, índices de separabilidade acima de 1.9.

Dois índices são frequentemente utilizados, para analisar a separabilidade de classes, o de Jeffries-Matushita e o da Divergência Transformada (RICHARDS, 1993), sendo para ambos o valor 1,8, considerado o limite entre a separabilidade e a não-separabilidade de duas classes.

O arquivo contendo as 40 bandas foi carregado no espaço RGB com as bandas 925 nm (R), 1659 nm (G) e 620 nm (B). Nesta visualização foram identificados, os temas a serem mapeadas, Lavouras (Milho e Cebola), Mata nativa, Pasto, Pasto sujo e Reflorestamentos (Eucalyptus, Pinus).

Amostras destes temas foram identificadas e localizadas em campo, por meio de 16 pontos coletados e georeferenciados com GPS (Global Positioning System) de navegação. Com o auxílio de um Notebook delimitou-se polígonos preliminares. Na tela do computador, foram criados polígonos a partir destes pontos, excluindo pixels que permaneciam na borda dos polígonos em formato vetor (regiões de interesse), criados em campo, para obter valores de DN mais homogêneos por tema (Tabela 1).

Tabela 1- Temas recolhidos em campo para o estudo.

Temas	Nº. de pixels
Cebola	13
<i>Eucalyptus</i>	54
Lavouras	54
Mata nativa	61
Milho	82
Pasto	97
Pasto sujo	52
<i>Pinus</i>	60

Em decorrência da pequena extensão da área do tema cebola, o tema não foi submetido à análise estatística com os outros temas, permanecendo fora do estudo.

Estes mesmos temas, exceto o da cebola, também foram utilizados para a realização de classificação supervisionada da imagem usando o algoritmo da máxima verossimilhança (MaxVer). Várias classificações com uso de diversos limiares de probabilidade foram realizadas, buscando fornecer resultados com níveis baixos de comissão e omissão para cada tema.

Da imagem foram recortadas (Figura 01) as áreas de nuvens que dificultavam a classificação e foi incluído o tema "sombra".

Após estes tratamentos, foi processada a matriz de confusão baseada nas próprias áreas de treinamento (acuracidade geral, coeficiente de Kappa, omissão e comissão de cada tema); isto permitiu a aferição das classificações e a determinação do grau de acerto e erro com base nas características espectrais das próprias áreas de treinamento.

Em seguida foram geradas, via ferramenta band math, bandas sintéticas contendo os índices de vegetação listados na Tabela 2.

O primeiro índice feito por ser o mais conhecido e o mais utilizado foi o Índice de Vegetação por Diferença Normalizada (NDVI). Segundo Epiphany et al.(1996), o resultado gerado deste índice é a construção de bases de dados globais fundamentado nos dados do sensor AVHRR (Advanced Very High Resolution Radiometer) dos satélites NOAA (National Oceanic and Atmospheric Administration)

este sensor possuindo canais ou bandas espectrais no visível e no infravermelho próximo permite a elaboração do NDVI.

Tabela 2: Índices espectrais com parâmetros usados no estudo.

Variáveis	Equação/Método	Referência
1. Normalized Difference Vegetation Index (NDVI)	$(\rho_{864nm} - \rho_{671nm}) / (\rho_{864nm} + \rho_{671nm})$	Rouse et al. (1973) citado por Galvão et al. (2005)
2. Normalized Difference Water Index (NDWI)	$(\rho_{864nm} - \rho_{1245nm}) / (\rho_{864nm} + \rho_{1245nm})$	Gao (1996) citado por Galvão et al. (2005)
3. Leaf Water Vegetation Index (LWVI-1)	$(\rho_{1094nm} - \rho_{893nm}) / (\rho_{1094nm} + \rho_{893nm})$	Galvão et al. (2005)
4. Leaf Water Vegetation Index (LWVI-2)	$(\rho_{1094nm} - \rho_{1205nm}) / (\rho_{1094nm} + \rho_{1205nm})$	Galvão et al. (2005)
5. Photochemical Reflectance Index (PRI)	$(\rho_{529nm} - \rho_{569nm}) / (\rho_{529nm} + \rho_{569nm})$	Gamon et al. (1992) citado por Galvão et al. (2005)
6. Red-Edge Vegetation Stress Index (RVSIS)	$((\rho_{712nm} + \rho_{752nm}) / 2) - \rho_{732nm}$	Merton e Huntington (1999) citado por Galvão et al. (2005)
7. Enhanced Vegetation Index (EVI)	$2.5(\rho_{1100nm} - \rho_{671nm}) / (\rho_{1100nm} + 6(\rho_{671nm}) - 7.5(\rho_{480nm}) + 1)$	Huete (2007)
8. Principal Components - Compute New Statistics and Rotate	Contínuo espectral (limites em 426 nm e 620 nm; 925 nm e 1003 nm; 1638 nm e 1739 nm)	Vibrans (este estudo)
9. Tasseled cap	1. Contínuo espectral (limites em 426 nm e 620 nm; 925 nm e 1003 nm; 1638 nm e 1739 nm); 2. Com todas as 156 bandas do espectro.	Vibrans (este estudo)

Outro índice usado foi o Índice Realçado da Vegetação (EVI) que destaca o sinal da vegetação em regiões de biomassa elevada. Este índice é uma versão otimizada do NDVI com coeficientes adicionados para melhorar a extração dos sinais da vegetação. Os coeficientes utilizados para o cálculo do EVI foram extraídos de acordo com o trabalho de Huete (2007), onde o fator de ajuste do solo (L) obtém valor 1, o fator de ganho (G) usado, foi o 2,5 e, os coeficientes de ajuste para efeito de aerossóis da atmosfera (C1 e C2) foram respectivamente 6 e 7,5.

Com cálculo semelhante ao do NDVI, o Índice da Diferença Normalizada da Água (NDWI), utiliza bandas do infravermelho próximo e do verde, o que produz o valor 1 para corpos d'água e próximo de -1 as demais feições. O cálculo é semelhante ao do NDVI.

Vários estudos indicam que o Índice Fotoquímico da Reflectância (PRI) pode ser correlacionado com as taxas de fotossínteses (BAPTISTA, 2003). O efeito deste índice expressa a diferença entre a aparência de absorção no azul e o pico de reflectância do verde e, o seu cálculo também pode ser considerado uma variante do NDVI.

O Índice de Stress da Vegetação "Vermelho-Borda" (RVSIS), também se baseia na mudança da reflectância pelo comprimento de onda, entre duas das regiões mais extensamente usadas para estudos, a banda vermelha e a do infravermelho. Este índice define a simetria complexa do "vermelho-borda" através de uma escala de medidas geométricas e estatísticas.

Os espectros gerados são usados também para identificar variações na geometria da "vermelho-borda" associada com o stress aparente nas

comunidades e as variáveis ambientais em mudança.

A base para gerar os Índices de Vegetação de Água na Folha (LWVI-1 e LWVI-2) foram extraídas do estudo do Tisot et al. (2005), onde são apenas uma variante do NDWI (Normalized Difference Water Index).

A transformação Tasseled Cap (TC) é empregada quando se quer reduzir os dados e aumentar a percepção de características físicas da cena, obtêm-se novas bandas através do ajuste linear das bandas originais, desta forma, as informações são arranjadas em relação a novos eixos que estão relacionados diretamente com as características físicas da cena, o brilho, o verde e a umidade. O índice teve início quando Kauth e Thomas em 1976 apresentaram uma identificação dos níveis de maturação de culturas agrícolas através desta transformação.

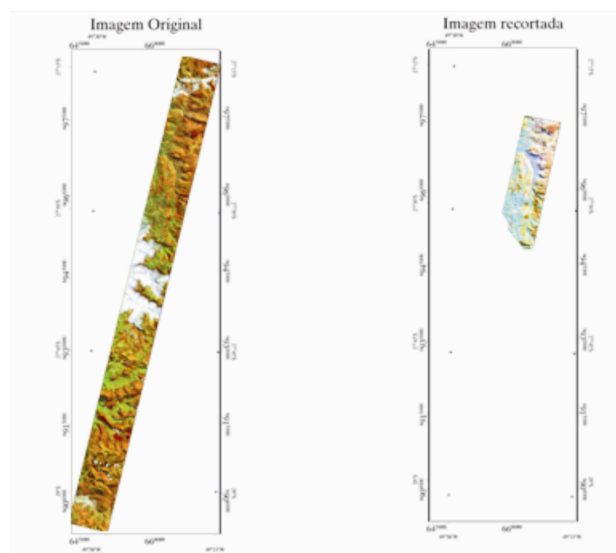


Figura 1. Imagem original e imagem após o recorte na composição R(925nm), G(1659nm) e B(620nm).

Neste estudo foram feitas duas transformações TC, a primeira com as quarenta bandas selecionadas (limites em 426 nm e 620 nm; 925 nm e 1003 nm; 1638 nm e 1739 nm), e outra transformação usando todas as 156 bandas do espectro. Nestas transformações pôde-se extrair a média, que nas duas transformações apresentou o mesmo resultado e as separabilidades dos temas nas bandas obtidas, os resultados mostram que a separabilidade com as bandas selecionadas não trouxeram um resultado satisfatório, mas mostrou-se melhor que a separabilidade encontrada usando todas as bandas do espectro.

A Transformação por Principais Componentes (TPC) é uma aplicação de uma transformação de bandas que reuni em um conjunto de novas bandas o que representa a maioria dos dados contidos nas

bandas originais. Geralmente os primeiros componentes conseguem agrupar a maioria das variações dos dados, utilizando-se somente estes para fins de interpretação, cada componente carrega informação independente dos outros componentes.

Nesta transformação foram avaliadas apenas as 40 bandas selecionadas (limites em 426 nm e 620 nm; 925 nm e 1003 nm; 1638 nm e 1739 nm) pode-se observar que esta transformação obteve os mesmos índices de separabilidade.

3. Resultados e Discussão

Extração dos perfis espectrais

Após a definição por polígonos das regiões de interesse, os pixels demarcados foram submetidos à análise estatística (o tema “cebola” não participou da análise, por não haver número suficiente de pixels). A análise das respostas espectrais dos temas é muito importante para o conhecimento do comportamento espectral das áreas de treinamento. A separabilidade dos temas depende de uma nítida distinção entre as assinaturas espectrais. O comportamento espectral dos temas, nas 156 bandas e nas 40 selecionadas, é igual. Na Figura 2, está apresentado o espectro de refletância extraído dos temas estudados.




Figura 2: Espectros de refletância extraídos dos temas analisados nas 156 bandas.

Os espectros foram extraídos e plotados comparando alguns temas a fim de observar a semelhança ou a distinção entre eles (Milho e Lavoura; Pasto e Pasto sujo; Eucalyptus e Pinus; Pinus, Eucalyptus e Mata nativa; Lavoura, Milho, Pasto e Pasto sujo, Figura 3).




Figura 3: Espectros de refletância das 156 bandas originais por classe temática.

Separabilidade das classes

A partir da identificação da assinatura espectral de cada classe (ou tema) é possível calcular a separabilidade entre as classes analisadas: quanto mais bem definidas as classes, do ponto de vista de sua diferenciação espectral, melhor será a classificação. A análise de separabilidade foi feita através da determinação da distância Jeffries-Matushita (JM) e da Divergência Transformada (DT); posteriormente foi realizada análise do resultado da classificação, a partir da matriz de contingência, ou matriz de confusão, gerada para cada tentativa de classificação.

O resultado da análise da separabilidade das classes indica que há boa separabilidade entre todos os pares de classes examinadas. Todos os pares de classes atingiram índices de JM e DT acima de 1,9, suficiente para a separabilidade entre as classes.

Tabela 03: Índices de separabilidade das classes com base na transformação TC (com limite espectral entre 426nm e 620nm; 925nm e 1003nm; 1638nm e 1739nm):

Pares de classes comparados	Jeffries-Matushita	Divergência transformada
Pasto sujo x Pasto	0.6220	0.7228
Eucalyptus x Pinus	1.4809	1.5998
Milho x Pasto	1.5053	1.9333
Lavoura x Milho	1.6453	1.8486
Milho x Pasto sujo	1.7218	1.9991
Lavoura x Pasto	1.7588	1.8788
Lavoura x Pasto sujo	1.8147	1.9672
Milho x Mata nativa	1.8293	1.9972

Para detalhar ainda mais os temas, foram feitos diversos procedimentos com as bandas originais. Duas transformações reduzem a quantidade das 40 bandas utilizadas, eliminando dados redundantes, a transformação Tasseled Cap (TC) e dos Principais Componentes (PC). Ambas foram realizadas a partir do conjunto de 40 bandas acima mencionado. Nas Tabelas 4 e 5 seguir, encontram-se os resultados

obtidos das duas transformações (TC e PC), quanto à separabilidade das classes baseada nas bandas Greenness, Brighthness e Third da transformação Tasseled Cap e nas 3 primeiras principais componentes. Nestas tabelas estão apresentados os somente os pares comparados que apresentaram índice de JM abaixo de 1.9.

Tabela 04: Índices de separabilidade das classes com base na transformação PC (com limite espectral entre 426nm e 620nm; 925nm e 1003nm; 1638nm e 1739nm):

Pares de classes comparados	Jeffries-Matushita	Divergência transformada
Pasto sujo x Pasto	0.3992	0.4535
<i>Eucalyptus</i> x Pasto sujo	0.4044	0.4379
Pasto x <i>Pinus</i>	0.4280	0.5008
<i>Eucalyptus</i> x Pasto	0.5856	0.7535
<i>Eucalyptus</i> x <i>Pinus</i>	0.7266	1.0340
<i>Eucalyptus</i> x Milho	0.7517	0.9432
Milho x Pasto sujo	0.9197	1.3248
Lavoura x Milho	1.0344	1.6196
Milho x Pasto	1.1095	1.8775
Milho x <i>Pinus</i>	1.2271	1.9694
<i>Eucalyptus</i> x Lavoura	1.4730	1.8726
Lavoura x Pasto sujo	1.4972	1.9207
<i>Eucalyptus</i> x Mata nativa	1.6113	1.9523
Lavoura x Pasto	1.6480	1.9828
Pasto sujo x <i>Pinus</i>	1.6453	0.5215
Milho x Mata nativa	1.6654	1.9987
Lavoura x <i>Pinus</i>	1.7179	1.9890
Mata nativa x Pasto sujo	1.8615	1.9823

Classificação

A acurácia e a confiabilidade da classificação digital de imagens dependem de vários fatores: da escolha de áreas de treinamento representativas, compostas por pixels com características similares, distribuídas, por sua vez em classes de boa separabilidade espectral (VIBRANS, 2003). Essas informações devem ser estimadas, para legitimar a eficiência da classificação.

Tabela 5: Limiares de probabilidade utilizados na classificação MaxVer da imagem.

Tema/classe	Limiar
Lavoura	0.5
Mata nativa	0.5
Milho	0.7
Pasto	0.7
Pasto Sujo	0.5
<i>Pinus</i>	0.6
<i>Eucalyptus</i>	0.5
Sombra	0.5

Com o classificador da Máxima Verossimilhança foram testados vários limiares de probabilidade, tanto gerais (iguais para todas as classes), como individuais (para cada classe), para obter melhores resultados em termos de acuracidade, comissão e omissão de cada classificação. Os limiares

individuais aplicados na classificação final constam na Tabela 6.

Num primeiro momento, o critério de avaliação foi à análise da matriz de confusão, que quantifica as variações entre a verdade em campo e a imagem classificada. O resultado mostrou acerto médio da classificação da imagem de 100%, com índice Kappa 1,0.

A matriz de confusão na diagonal atingiu acerto de 100% para todos os temas, bem como, mostrou valores de comissão (percentual de inclusão incorreta de pixels de outras classes) e omissão (percentual de pixels da respectiva classe não classificadas corretamente) insignificantes. A acuracidade de produtor e acuracidade de usuário por classe temática da imagem classificada apresentou acerto de 100% para todos os temas. Apesar deste ótimo resultado encontrado, a imagem com a classificação realizada não apresentou um mapeamento satisfatório da realidade terrestre, mostrando algumas incoerências óbvias, como mostra a Figura 4.

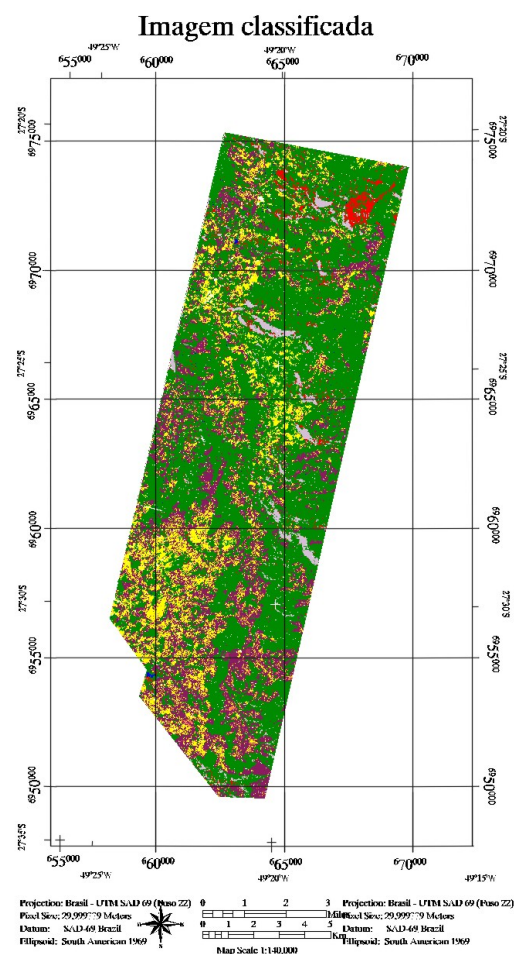


Figura 4: Imagem classificada.

A Tabela 9 mostra os dados quantitativos da cobertura florestal e uso do solo (resultados da

classificação MaxVer) da imagem classificada em hectare e em valores percentuais.

Tabela 6: Resultado da classificação supervisionada MaxVer da imagem Hyperion:

Classes	Área em hectares	%
Lavoura	193,77	1,13
Mata nativa	9.909,03	57,75
Milho	2.107,41	12,28
Pasto	3.738,81	21,79
Pasto Sujo	45,45	0,26
Pinus	404,81	2,36
Eucalyptus	33,30	0,19
Sombra	431,81	2,52
Não classificado	294,21	1,71
Área total	17.158,6	100,00

Através dos resultados obtidos podemos dizer que as áreas cobertas por vegetação natural dominam a imagem, somente este tema soma 57% da superfície na imagem. Pastagens ocupam uma superfície em torno de 21%. O Eucalyptus e o Pasto sujo nesta área representam menos que 1% da área total e foram os temas menos representativos.

Índices de vegetação e transformações de bandas

Os índices de vegetação servem para melhor avaliar o estado da vegetação, reduzir os aspectos topográficos, melhorar a visualização das diferenciações na reflectância de determinados alvos, além de refletir indiretamente o estado da vegetação, influenciado pelas condições do meio ambiente. A maior parte baseia-se na diferença entre a absorção máxima da radiação no vermelho com a reflexão máxima da radiação no infravermelho próximo.

Na Figura 5 pode-se analisar o resultado obtido quanto à média de todos os índices aplicados. Após a aplicação dos índices foram realizadas 2 transformações de bandas, a Tasseled Cap (TC) e a Transformação por Principais Componentes (TPC).

Na transformação TC foi realizada duas vezes, uma transformação com todas as 156 bandas e outra com as 40 bandas selecionadas (com limite espectral entre 426nm e 620nm; 925nm e 1003nm; 1638nm e 1739nm). O melhor resultado foi encontrado com a transformação usando a seleção das bandas, apresentando melhor separabilidade entre os temas.

A Transformação por Principais Componentes foi aplicada somente sobre as 40 bandas selecionadas; o resultado, em termos de separabilidade dos temas, foi inferior ao encontrado na transformação TC.

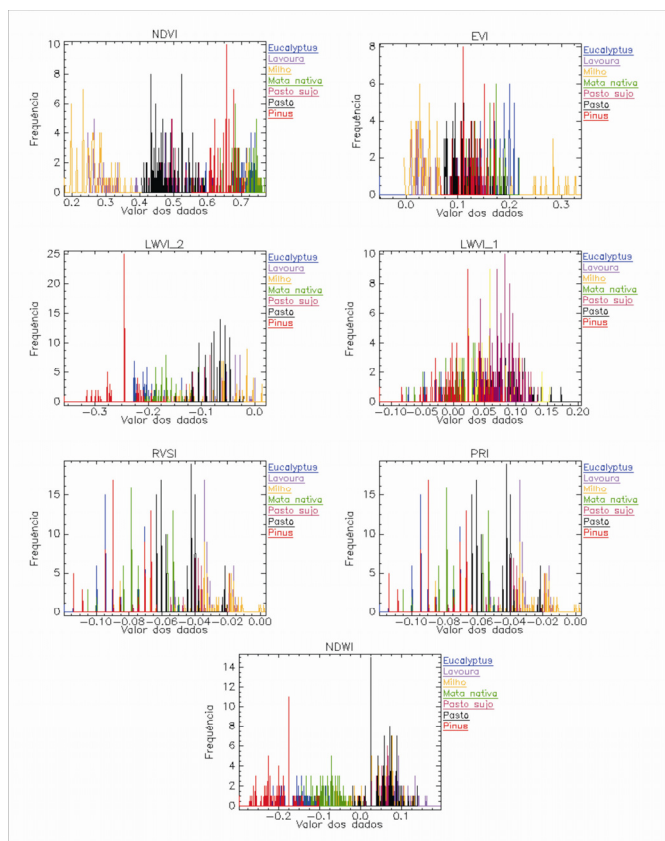


Figura 5: Histogramas das áreas de treinamento das classes temáticas nas bandas dos índices de vegetação utilizados.

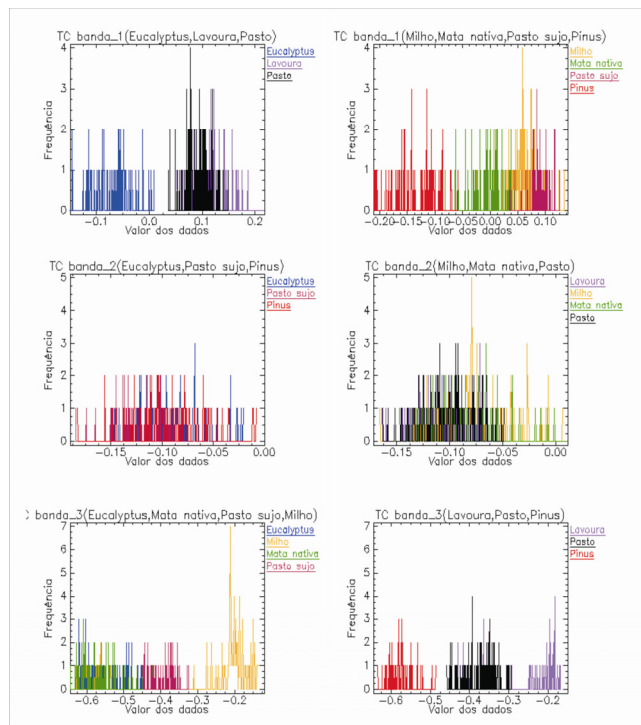


Figura 6: Histogramas da transformação TC por banda e tema.

Nas Figuras 6 e 7 constam os histogramas com os resultados das três bandas geradas pela

transformação TC e das três primeiras bandas da transformação TPC.

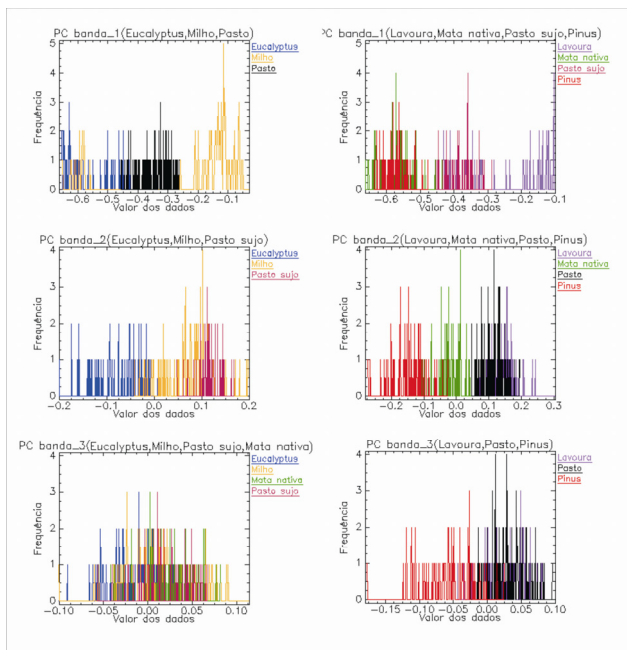


Figura 7: Histogramas da transformação TPC por banda e temas.

4. Conclusão

A análise visual dos espectros de reflectância e das feições de reflectância das classes examinadas com dados do sensor Hyperion permitiu uma certa distinção entre as áreas da maioria das diversas classes colhidas em campo. A aplicação de algumas transformações de bandas melhorou o nível desta distinção, mostrando um importante avanço em relação aos resultados obtidos com base em dados multiespectrais (VIBRANS, 2003).

Os melhores resultados apresentaram os temas com uma menor variabilidade espectral (menor desvio padrão e maiores índices JM e DT, o que significa maior homogeneidade – Mata nativa, Lavoura, Milho). Em virtude da maior quantidade de informação espectral fornecida pelo sensor Hyperion, a acurácia de classificação para a imagem deste sensor foi superior a alcançada em muitos outros trabalhos obtidos com dados dos sensores Landsat TM e ETM+.

O cálculo da separabilidade entre as classes através da distância Jeffries-Matushita (JM) e da Divergência Transformada (DT), extraídas das bandas originais e de algumas bandas sintéticas, mostraram claramente o potencial das imagens hiperespectrais quanto à nítida separabilidade das classes estudadas.

Foram avaliadas as transformações Tasseled Cap e das Principais Componentes e ainda nove índices

de transformações de bandas, com objetivo de escolher as bandas sintéticas mais adequadas para esta cena, quanto à capacidade de distinguir as classes temáticas. Os índices atenderam a expectativa para a separabilidade entre as classes. Por apresentarem resultados parecidos, ressalta-se o NDVI como um índice de separabilidade para análise de informação que gerou resultados melhores neste estudo. A transformação por TC apresenta resultados sensivelmente melhores que os outros índices e transformações de bandas, podendo ser verificada nos resultados obtidos por este índice na Figura 6, e também através da separabilidade encontrada por esta transformação.

A utilização de todas as 156 bandas para a realização da transformação TC, ocasionou o processamento de um grande número de dados que não melhorou a separação entre as classes; pelo contrário, gerou confusão entre as classes “pasto” e “pasto sujo”, portanto ocasionando uma dificuldade adicional na separação das classes. Utilizando a seleção de 40 bandas (com limite espectral entre 426nm e 620nm; 925nm e 1003nm; 1638nm e 1739nm) o resultado obtido mostrou-se muito melhor quanto à separabilidade dos temas, embora continue existindo certa dificuldade de distinção espectral entre as classes “pasto” e “pasto sujo”.

Na classificação supervisionada, no entanto, não se obteve um resultado satisfatório, causado provavelmente pelo número insuficiente de pixels de alguns temas, resultando em muitas áreas não classificadas, apesar de bons resultados da matriz de confusão, com baixos níveis de omissão e comissão.


O presente trabalho mostrou o potencial das imagens hiperespectrais do sensor Hyperion para a distinção de diversas formas da cobertura vegetal e, principalmente, o potencial dos índices de vegetação e das demais transformações de bandas aplicadas neste estudo. Mas diante da necessidade de um maior aprofundamento dos estudos e para poder classificar melhor os temas propostos e mapeá-los com segurança, é necessário a utilização de um conjunto maior de áreas de treinamento, com maior número de pixels por classe que seja suficientemente representativo para todos os temas em estudo.

5. Agradecimentos: este trabalho foi apoiado pelo Conselho de Desenvolvimento Científico e Tecnológico – CNPq, no Programa Institucional de Bolsas de Iniciação Científica – PIBIC na Universidade Regional de Blumenau.

6. Referências

1. Accioly, L. J. O.; Garçon, E. A. M.; Barros, M. R.; Botelho, F. Avaliação de alvos em áreas sob desertificação no semi-árido paraibano com bases nos sensores Hyperion e Landsat 7 ETM+. In: Simpósio Brasileiro de Sensoriamento Remoto, 12. (SBSR), 16-21 abr. 2005, Goiânia. Anais... São José dos Campos: INPE, 2005. Artigos, p. 347-353.
2. Alixandrini Jr, M. J. O potencial das imagens hiperespectrais. In: Congresso Brasileiro de Cadastro Técnico Multifinalitário (COBRAC), 10-14 Out. 2004, Santa Catarina. Florianópolis: UFSC, 2004.
3. Baptista, G. M. M. Validação da modelagem de seqüestro de carbono para ambientes tropicais do cerrado, por meio de dados Aviris e Hyperion. In: Simpósio Brasileiro de Sensoriamento Remoto, 11. (SBSR). 05-10 abr. 2003, Minas Gerais. Anais... Belo Horizonte: INPE, 2003. Artigos, p. 1037-1044.
4. Epiphânio, J. C. N.; Almeida Jr., A. C.; Formaggio, A. R. Desenvolvimento do trigo avaliado com dois índices de vegetação. In: Simpósio Brasileiro de Sensoriamento Remoto, 8. (SBSR). 14-19 abr. 1996, Bahia. Anais... Salvador: INPE, 1996. Artigos, p. 19-24.
5. Galvão, L. S.; Formaggio, A. R.; Tisot, D. A. Discriminação de variedades de cana-de-açúcar com dados hiperespectrais do sensor EO-1/Hyperion. In: Simpósio Brasileiro de Sensoriamento Remoto, 12. (SBSR), 16-21 abr. 2005, Goiânia. Anais... São José dos Campos: INPE, 2005. Artigos, p. 381-388.
6. Shimabukuro, Y. E.; Miura, T.; Huete, A. et al. Análise dos dados hiperespectrais do EO-1 obtidos sobre a Floresta Nacional de Tapajós no Estado do Pará. In: Simpósio Brasileiro de Sensoriamento Remoto, 11. (SBSR), 5-10 abr. 2003, Belo Horizonte. Anais... São José dos Campos: INPE, 2003. Artigos, p. 1099-1106.
7. Tisot, D. A.; Formaggio, A. R.; Galvão, L. S.; Rennó, C. D. Dados Hyperion e ETM+ na classificação de alvos agrícolas com diferentes níveis de distinção espectral. In: Simpósio Brasileiro de Sensoriamento Remoto, 12. (SBSR), 16-21 abr. 2005, Goiânia. Anais... São José dos Campos: INPE, 2005. Artigos, p. 439-446.
8. Huete, A. Sensoriamento Remoto Aplicado ao estudo da vegetação. In: Simpósio Brasileiro de Sensoriamento Remoto, 13. (SBSR). 21-26 abr. 2007, Santa Catarina. Florianópolis: INPE, 2007.
9. Meneses, P. R.; Netto, J. S. M. Sensoriamento Remoto: reflectância dos alvos naturais. Brasília, DF: UnB; Planaltina: Embrapa Cerrados, 2001. 262p.
10. Ponzoni, F. J.; Shimabukuro, Y. E. Sensoriamento Remoto no Estudo da Vegetação. SP. São José dos Campos: A. Silva Vieira Ed., 2007. 127p.
11. Richards, J.A. Remote sensing digital image analysis: an introduction. 2. ed. Berlin: Springer-Verlag, 1993. 340p.
12. Vibrans, A. C. A cobertura florestal da bacia do Rio Itajaí - elementos para uma análise histórica. 2003. 240f. Tese (Doutorado em Geografia) - UFSC, Florianópolis, 2003.

ANEXO-I



Imagens de todos os índices de vegetação gerados, em tons de cinza (com uma banda, “Grey Scale”).