

## Desempenho de classificadores paramétrico e não paramétrico na classificação da fisionomia vegetal

Alexandre Curvelo de Andrade<sup>1</sup>

Cristiane Nunes Francisco<sup>2</sup>

Cláudia Maria Almeida<sup>3</sup>

INFORMS/CONDER<sup>1</sup>

Av. Edgard Santos, 936 Narandiba – CEP 41192-005- Salvador – Bahia, Brasil

[alexcurvandrade@gmail.com](mailto:alexcurvandrade@gmail.com)

<sup>2</sup> Universidade Federal Fluminense – UFF

EGG – Departamento de Análise Geoambiental – CEP 24210-346 – Niterói - RJ, Brasil

[crisnf@vm.uff.br](mailto:crisnf@vm.uff.br)

<sup>3</sup> Instituto Nacional de Pesquisas Espaciais - INPE

Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil

[almeida@dsr.inpe.br](mailto:almeida@dsr.inpe.br)

**Abstract.** The present work is committed to conduct a comparative analysis between two supervised classifiers, Maximum Likelihood and Support Vector Machine, respectively parametric and non-parametric, for the classification of vegetal physiognomies using very high spatial resolution imagery, emphasizing the gain in performance with the accordingly increase in the number of attributes. The database consisted of pan-sharpened QuickBird images and transformed images derived from the original bands besides relief data obtained from the TOPODATA Project. The study area extends over a surface of 16 km<sup>2</sup> and is located within the municipality of Nova Friburgo, in the mountainous region of Rio de Janeiro state. In total, four experiments were accomplished all of them combining the adopted classifier with a different number of attributes. In the first two experiments, only the four QuickBird spectral bands, previously subject to geometric and radiometric corrections, were used. In the remainder two experiments, eighteen input bands were employed. The Kappa indices obtained with the Maximum Likelihood classifier lied between 0.64 and 0.66, while those obtained for the Support Vector Machine ranged from 0.52 to 0.80. Considering the attained results, we concluded that the number of input bands does not meaningfully increase the accuracy of the Maximum Likelihood classifier, whereas this factor greatly influences the Support Vector Machine performance.

**Palavras-chave:** image classification, QuickBird, MAXVER, SVM, classificação de imagens, índice Kappa.

### 1. Introdução

As técnicas de processamento digital de imagens têm sido massivamente testadas no mapeamento da vegetação. Dentre as mais difundidas, destaca-se a classificação que utiliza algoritmos computacionais para a identificação automática de alvos baseada no reconhecimento de padrões, dividindo-se em não-supervisionados ou supervisionados. Nos algoritmos do primeiro tipo, a classificação está apoiada em métodos estatísticos de análise de agrupamento, e a identificação das classes ocorre sem a intervenção direta do intérprete. Os supervisionados fundamentam-se na definição das classes e na coleta das amostras executadas pelo usuário, e utilizam-se das amostras para gerar os padrões e, assim, rotular os *pixels* como pertencentes a uma determinada classe, através de métodos paramétricos e não-paramétricos

O modelo paramétrico emprega parâmetros, como média e matriz de covariância, para definir as regras do classificador, o que demanda certa homogeneidade nas propriedades espectrais das classes (Andreola et al., 2009). O desempenho e a exatidão dos classificadores estão diretamente ligados à distribuição normal dos dados. O problema reside nas imagens que apresentam comportamento heterogêneo, assim como nas feições anômalas presentes em imagens homogêneas.

Dentro da abordagem da estatística paramétrica, um dos algoritmos mais usados é a Máxima Verossimilhança (MAXVER), que estima, em uma abordagem quantitativa, a variância e a covariância dos padrões espectrais das amostras de treinamento, pressupondo que os *pixels* que formam o conjunto de treinamento apresentam uma distribuição normal. Desta forma, um vetor de

médias e uma matriz de covariância podem descrever os padrões de respostas encontradas na imagem. Apesar de ser um classificador tradicionalmente utilizado, o MAXVER não apresenta bom desempenho quando aplicado a imagens de alta resolução espacial.

O aumento na dimensionalidade dos dados eleva a acurácia da imagem classificada, na medida em que novas variáveis são acrescentadas. Entretanto, a partir de um determinado número de bandas incluídas no espaço dimensional, a acurácia decresce devido ao limite na geração de novas amostras de treinamento (Queiroz et al., 2004; Liczbinski, 2007), pois o número de parâmetros a serem estimados na matriz de covariância cresce rapidamente na medida em que a dimensionalidade dos dados aumenta. Se o número das amostras de treinamento não aumenta na mesma proporção, a confiabilidade na estimação destes parâmetros decresce. Em outras palavras, quando o tamanho das amostras de treinamento permanece constante, o acréscimo de bandas espectrais adicionais resulta na incerteza da estimativa dos parâmetros e, conseqüentemente, em decréscimo na acurácia da imagem temática produzida pelo classificador (Liczbinski, 2007).

Recentemente, uma nova família de algoritmos baseados em aprendizado de máquina, área da Inteligência Computacional que estuda o desenvolvimento de técnicas para extrair conhecimento a partir de amostras, tem sido reconhecida como promissora para a classificação de imagens. Essas técnicas, baseadas em modelos matemáticos, têm a capacidade de “aprender” a partir de um número de amostras e generalizar o conhecimento gerado para toda a imagem (Queiroz et al., 2004).

Entre essas técnicas estão as máquinas de vetores de suporte (*Support Vector Machines* – SVMs), conhecidas pelo seu alto grau de generalização e por embasamento matemático sólido apoiado em probabilidade estatística. Estudos recentes demonstram que o classificador SVM tem proporcionado resultados superiores aos de outros métodos de classificação, como Redes Neurais e Árvores de Decisão, nas imagens de sensoriamento remoto (Nascimento et al., 2009). As SVMs têm obtido sucesso em várias aplicações de sensoriamento remoto, notadamente em classificações que apresentam problemas em vista da alta dimensionalidade (Dixon e Candade, 2008).

As SVMs são apresentadas como uma classificação supervisionada derivada da teoria de aprendizagem estatística que, na maioria das vezes, gera bons resultados para dados complexos ou ruidosos (ENVI, 2009). Apresentam, basicamente, a abordagem dos problemas de dois modos. No primeiro, os erros de classificação não são considerados. No segundo, são instituídas variáveis de folga, de maneira que os padrões fora dos valores esperados da classe possam ser desconsiderados em função do limiar de aceitação usado, diminuindo, desta forma, a probabilidade de erros na classificação (Alixandrini, 2009). De modo geral, os algoritmos baseados em SVM obtêm ótimos resultados no que se refere à generalização por apresentar baixo *overfitting*, ou seja, ajuste demasiado dos dados de treinamento (super-especialização), pois, além de extraírem os parâmetros gerais que permitem a generalização, armazenam os ruídos e as peculiaridades, tolerando o reconhecimento de padrões não observados durante a etapa de treinamento (Alixandrini, 2009).

O objetivo do presente trabalho é comparar dois algoritmos estatísticos e supervisionados, MAXVER e SVM, aplicados na classificação da fisionomia da vegetação em imagens de altíssima resolução espacial, com ênfase na avaliação do desempenho das classificações derivadas do incremento de novos atributos. A área de estudo, com aproximadamente 16 km<sup>2</sup>, está situada no município de Nova Friburgo, na região serrana do estado do Rio de Janeiro, e é coberta por formações vegetais com diferentes níveis de intervenção antrópica.

## 2. Material e Métodos

Para a classificação da fisionomia da cobertura vegetal, foram utilizadas as bandas fusionadas do satélite Quickbird, obtidas em julho de 2008. Essa plataforma possui dois sensores que atuam no modo pancromático (PAN) e multi-espectral (MS), com resolução radiométrica de 11 bits. Também foram utilizados o Modelo Digital de Elevação (*Digital Elevation Model* - DEM) e a grade de declividade, com 30 m de resolução espacial, oriundos do projeto TOPODATA (Valeriano, 2005).

Inicialmente foram executadas as etapas de pré-processamento, que tem objetivo eliminar as

distorções geométricas e radiométricas da imagem. Foi realizada a ortorretificação pelo método de Coeficientes Polinomiais Racionais. Também foi feita a conversão dos níveis digitais para valores de radiância no topo da atmosfera, fundamental em estudos que comparam bandas ou imagens geradas por diferentes sensores (Ponzoni e Shimabukuro, 2009). Os parâmetros para a transformação foram obtidos em Digital Globe (2003).

A etapa seguinte consistiu na realização de operações entre as bandas com o objetivo de aumentar o contraste e, assim, inserir informações que possibilitassem a discriminação entre os alvos pelos algoritmos de classificação. Em trabalho realizado por Francisco e Almeida (2012) sobre mineração de dados visando à classificação de imagens, com banco de dados constituído por 138 descritores relacionados a imagens derivadas e a bandas sem processamento radiométrico, as árvores de decisão foram constituídas, predominantemente, por descritores correspondentes às imagens derivadas.

Foram aplicadas a Análise das Principais Componentes (*Principal Components Analysis* - PCA) e a conversão do sistema de cores aditivo RGB (*Red* ou Vermelho, *Green* ou Verde, *Blue* ou Azul) para o espaço IHS (*Intensity* ou Intensidade - I, *Hue* ou Matiz - H, *Saturation* ou Saturação - S). Também foram realizadas operações para cálculo de índices de vegetação - o Índice de Vegetação por Diferença Normalizada (*Normalized Difference Vegetation Index* - NDVI) e o Índice de Vegetação por Razão Simples (*Simple Ratio* - SR). Ressalta-se que no trabalho realizado por Francisco e Almeida (2012), as árvores de decisão foram constituídas por no mínimo 30% de descritores relacionados ao NDVI.

O banco de dados para classificação apresentou, no total, dezoito planos de informação, composto por quatro bandas multiespectrais fusionadas do sistema Quickbird convertidas para radiância, quatro componentes principais, seis componentes IHS, dois índices de vegetação, um DEM e uma grade de declividade.

As amostras de treinamento foram constituídas por 724 *pixels* distribuídos nas seguintes classes: vegetação arbórea - 134, vegetação herbácea-arbustiva - 98, vegetação de gramínea - 120, afloramento rochoso - 112, área antrópica - 164, e sombra - 134. A classe antrópica abrangeu um conjunto de alvos distintos, no entanto, como apresentam respostas espectrais semelhantes, foram inseridos em uma única classe.

Foram feitos quatro experimentos de classificação, dois utilizando o algoritmo MAXVER, e dois o SVM utilizando a função de base radial (FBR). Este último algoritmo possui também outras três funções - linear, quadrática e polinomial, que são variações da FBR, sendo que essa apresenta os melhores resultados na separação ótima de classes (Nascimento et al., 2009).

Duas das classificações, cada uma com um algoritmo, foram executadas usando quatro bandas pré-processadas da imagem QuickBird, ou seja, corrigidas das distorções geométricas e radiométricas. Outras duas classificações foram executadas, cada uma com um algoritmo, utilizando dezoito planos de informação correspondentes aos dados topográficos, às bandas originais corrigidas e às bandas derivadas por processamento digital.

Para a avaliação da acurácia das classificações, foram coletadas cerca de 300 amostras para cada experimento, estratificadas pela área esperada das seis classes, totalizando 1,2 mil amostras. Procurou-se obedecer ao número mínimo de 50 amostras por classe para mapas cobrindo menos de um milhão de acres e com menos de 12 classes (Congalton e Green, 2009). No entanto, devido à reduzida área de algumas classes, não foi possível atingir este número em todas elas.

Foram construídas as matrizes de erros e calculados os seguintes índices: (a) exatidão global - relação entre o número de amostras classificadas corretamente sobre o número total de amostras de referência; (b) exatidão do produtor - relativa aos erros de omissão, a qual representa a relação entre o número de amostras classificadas corretamente da classe k e o número total de amostras de referência da classe k, (c) exatidão do usuário - referente aos erros de comissão, a qual representa a relação entre o número de amostras classificadas corretamente da classe k e o número total de amostras classificadas da classe k; (d) *Kappa* (K) - analisa todos os elementos da matriz de erros; e

(e) *Kappa* condicional - avalia a acurácia de cada classe e é calculado com base no mesmo princípio do índice *Kappa* utilizado para a avaliação global da classificação, assim como a interpretação dos resultados obedece aos mesmos princípios (Congalton e Green, 2009).

### 3. Resultados e Discussões

A Tabela 1 refere-se à matriz de erros correspondente à classificação do Experimento 1, ou seja, obtida pela aplicação do algoritmo MAXVER utilizando quatro bandas pré-processadas do QuickBird. O índice de exatidão global foi de 70%, e o índice *Kappa*, 0,64, considerado muito bom de acordo com Landis e Koch (1977). Apenas a classe vegetação herbácea-arbustiva apresentou erros superiores a 50%, ou seja, a exatidão do produtor foi de 48%, e a exatidão do usuário foi de 37%, confundindo-se principalmente com a classe vegetação arbórea. Da mesma forma, os índices de exatidão da classe vegetação arbórea apresentaram grande confusão com herbácea-arbustiva, tanto por erros de omissão como de comissão, com a exatidão em torno de 60%. Entre as classes de vegetação, a que apresentou melhor desempenho foi a vegetação de gramínea, com exatidão do produtor de 64% e do usuário de 83%. As classes de não-vegetação – antrópica, sombra e afloramento rochoso – apresentaram menores erros do que as classes de vegetação, com a maioria dos índices de exatidão acima de 80%.

A Tabela 2 corresponde à matriz de erros da classificação do Experimento 2, ou seja, obtida pelo algoritmo SVM, usando quatro bandas pré-processadas do QuickBird. O índice de exatidão global foi de 60%, e o índice *Kappa*, 0,52, considerado bom (Landis e Koch, 1977). A classe vegetação herbácea-arbustiva apresentou resultado ruim, com exatidão do produtor correspondendo apenas a 6%, confundindo-se com a classe arbórea, e exatidão do usuário próxima a 20%, confundindo-se com a classe sombra. A vegetação de gramínea apresentou índices de exatidão próximos a 50%, apresentando maiores erros de omissão com a classe afloramento e de comissão com a classe vegetação arbórea. Entre as classes de vegetação, a arbórea apresentou melhor desempenho, com índices de exatidão acima de 50%. As classes de não-vegetação apresentaram erros menores do que as classes de vegetação, com a maioria dos índices de exatidão acima de 70%.

A Tabela 3 refere-se à matriz de erros da classificação do Experimento 3, ou seja, obtida pelo algoritmo MAXVER, usando 18 planos de informação, compostos pela bandas pré-processadas e processadas do QuickBird, além do DEM e grade de declividade. O índice de exatidão global foi de 73%, e o índice *Kappa*, 0,66, considerado muito bom (Landis e Koch, 1977). A classe vegetação herbácea-arbustiva apresentou pior desempenho entre as classes de vegetação, com exatidão do produtor correspondendo apenas a 31%, e do usuário próxima a 50%, confundindo-se principalmente com a classe arbórea. Por sua vez, a classe arbórea apresentou índices de exatidão superiores a 60%, confundindo-se com a herbácea-arbustiva. Entre as classes de vegetação, a gramínea apresentou melhor desempenho, com índices de exatidão acima de 80%. As classes de não-vegetação apresentaram erros menores do que as classes de vegetação, com a maioria dos índices de exatidão acima de 80%.

A Tabela 4 refere-se à matriz de erros da classificação referente ao Experimento 4 (Figura 1), ou seja, obtida pelo algoritmo SVM, usando 18 planos de informação. O índice de exatidão global foi de 84%, e o índice *Kappa*, 0,80, considerado muito bom (Landis e Koch, 1977). Neste experimento, os erros de omissão e comissão foram pequenos em todas as classes, com a maioria dos índices de exatidão superiores a 70%. A classe herbácea-arbustiva apresentou pior desempenho entre as classes de vegetação, com exatidão do produtor correspondendo 74%, e do usuário próxima a 60%, confundindo-se principalmente com a classe arbórea. Esta, por sua vez, apresentou índices de exatidão variando entre 70 e 90%, confundindo-se principalmente com a classe herbácea-arbustiva. Entre as classes de vegetação, a gramínea apresentou melhor desempenho, com índices de exatidão acima de 90%. As classes de não-vegetação apresentaram erros semelhantes aos das classes de vegetação, com a maioria dos índices de exatidão acima de 80%.

Tabela 1: Matriz de erros de classificação do MAXVER com 4 bandas, Experimento 1.

Classes		Amostras de referência						Total classificadas
		Afloramento	Árborea	Herbácea arbustiva	Gramínea	Sombra	Antrópico	
Classificadas	Afloramento	27	3		11	1	2	44
	Árborea		42	15	6	8	1	72
	Herbácea arbustiva		23	15	1	1	1	41
	Gramínea	3	1		35		3	42
	Sombra	1	2	1	1	43	2	50
	Antrópico				1		46	47
<b>Total coletadas</b>		31	71	31	55	53	55	296
Exatidão do produtor		87%	59%	48%	64%	81%	84%	70%
Exatidão do usuário		61%	58%	37%	83%	86%	98%	

Tabela 2: Matriz de erros de classificação do SVM com 4 bandas, Experimento 2.

Classes		Amostras de referência						Total classificadas
		Afloramento	Árborea	Herbácea arbustiva	Gramínea	Sombra	Antrópico	
Classificadas	Afloramento	26	5	1	21	5	4	62
	Árborea		39	19	1	4		63
	Herbácea arbustiva		1	2		6		9
	Gramínea	3	20	6	29		1	59
	Sombra	2	7	3	2	37	1	52
	Antrópico				6	1	49	56
<b>Total coletadas</b>		31	72	31	59	53	55	301
Exatidão do produtor		84%	54%	6%	49%	70%	89%	60%
Exatidão do usuário		42%	62%	22%	49%	71%	88%	

Tabela 3: Matriz de erros do classificador MAXVER com 18 planos de informação, Experimento 3.

Classes		Amostras de referência						Total classificadas
		Afloramento	Árborea	Herbácea arbustiva	Gramínea	Sombra	Antrópico	
Classificadas	Afloramento	25		3			3	31
	Árborea		55	18	4	13	1	91
	Herbácea arbustiva		10	11		2		23
	Gramínea	4		1	43	2	1	51
	Sombra	2	6	1	3	34	3	49
	Antrópico			2	2		47	51
<b>Total coletadas</b>		31	71	36	52	51	55	296
Exatidão do produtor		81%	77%	31%	83%	67%	85%	73%
Exatidão do usuário		81%	60%	48%	84%	69%	92%	

Tabela 4: Matriz de erros do classificador do SVM com 18 planos de informação, Experimento 4.

Classes		Amostras de referência						Total classificadas
		Afloramento	Árborea	Herbácea arbustiva	Gramínea	Sombra	Antrópico	
Classificadas	Afloramento	31			2	1	6	40
	Árborea		51	4		2		57
	Herbácea arbustiva		13	23		4		40
	Gramínea	1	1	3	50		1	55
	Sombra		6	1	3	45		55
	Antrópico					1	48	49
<b>Total coletadas</b>		31	71	31	55	53	55	296
Exatidão do produtor		100%	72%	74%	91%	85%	87%	84%
Exatidão do usuário		78%	89%	58%	91%	82%	98%	

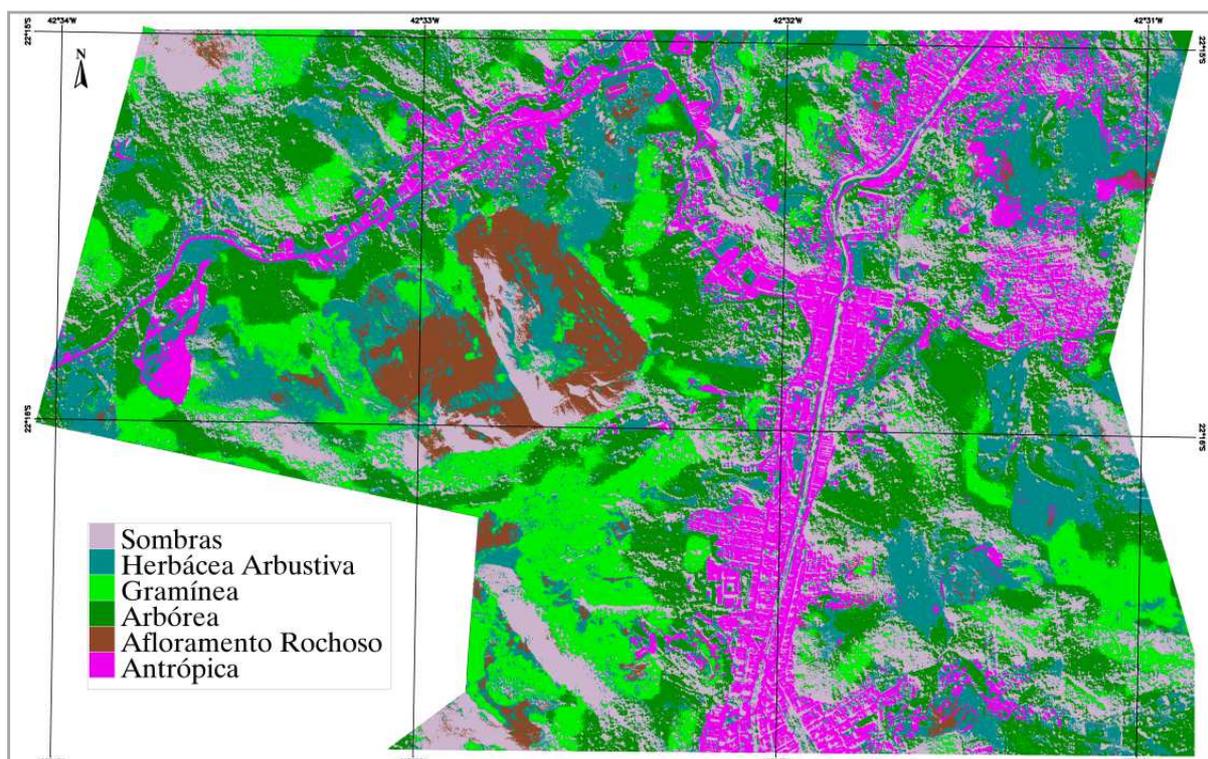


Figura 1: Classificação do algoritmo SVM constituída por 18 planos de informação, Experimento 4.

A Figura 2 apresenta o *Kappa* condicional de usuário das classes de cobertura da terra, confirmando a tendência apresentada nas matrizes de erros da classificação de que as classes de não-vegetação e de gramínea obtiveram melhores índices de acurácia nos experimentos realizados, com valores acima de 0,60 na maioria das situações testadas. Neste grupo, destaca-se a classe antrópica, com *Kappa* superior a 0,85, valores considerados (Landis e Koch, 1977). Entre as classes de vegetação, a herbácea-arbustiva apresenta o pior desempenho nos experimentos realizados, com valores de *Kappa* condicional abaixo de 0,60, alcançando 0,13 no Experimento 2. O melhor desempenho foi da gramínea, com índices entre 0,80 e 0,90, com exceção do Experimento 2. Verifica-se também que o Experimento 4 (algoritmo SVM e 18 bandas) apresentou melhor desempenho em quase todas as classes, com índices variando entre 0,75 e 0,98, exceção feita às classes afloramento rochoso e herbácea-arbustiva. No caso desta última, contudo, o índice, próximo a 0,5, foi o maior apresentado por esta classe nos experimentos realizados

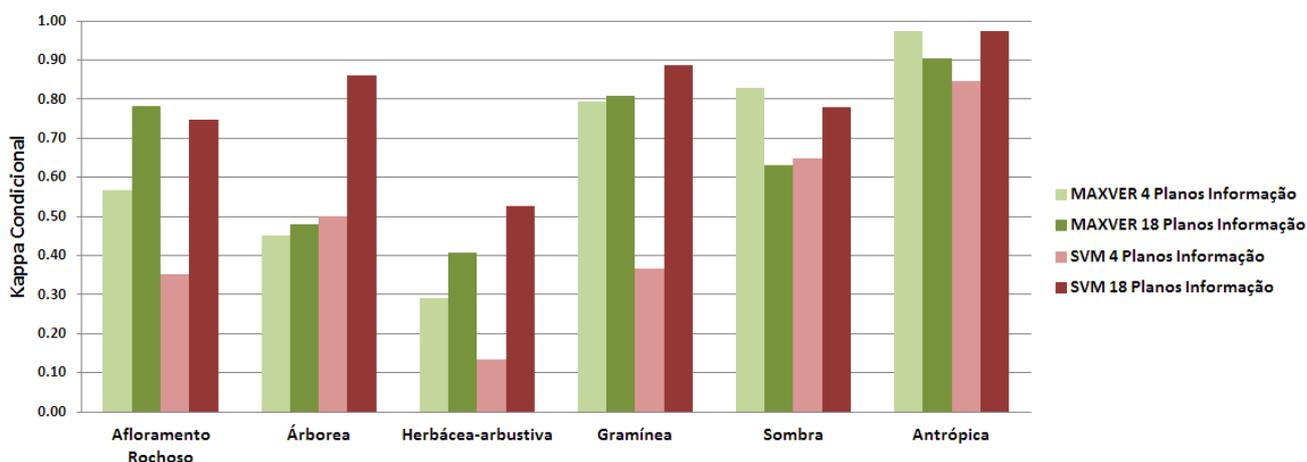


Figura 2: *Kappa* condicional do usuário das classes de cobertura da terra.

A Figura 4 mostra o desempenho do algoritmo SVM através da comparação do *Kappa* condicional de usuário das classes dos Experimentos 2 e 4. Verifica-se que, com o aumento do número de planos de informação no espaço de atributos, a classificação apresentou sensível melhora na discriminação das classes estabelecidas, com aumento substancial dos valores do *Kappa* condicional em todas as classes. Com destaque para a classe herbácea-arbustiva, que apesar de ter apresentado o pior desempenho nos outros três experimentos, obteve, no Experimento 4, o seu melhor desempenho. No entanto, não se evidenciou o mesmo comportamento nos experimentos que utilizaram o algoritmo MAXVER (Experimentos 1 e 3). Neste caso, verificou-se que para as classes de vegetação e afloramento rochoso, os índices *Kappa* se elevaram com o incremento de atributos, com aumento entre 0,20 (afloramento) e 0,05 (arbórea), enquanto os índices das classes sombra e antrópica reduziram-se com o incremento de atributos, 0,25 e 0,05, respectivamente.

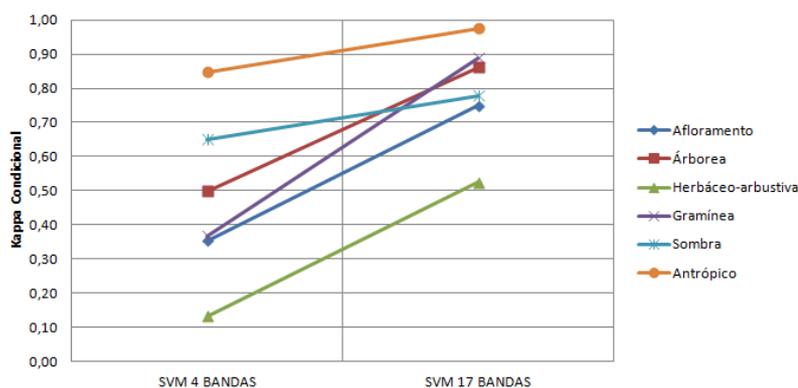


Fig. 5 - *Kappa* condicional do usuário do algoritmo SVM.

#### 4. Conclusões

Tendo em vista que o objetivo deste estudo foi analisar o desempenho entre um algoritmo não paramétrico e um paramétrico na classificação de fisionomias vegetais em imagens de alta resolução, pode-se afirmar que o classificador não paramétrico, SVM, apresentou melhor desempenho do que o paramétrico, MAXVER, quando utilizou maior número de planos de informação no espaço de atributos de classificação. A classificação correspondente ao algoritmo SVM com incremento de planos de informação *Kappa* passou de 0,52 para 0,80, valor considerado excelente segundo Landis e Koch (1977). No entanto, o desempenho da classificação com MAXVER não apresentou melhora significativa, com índice *Kappa* passando de 0,64 para 0,66.

Nos experimentos que aproveitaram apenas as quatro bandas pré-processadas do QuickBird, o desempenho do algoritmo paramétrico MAXVER mostrou-se superior tanto na avaliação global quanto individualmente para as classes de vegetação, com exceção da classe vegetação arbórea, que apresentou melhor desempenho pelo algoritmo SVM em ambos os cenários (com 4 e 18 bandas).

Considerando o experimento de melhor desempenho (SVM com 18 planos de informação), as classes referentes às fisionomias vegetais alcançaram excelente desempenho individual, com *Kappa* condicional próximo a 0,90, exceto a classe herbácea-arbustiva, que obteve desempenho próximo a 0,50), no entanto foi a que teve o segundo maior aumento do *Kappa* condicional. O aumento do número de atributos revelou-se de fundamental importância para o desempenho individual das classes alcançado pelo algoritmo SVM.

Deve ser destacado que, considerando-se todos os experimentos realizados, a vegetação herbácea-arbustiva obteve os menores índices de acurácia entre todas as classes, ao passo que a gramínea obteve os maiores índices entre as classes de vegetação. Este resultado está relacionado à resposta espectral semelhante entre as classes vegetação herbácea-arbustiva e arbórea, o que causa muita confusão na classificação. Já a gramínea se difere espectralmente das outras classes de vegetação devido à influência do solo na resposta espectral. Resultados semelhantes foram obtidos por Francisco e Almeida (2012).

As classes de não-vegetação apresentaram desempenho maior do que as de vegetação em todos os experimentos, com destaque para a classe área antrópica. Desta forma, em relação a estas classes, pode-se afirmar que a utilização do algoritmo SVM e o incremento no número de atributos não melhoraram significativamente o desempenho da classificação quando comparada com outros experimentos. No caso específico das classes área antrópica e sombra, os desempenhos do classificador MAXVER com 4 bandas e do SVM com 18 bandas foram muito semelhantes. Como a classe área antrópica é composta por vários tipos de cobertura e uso, o melhor desempenho por esta classe em todos os experimentos pode estar relacionado à resposta espectral mais diversificada em relação às demais classes consideradas, o que reduz consideravelmente a confusão.

Como quase todas as bandas que incrementaram os dados de entrada nos experimentos realizados foram produzidas a partir de operações que envolviam as próprias bandas que compõem a imagem QuickBird original (exceção feita aos planos de informação topográficos), é possível afirmar que o método de classificação não paramétrico SVM apresenta-se como uma alternativa viável ao mapeamento de fisionomias vegetais em imagens de alta resolução. Ainda assim, com o intuito de aperfeiçoar o método e aumentar a eficácia, outros estudos devem ser conduzidos, especialmente aqueles que procurem entender a importância que cada atributo apresenta no resultado final.

### Referências bibliográficas

- Alixandrini, M. Classificação de imagens Landsat 7 ETM multiespectrais utilizando SVM. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 14, 2009, Natal, Brasil. **Anais...** São José dos Campos: INPE, p. 7757-7764. 2009.
- Andreola, R.; Haertel, V. Support Vector Machines na Classificação de Imagens Hiperespectrais. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 14, 2009, Natal, Brasil. **Anais...** São José dos Campos: INPE, p. 6757-6764. 2009.
- Congalton, R.; Green, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. Boca Raton: CRC/Taylor & Francis. 2009. 183p.
- Digital Globe. **Radiance Conversion of QuickBird Data**. Technical Note. 2003.
- Dixon, B.; Candade, N. Multispectral landuse classification using neural networks and support vector machines: one or the other, or both?. **International Journal of Remote Sensing**, v. 29, n. 4, p. 1185–1206, 2008.
- ENVI. **ENVI User's Guide - ENVI Version 4.7**. ITT Visual Information Solutions. 2009.
- Francisco, C. N.; Almeida, C. M. Avaliação de Desempenho de Atributos Estatísticos e Texturais em uma Classificação de Cobertura da Terra Baseada em Objeto. **Boletim de Ciências Geodésicas**, v. 18, n. 2, p. 302-326, 2012.
- Landis, J.; Koch, G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, p. 159 – 174, 1977.
- Liczbinski, C. A. **Classificação de Dados Imagem em Alta Dimensionalidade, empregando Amostras Semi-Rotuladas e Estimadores para as Probabilidades a Priori**. 2007. 152p. Dissertação (Mestrado em Sensoriamento
- Nascimento, R. F. F.; Alcântara, E. H.; Kampel, M.; Stech, J. L.; Novo, E. M. L. M.; Fonseca, L. M. G. O Algoritmo Support Vector Machines (SVM): Avaliação da Separação Ótima de Classes em Imagens CCD-CBERS-2. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 14, 2009, Natal, Brasil. **Anais...** São José dos Campos: INPE. p. 2079-2086.2009
- Ponzoni, F. J.; Shimabukuro, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos, SP: Parêntese. 2009. 127p.
- Queiroz, R. B.; Rodrigues, A. G.; Gómez, A. T.. Estudo Comparativo entre as Técnicas Máxima Verossimilhança Gaussiana e Redes Neurais na Classificação de Imagens IR-MSS CBERS 1. *In: I WorkComp Sul*, 1, 2004, Palhoça, SC, Brasil. **Anais...** Disponível em: <http://inf.unisul.br/~ines/workcomp/cd/pdfs/2307.pdf>. Acesso em: 05/08/2012.
- Valeriano, M. M. Modelo digital de Variáveis Morfométricas com dados SRTM para o Território Nacional: o Projeto TOPODATA. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 12, 2005, Goiânia, Brasil. **Anais...** São José dos Campos: INPE. p. 1-8. 2005.