

Análise de Componentes Principais e Modelo Linear de Mistura na discriminação de classes de vegetação na Mata Atlântica

Simone Rodrigues Freitas¹
Carla Bernadete Madureira Cruz¹

¹ Universidade Federal do Rio de Janeiro - Departamento de Geografia
Laboratório de Geomorfologia Marinha - Grupo de Sensoriamento Remoto
21949-900 - Rio de Janeiro - RJ, Brasil
sfreitas@biologia.ufrj.br, cmad@domain.com.br

Abstract. Because of their particular characteristics, such as relief and heterogeneity, studies done in Atlantic Forest sites must test the available techniques and develop others that best fit to their conditions. This paper aims to evaluate the performance of three different band combination used in automatic classification of vegetation, considering how vegetation classes are spectrally separable through discriminant function analysis, using a Landsat ETM+ image, in an Atlantic Rainforest site, SE Brazil. Vegetation cover classification was done using the same procedure and the same training areas, but a different bands combination: 1) using 6 spectral bands; 2) using 4 spectral bands and mixture components; 3) using mixture components and 3 principal components. We defined 6 classes: pasture, grassland, marsh, herbaceous shrub, woody shrub, and forest. Regarding the percentage of correct allocations, the combination of PCA and LMM showed the best performance in spectrally separating vegetation classes. We also discussed some constraints in the use of Landsat ETM+ sensor.

Palavras-chave: Landsat, resolution, forest patches, tropical forest, resolução, fragmentos florestais, floresta tropical.

1. Introdução

No Brasil, a maioria dos estudos em sensoriamento remoto foram feitos na Floresta Amazônica e no Cerrado (Saatchi et al., 1997; Shimabukuro et al., 1998; Carvalho et al., 2003; Miura et al., 2003; Lu et al., 2003; Vieira et al., 2003). No entanto, estudos feitos em outras fitofisionomias, como é o caso da Mata Atlântica, precisam testar as técnicas existentes e desenvolver outras que melhor se adequem às suas condições particulares, tais como relevo e heterogeneidade de usos da terra. A maioria dos fragmentos de Mata Atlântica se encontra em áreas montanhosas úmidas acarretando problemas relacionados a sombras devido a nuvens, topografia e dossel da floresta. As sombras causadas por nuvens podem ser removidas depois da classificação, porém, as sombras no interior da floresta podem induzir a confusões entre vegetação com folhas de alta concentração de água, p.ex. brejos (Bowker et al., 1985; Campbell, 1996; Lacruz e Santos, 1997; Moreira, 2001; García-Haro e Sommer, 2002). Devido a heterogeneidade do uso da terra, as imagens de satélite são formadas por pixels pequenos e compostos por muitos alvos, causando mistura. Na Mata Atlântica, os tipos de uso são diversos no entorno da floresta: pasto, cultivos anuais e perenes, vegetação secundária, solos exposto e queimado, áreas urbanas e rurais. Alguns desses usos apresentam uma assinatura espectral característica, como pasto e floresta, enquanto que em outros, a resposta depende do tamanho do alvo dominante, p.ex. casas de campo cercadas por algumas árvores, cultivos diversos e pasto.

O Modelo Linear de Mistura é uma técnica usada para reduzir a mistura do pixel, quantificando as proporções de elementos puros que constituem o pixel misturado (Shimabukuro e Smith, 1991). Essa técnica tem sido usada, por exemplo, para mapear áreas desmatadas da Floresta Amazônica (Shimabukuro et al., 1998; Mello et al., 2003a). Outras técnicas são usadas para reduzir a variação das respostas espectrais sem considerar as

propriedades físicas do alvo, tal como a Análise de Componentes Principais (Crósta, 1992; Lillesand e Kiefer, 1994). Nessa técnica, o primeiro componente usualmente representa o albedo e as sombras causadas pela topografia, o que pode aprimorar a classificação em áreas montanhosas de Mata Atlântica.

O melhor desempenho em distinguir classes de uso da terra depende das características do sensor (resoluções espacial, espectral e radiométrica), das técnicas usadas durante o processamento da imagem (erro no georreferenciamento, método de classificação, tamanho e heterogeneidade das áreas de treinamento) e da resposta espectral dos alvos (Campbell, 1996; Foody, 2002; Smith et al., 2003; Powell et al., 2004). Em áreas heterogêneas constituídas por amostras pequenas e onde as classes de uso da terra dominantes, representam um gradiente contínuo, desde pasto até floresta secundária, é importante avaliar como as classes se separam espectralmente em toda a cena.

O objetivo desse trabalho é avaliar o desempenho de três combinações de bandas diferentes usadas na classificação automática da cobertura vegetal, através das técnicas Modelo Linear de Mistura e Análise de Componentes Principais, considerando como as classes de vegetação se separam espectralmente através da análise discriminante, usando uma imagem Landsat ETM+ de uma área de Mata Atlântica, no Estado do Rio de Janeiro.

2. Material e Métodos

A área de estudo é a bacia do Rio Guapiaçú, localizada nos Municípios de Guapimirim e Cachoeiras de Macacu ($22^{\circ}39'36''\text{S}$, $43^{\circ}01'02''\text{W}$ e $22^{\circ}21'13''\text{S}$, $42^{\circ}39'46''\text{W}$), no Estado do Rio de Janeiro, sudeste do Brasil (**Figura 1**). A bacia tem $573,54 \text{ km}^2$ e a principal cobertura do solo é a floresta tropical úmida densa (Rizzini, 1979; IBGE, 1991; Amador, 1997). Situa-se na porção atlântica da Serra do Mar, compreendendo morros e baixadas até a Baía de Guanabara. A maioria dos fragmentos florestais ocorre em topos de morro de 100 a 200m de altitude, sendo circundados por pastagens e cultivos. A floresta é densa e úmida, altamente diversa, atingindo cerca de 45m de altura formando três estratos: árvores emergentes, sobre o dossel principal de 5 a 10m, com árvores menores sombreadas abaixo deste (Mello et al., 2003b).

Foi utilizada uma imagem Landsat 7 ETM+ de 28 de Fevereiro de 2000 (órbita 217/ponto 76). As seis bandas espectrais com 30m de resolução espectral foram georreferenciadas através de mapas topográficos, obtendo a precisão de 0,50 pixel. Adotou-se a projeção UTM com longitude de origem em $45^{\circ}00'00''\text{W}$ e datum SAD69. Todo o processamento da imagem foi feito no SPRING. Para corrigir a influência atmosférica, aplicou-se o método aprimorado de Chavez (Chavez, 1996) que tem mostrado bons resultados (Pax-Lenney et al., 2001). Em seguida, o Modelo Linear de Mistura foi aplicado usando as seis bandas corrigidas, gerando os componentes de mistura solo, vegetação e sombra (Shimabukuro e Smith, 1991; Shimabukuro et al., 1998; Aguiar et al., 1999). A Análise de Componentes Principais também foi aplicada usando as seis bandas corrigidas, gerando três componentes principais (Crósta, 1992; Lillesand e Kiefer, 1994).

A classificação da vegetação foi feita usando o mesmo procedimento e as mesmas áreas de treinamento, mas com três combinações de bandas distintas. O procedimento de classificação se constituiu da segmentação da imagem por regiões (limite de similaridade = 8 e área mínima = 10), seguida pelo algoritmo não-supervisionado (ISOSEG) e pela classificação supervisionada através do método Bhattacharya (INPE/DPI, 2004). As áreas de treinamento foram selecionadas durante idas a campo, usando como base as regiões da imagem segmentada.

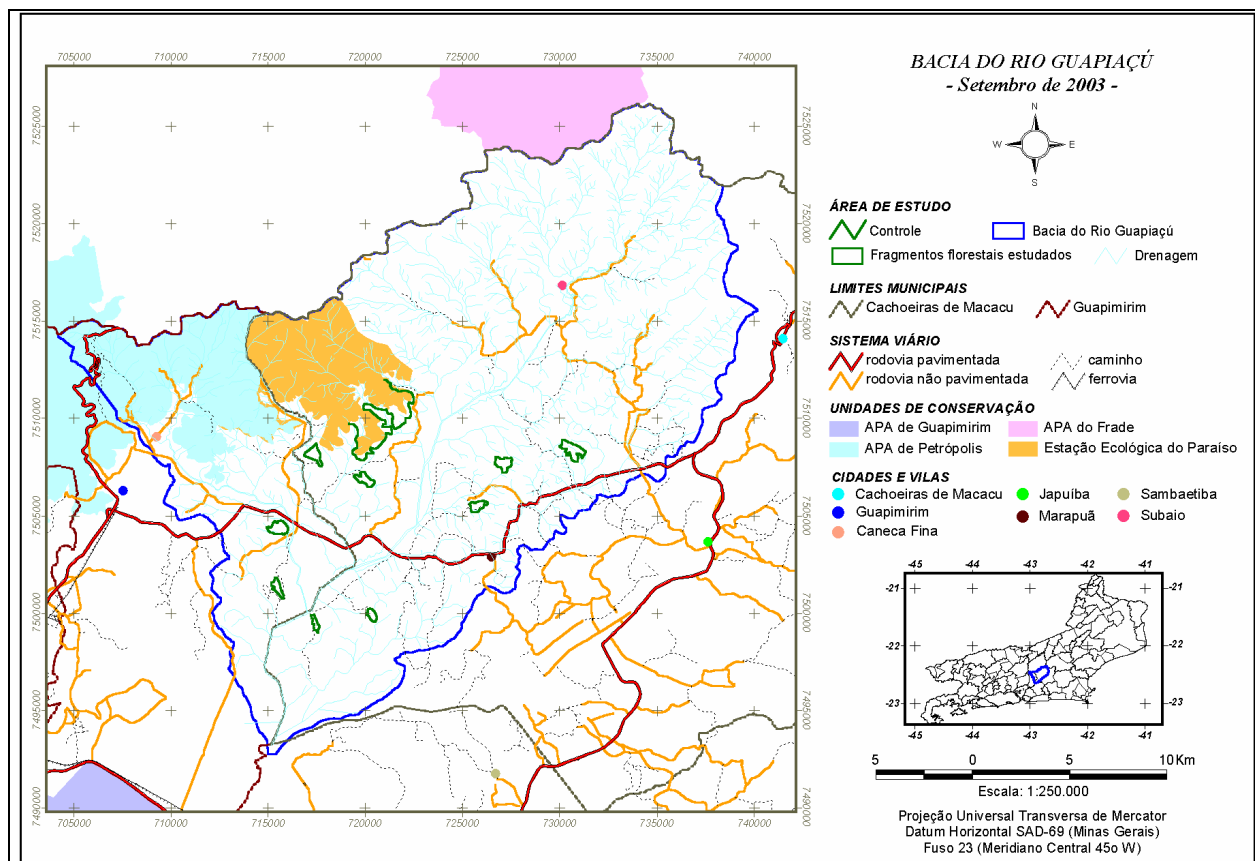


Figura 1. A área de estudo e sua localização no Estado do Rio de Janeiro.

Foram usadas três combinações de bandas distintas no procedimento de classificação: (1) 123457chz, com seis bandas espectrais (bandas 1, 2, 3, 4, 5 e 7); (2) 3457mix, com quatro bandas espectrais associadas à vegetação (bandas 3, 4, 5 e 7) e os componentes de mistura (solo, vegetação e sombra); (3) Pca123mix, com os componentes de mistura (solo, vegetação e sombra) e os três primeiros componentes principais (PC1, PC2 e PC3). A segunda combinação de bandas (3457mix) visou aprimorar o reconhecimento de classes de vegetação, tais como eucalipto, café, brejo, floresta (Vicens et al., 1998; Agarez et al., 2001). No entanto, os componentes de mistura apresentam alta variância quando usados com as bandas originais, podendo causar piores resultados (Aguiar et al., 1999). Dessa forma, a terceira combinação de bandas visou reduzir o tempo de processamento e incluir a maior parte da informação sobre a cobertura vegetal, evitando o aumento da variância. Além disso, a união da Análise de Componentes Principais ao Modelo Linear de Mistura teve como objetivo aprimorar a classificação através do controle da maior parte das fontes da heterogeneidade na área de estudo: topografia e pixels misturados.

Foram definidas seis classes de vegetação: pasto, pasto degradado, brejo, capoeira herbácea, capoeira arbustiva e floresta (**Figura 2**) e 15 áreas de treinamento para pasto, 18 para pasto degradado, seis para brejo, 13 para capoeira herbácea, 17 para capoeira arbustiva e 38 para floresta. A seleção das áreas de treinamento dependeu do tamanho e da forma das regiões e da frequência de ocorrência na área de estudo. Brejo, por exemplo, foi menos frequente e menor do que floresta na bacia do Rio Guapiaçú. Depois da classificação de cada combinação de bandas, extraiu-se os valores de reflectância média de cada região, de cada banda, representando as classes de vegetação, através do programa Idrisi 32. Antes da extração, as bandas foram convertidas de níveis de cinza para reflectância no SPRING (Luiz et al., 2003). Aplicou-se a análise discriminante, através do programa STATISTICA, para

avaliar como as classes se separavam espectralmente (Manly, 1994; Valentin, 2000). A análise discriminante é um método estatístico multivariado usado para avaliar a possibilidade de separar dois ou mais grupos de indivíduos, dadas as várias medidas tomadas desses indivíduos (Manly, 1994). Nesse trabalho, os grupos foram as classes de vegetação, os indivíduos foram as regiões segmentadas, e as medidas foram a reflectância média de cada banda usada na combinação. Assim, a análise discriminante foi feita para cada combinação de bandas, resultando em um teste de significância e uma matriz de classificação, onde é possível quantificar a porcentagem de classes corretamente classificadas no total e para cada classe.



Figura 2. Exemplos da seis classes de vegetação na área de estudo.

3. Resultados e Discussão

A análise discriminante da combinação de bandas usando seis bandas (123457chz) foi capaz de separar espectralmente as classes de vegetação ($F=643.15$, $p<0.000$), embora com uma baixa porcentagem total de classes corretamente classificadas (64.50%) (**Tabela 1**). Essa combinação de bandas mostrou as maiores porcentagens de acertos para as classes: capoeira herbácea (75.04%), floresta (78.34%) e pasto (74.48%); e as menores porcentagens de acerto para as classes: brejo (25.73%), capoeira arbustiva (59.92%) e pasto degradado (70.08%) (**Tabela 1**).

Para a combinação de bandas usando as quatro bandas relacionadas à vegetação (bandas 3, 4, 5 e 7) e os componentes de mistura (solo, vegetação e sombra) (3457mix), a análise discriminante também conseguiu separar espectralmente as classes de vegetação ($F=690.35$, $p<0.000$), embora tenha apresentado a menor porcentagem total de acertos (64.08%) (**Tabela 1**). A combinação 3457mix obteve a maior porcentagem de acerto apenas para a classe brejo (39.79%); e as menores porcentagens de acerto para as classes: floresta (67.75%) e pasto (55.59%) (**Tabela 1**).

Finalmente, para a combinação de bandas usando os componentes de mistura e os três primeiros componentes principais (pca123mix), a análise discriminante também foi capaz de

separar espectralmente as classes de vegetação ($F=731.85$, $p<0.000$), obtendo a maior porcentagem total de classes corretamente classificadas (65.02%) (**Tabela 1**). A combinação *pca123mix* obteve as maiores porcentagens de acerto para as classes: capoeira arbustiva (75.81%) e pasto degradado (89.40%); e a menor porcentagem de acerto apenas para a classe capoeira herbácea (56.63%) (**Tabela 1**).

Considerando a porcentagem de acertos no total e por classe, a combinação *pca123mix* mostrou o melhor desempenho na distinção entre as classes de vegetação. No entanto, se o estudo pretende usar apenas uma das classes, p.ex. floresta/não-floresta, sugerimos a combinação que obteve melhor desempenho na classe em questão, no caso, *123457chz*.

Vale notar que todas as combinações mostraram altas sobreposições entre as classes: brejo e capoeira herbácea, brejo e capoeira arbustiva, floresta e capoeira arbustiva, pasto degradado e capoeira herbácea, e pasto e capoeira herbácea (**Tabela 1**). Essas sobreposições representam o gradiente contínuo de biomassa formado por essas classes de vegetação: pasto-pasto degradado-capoeira herbácea-capoeira arbustiva-floresta. Powell et al. (2004) encontraram um gradiente semelhante formado por pasto-floresta secundária-floresta primária na Floresta Amazônica. Devido ao conteúdo úmido em suas folhas, o brejo se sobrepôs às classes com relativamente mais biomassa foliar, como as capoeiras. Nenhuma das combinações de bandas foi capaz de discriminar entre os efeitos da biomassa foliar daqueles causados pelo conteúdo úmido das folhas sobre a reflectância.

Tabela 1. Matriz de classificação mostrando a porcentagem de classes corretamente classificadas (para cada classe e no total), na análise discriminante feita para as combinações de bandas usando seis bandas (*123457chz*), usando as quatro bandas relacionadas à vegetação (bandas 3, 4, 5 e 7) e os componentes de mistura (solo, vegetação e sombra) (*3457mix*), e usando os componentes de mistura e os três primeiros componentes principais (*pca123mix*).

Combinação de bandas	Classes	brejo	capoeira herbácea	capoeira arbustiva	floresta	pasto degradado	pasto
123457chz	brejo	25.73%	36.91%	27.07%	1.23%	5.26%	3.80%
3457mix		39.79%	20.34%	35.80%	1.55%	0.57%	1.95%
<i>pca123mix</i>		36.33%	40.30%	18.88%	2.17%	1.20%	1.12%
123457chz	capoeira herbácea	8.89%	75.04%	5.87%	0.08%	8.89%	1.24%
3457mix		9.67%	65.00%	5.36%	0.63%	7.52%	11.83%
<i>pca123mix</i>		15.86%	56.63%	9.57%	0.94%	8.63%	8.37%
123457chz	capoeira arbustiva	3.10%	11.01%	59.92%	16.28%	0.99%	8.70%
3457mix		6.60%	6.65%	72.94%	8.51%	0.11%	5.19%
<i>pca123mix</i>		10.36%	5.27%	75.81%	5.90%	0.29%	2.37%
123457chz	floresta	1.94%	0.90%	18.07%	78.34%	0.30%	0.45%
3457mix		2.22%	0.13%	25.27%	67.75%	0.06%	4.57%
<i>pca123mix</i>		2.89%	1.32%	21.90%	68.02%	0.00%	5.87%
123457chz	pasto degradado	0.33%	28.82%	0.66%	0.11%	70.08%	0.00%
3457mix		0.32%	17.72%	0.00%	0.00%	80.99%	0.97%
<i>pca123mix</i>		0.09%	10.23%	0.09%	0.00%	89.40%	0.19%
123457chz	pasto	0.00%	14.94%	7.59%	1.38%	1.61%	74.48%
3457mix		0.87%	30.32%	10.79%	0.78%	1.65%	55.59%
<i>pca123mix</i>		0.00%	19.58%	11.11%	0.00%	0.97%	68.33%
123457chz	Total	64.50%					
3457mix		64.08%					
<i>pca123mix</i>		65.02%					

Para melhorar a discriminação do brejo, sugerimos o uso da classificação orientada ao objeto, usando textura, tipo de solo e declividade (Batz, 2004; Walter, 2004). Já no caso da floresta, tendo como base a similaridade fisionômica e a alta sobreposição entre as classes, o agrupamento com a classe capoeira arbustiva parece ser uma solução (Freitas, 2004). Dessa forma, o número de classes reduziria para cinco, produzindo uma classificação mais grosseira.

A dificuldade encontrada para distinguir as classes que compõem o gradiente contínuo formado entre as classes de vegetação, em parte, se deve as limitações do sensor Landsat ETM+, quanto às resoluções espacial, radiométrica e espectral, em paisagens altamente heterogêneas, como as da Mata Atlântica. Lacruz & Santos (1997) encontraram um problema semelhante em matas ripárias, devido a sua forma estreita, dificultando a obtenção de áreas de treinamento representativas. Na medida em que a acurácia decresce com o aumento da heterogeneidade e da fragmentação, se faz necessário o uso de outro sensor para reduzir esse efeito (Smith et al., 2003; Powell et al., 2004). Dessa forma, o uso de imagens com maior resolução espacial, radiométrica e/ou espectral, p.ex. ASTER e AVIRIS, parece ser uma solução para distinguir mais claramente as classes de vegetação que compõem o gradiente contínuo formado em áreas de Mata Atlântica.

4. Referências

- Agarez, F. V.; Vicens, R. S.; Cruz, C. B. M.; Nogueira, C. R.; Garay, I. Utilização de Índice de vegetação na classificação integrada de fragmentos florestais em Mata Atlântica de Tabuleiros no Município de Sooretama, ES. In: X Simpósio Brasileiro de Sensoriamento Remoto, 2001, Foz do Iguaçu. **Anais**. São José dos Campos: INPE, 2001. p. 1-9. Repositório da URLib: <dpi.inpe.br/lise/2001/09.24.08.56>. Disponível em: <<http://iris.sid.inpe.br:1908/rep/dpi.inpe.br/lise/2001/09.24.08.56>>.
- Aguiar, A. P. D.; Shimabukuro, Y. E.; Mascarenhas, N. D. A. Use of synthetic bands derived from mixing models in the multispectral classification of remote sensing images. **International Journal of Remote Sensing**, v. 20, p. 647-657, 1999.
- Amador, E. S. **Baía de Guanabara e ecossistemas periféricos: homem e natureza**. Rio de Janeiro: E. S. Amador, 1997. 539 p.
- Batz, M.; Benz, U.; Dehghani, S.; Heynen, M.; Hölting, A.; Hofmann, P.; Lingenfelder, I.; Mimler, M.; Sohlbach, M.; Weber, M.; Willhauck, G. **eCognition professional: user guide 4**, 2004. Disponível em <www.definiens-imaging.com>. Acesso em: 20/06/2004.
- Bowker, D. E.; Davis, R. E.; Myrick, D. L.; Stacy, K.; Jones, W. T. **Spectral reflectances of natural targets for use in remote sensing studies**. RP-1139. Washington: NASA, 1985. 184 p.
- Campbell, J. B. **Introduction to remote sensing**. New York: The Guilford Press, 1996. 622 p.
- Carvalho, A. P. F.; Bustamante, M. M. C.; Guimarães, R. F.; Júnior, O. A. C. Classificação de padrões de vegetação na região de transição entre o Cerrado e a Floresta Amazônica. In: Simpósio Brasileiro de Sensoriamento Remoto, 11. 2003, Belo Horizonte. **Anais**. São José dos Campos: INPE, 2003. p. 2679-2687. Repositório da URLib: <<http://iris.sid.inpe.br/sbsr/2002/11.19.10.19>>. Disponível em: <<http://iris.sid.inpe.br:1908/rep/iris.inpe.br/sbsr/2002/11.19.10.19>>.
- Chavez Jr., P. S. Image-based atmospheric corrections - revisited and improved. **Photogrammetric Engineering & Remote Sensing**, v. 62, p. 1025-1036, 1996.
- Crósta, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1992. 170 p.
- Foody, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, v. 80, p. 185-201, 2002.
- Freitas, S. R. **Modelagem de dados espectrais na análise de padrões de fragmentação florestal na bacia do Rio Guapiaçu (RJ)**. 2004. 373 p. Tese (Doutorado em Geografia) - Universidade Federal do Rio de Janeiro, Rio de Janeiro. 2004.

García-Haro, F. J.; Sommer, S. A fast canopy reflectance model to simulate realistic remote sensing scenarios. **Remote Sensing of Environment**, v. 81, p. 205-227, 2002.

IBGE. **Manual técnico da vegetação brasileira**. Rio de Janeiro: IBGE, 1991. 92 p.

INPE/DPI. **Tutorial de Geoprocessamento**, 2004. Disponível em <<http://www.dpi.inpe.br/spring/portugues/tutorial/index.html>>. Acesso em: 18/10/2004.

Lacruz, M. S. P.; Santos, J. R. Uso de la percepción remota como subsídio para inventários forestales en la amazonia brasileira. **Revista Selper**, v. 13, p. 24-28, 1997.

Lillesand, T. M.; Kiefer, R. W. **Remote sensing and image interpretation**. New York: John Wiley & Sons, 1994. 750 p.

Lu, D.; Moran, E.; Batistella, M. Linear mixture model applied to Amazonian vegetation classification. **Remote Sensing of Environment**, v. 87, p. 456-469, 2003.

Luiz, A. J. B.; Gütler, S.; Gleriani, J. M.; Epiphanyo, J. C. N.; Campos, R. C. Reflectância a partir do número digital de imagens ETM+. In: XI Simpósio Brasileiro de Sensoriamento Remoto, 2003, Belo Horizonte. **Anais**. São José dos Campos: INPE, 2003. p. 2071-2078. Repositório da URLib: <<http://iris.sid.inpe.br:1908/rep/ltid.inpe.br/sbsr/2002/10.10.19.00>>. Disponível em: <<http://iris.sid.inpe.br:1908/rep/ltid.inpe.br/sbsr/2002/10.10.19.00>>.

Manly, B. **Multivariate statistical methods: a primer**. London: Chapman & Hall, 1994. 215 p.

Mello, E. M. K.; Moreira, J. C.; Santos, J. R.; Shimabukuro, Y. E.; Duarte, V.; Souza, I. M.; Barbosa, C. C.; Souza, R. C. M.; Paiva, J. A. C. Técnicas de modelo de mistura espectral, segmentação e classificação de imagens TMLANDSAT para o mapeamento do desflorestamento da Amazônia. In: Simpósio Brasileiro de Sensoriamento Remoto, 11. 2003, Belo Horizonte. **Anais**. São José dos Campos: INPE, 2003a. p. 2807-2814. Repositório da URLib: <<http://iris.sid.inpe.br:1908/rep/ltid.inpe.br/sbsr/2002/11.04.09.08>>. Disponível em: <<http://iris.sid.inpe.br:1908/rep/ltid.inpe.br/sbsr/2002/11.04.09.08>>.

Mello, M. C. S.; Freitas, S. R.; Cerqueira, R. Estrutura da vegetação em fragmentos florestais de Mata Atlântica com base no sensoriamento remoto. In: VI Congresso de Ecologia do Brasil, 2. 2003, Fortaleza. **Anais**. Fortaleza: Editora da Universidade Federal do Ceará, 2003b. p. 133-134.

Miura, T.; Huete, A. R.; Ferreira, L. G.; Sano, E. E. Discrimination and biophysical characterization of cerrado physiognomies with EO-1 hyperspectral HYPERION. In: Simpósio Brasileiro de Sensoriamento Remoto, 11. 2003, Belo Horizonte. **Anais**. São José dos Campos: INPE, 2003. p. 1077-1082. Repositório da URLib: <<http://iris.sid.inpe.br:1908/rep/ltid.inpe.br/sbsr/2002/11.17.01.11>>. Disponível em: <<http://iris.sid.inpe.br:1908/rep/ltid.inpe.br/sbsr/2002/11.17.01.11>>.

Moreira, M. A. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação**. São José dos Campos: INPE, 2001. 252 p.

Pax-Lenney, M.; Woodcock, C. E.; Macomber, S. A.; Gopal, S.; Song, C. Forest mapping with a generalized classifier and Landsat TM data. **Remote Sensing of Environment**, v. 77, p. 241-250, 2001.

Powell, R. L.; Matzke, N.; Souza Jr., C.; Clark, M.; Numata, I.; Hess, L. L.; Roberts, D. A. Sources of error in accuracy assessment of thematic land-cover maps in the Brazilian Amazon. **Remote Sensing of Environment**, v. 90, p. 221-234, 2004.

Rizzini, C. T. Floresta Atlântica. In: Rizzini, C. T. **Tratado de Fitogeografia do Brasil: aspectos sociológicos e florísticos**. São Paulo: HUCITEC/EdUSP, 1979. p. 65-78.

Saatchi, S. S.; Soares, J. V.; Alves, D. S. Mapping deforestation and land use in Amazon rainforest by using SIR-C imagery. **Remote Sensing of Environment**, v. 59, p. 191-202, 1997.

Shimabukuro, Y. E.; Smith, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, p. 16-20, 1991.

Shimabukuro, Y. E.; Novo, E. M.; Ponzoni, F. J. Índice de vegetação e modelo linear de mistura espectral no monitoramento da região do Pantanal. **Pesquisa Agropecuária Brasileira**, v. 33, p. 1729-1737, 1998.

Smith, J. H.; Stehman, S. V.; Wickham, J. D.; Yang, L. Effects of landscape characteristics on land-cover class accuracy. **Remote Sensing of Environment**, v. 84, p. 342-349, 2003.

Valentin, J. L. **Ecologia numérica: uma introdução à análise multivariada de dados ecológicos**. Rio de Janeiro: Editora Interciência, 2000. 118 p.

Vicens, R. S.; Cruz, C. B. M.; Rizzini, C. M. Utilização de técnicas de sensoriamento remoto na análise da cobertura vegetal da Reserva Florestal de Linhares, ES, Brasil. In: IX Simpósio Brasileiro de Sensoriamento Remoto, 1998, Santos. **Anais**. São José dos Campos: INPE/SELPER, 1998. p. 12. Repositório da URLib: <sid.inpe.br/deise/1999/02.09.10.01>. Disponível em: <<http://iris.sid.inpe.br:1908/rep/sid.inpe.br/deise/1999/02.09.10.01>>.

Vieira, I. C. G.; Almeida, A. S.; Davidson, E. A.; Stone, T. A.; Carvalho, C. J. R.; Guerrero, J. B. Classifying successional forests using Landsat spectral properties and ecological characteristics in eastern Amazônia. **Remote Sensing of Environment**, v. 87, p. 470-481, 2003.

Walter, V. Object-based classification of remote sensing data for change detection. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 58, p. 225-238, 2004.