

O algoritmo *Support Vector Machines (SVM)*: avaliação da separação ótima de classes em imagens CCD-CBERS-2

Renata Fernandes Figueira Nascimento¹
Enner Herenio de Alcântara¹
Milton Kampel¹
José Luiz Stech¹
Evlyn Márcia Leão de Moraes Novo¹
Leila Maria Garcia Fonseca¹

Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil
{renata, enner, milton, stech, evlyn}@dsr.inpe.br; leila@dpi.inpe.br

Abstract. The aim of this work is to evaluate the support vector machine (SVM) classifier, which is part of a theoretically superior machine learning algorithm. The area surrounding Itumbiara reservoir in the State of Goiás, Brazil, was selected as a case study to carry out the classification of a CCD CBERS-2 image. The classes were defined in accordance with the Land Cover Classification System of the Food and Agriculture Organization of the United Nations (FAO) as Cultivated and Managed terrestrial Areas, Natural and Semi-Natural Vegetation, Artificial Surfaces and Associated Areas, Bare Areas, and Natural and Artificial Waterbodies. Training sets were collected for each class and then the algorithm was applied. Matrix confusion and the Kappa coefficients were used to evaluate the classification algorithm. The computed accuracy was about 75% and the Kappa coefficient 60%. According to these results the optimal class separation by SVM algorithm was considered reasonable good.

Palavras-chave: digital image processing, supervised classification, land use and cover, Itumbiara Reservoir, processamento digital de imagens, classificação supervisionada, uso e cobertura do solo, Reservatório de Itumbiara.

1. Introdução

Os problemas em processamento de dados em sensoriamento remoto geralmente envolvem a identificação específica da cobertura da terra, a estimativa de parâmetros biogeofísicos e a extração de feições. Essa variedade de problemas tem aumentada a sua complexidade dependendo dos cenários analisados. Dentre as aplicações mais difundidas do sensoriamento remoto destaca-se o mapeamento do uso e cobertura do solo, cuja rápida modificação no século XX tornou ineficiente os sistemas de tradicionais de aerolevante devido ao custo de aquisição. Nas últimas três décadas o sensoriamento remoto se tornou a fonte primária de informações sobre a cobertura do solo em decorrência dos avanços tecnológicos nos sistemas sensores e da ampliação do número de países que operam sistemas de Observação da Terra (Foody e Mathur, 2004). Estas tecnologias têm permitido a aquisição de informações sobre grandes áreas geográficas em diferentes resoluções espaciais, temporais, espectrais e radiométricas.

Brassoulis (1999) chama a atenção para o fato de que os conceitos de cobertura do solo e uso do solo são similares, mas não equivalentes. Cobertura do solo compreende a caracterização do estado físico, químico e biológico da superfície terrestre, como por exemplo, floresta, gramínea, água ou área construída. Por outro lado, uso do solo se refere aos propósitos humanos associados àquela cobertura, como por exemplo, pecuária, recreação, conservação ou área residencial.

A disponibilidade de dados dos satélites CBERS-2 e CBERS-2B (Satélite Sino-Brasileiro de Recursos Terrestres) de forma gratuita na internet tem aumentado o uso de imagens nas diversas aplicações de sensoriamento remoto. O CBERS-2 carrega três câmeras: CCD (Câmera Imageadora de Alta Resolução), IRMSS (Imageador por Varredura de Média Resolução) e WFI (Câmera Imageadora de Amplo Campo de Visada), e está no fim de sua

vida útil, sendo substituído pelo satélite CBERS-2B, lançado em outubro de 2007. Este satélite é muito semelhante aos CBERS-2, mas o IRMSS é substituído pela Câmera Pancromática de Alta Resolução – HRC (Epiphany et al., 2007).

Vários programas de manejo dos recursos naturais, planejamento e monitoramento dependem de informações acuradas sobre a cobertura do solo em determinada região. Exemplo prático é o apresentado por Selhorst et al. (2007) em que as imagens CCD-CBERS-2 são utilizadas no monitoramento e fiscalização do desmatamento na Amazônia por meio de algoritmos de classificação digital de imagens.

Dada a importância das técnicas de classificação no mapeamento do uso e cobertura do solo e a disponibilidade de novos métodos na literatura, o objetivo deste trabalho é avaliar o algoritmo de classificação SVM (*Support Vector Machine*) na separação ótima de classes em imagens CCD-CBERS-2. Estudos recentes (Huang et al., 2002; Foody e Mathur, 2004; Pal e Mather, 2005) mostram que o classificador SVM tem apresentados resultados superiores aos outros métodos de classificação, como Redes Neurais e Árvores de Decisão, para imagens de sensoriamento remoto.

1.1 Fundamentação teórica

Classificação é o processo que permite relacionar pixels em imagens de satélite a uma devida classe do terreno. Os algoritmos normalmente utilizados para a realização deste processo são conhecidos por classificadores de imagens (Mather, 1999). Os classificadores podem ser enquadrados em dois grupos: (i) os não supervisionados e (ii) os supervisionados. Dentre os não supervisionados estão, o IsoData e o K-médias; dentre os supervisionados estão, o paralelepípedo, o distância mínima, máxima verossimilhança, mapeamento por ângulo espectral, árvores de decisão, redes neurais e mais recentemente o *Support Vector Machines* (SVM). Os algoritmos de aprendizagem de máquina (SVM) têm como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (Vapnik, 1995). O SVM consiste em uma técnica computacional de aprendizado para problemas de reconhecimento de padrão. Introduzida por meio da teoria estatística de aprendizagem por Vapnik (1995), essa classificação é baseada no princípio de separação ótima entre classes, tal que se as classes são separáveis, a solução é escolhida de forma a separar o máximo as classes. Recentemente, o SVM foi utilizado na área de sensoriamento remoto com relativo sucesso (Brown et al., 2000; Melgani e Bruzzone, 2004).

O algoritmo pode ser descrito da seguinte forma: dadas ‘ D ’ amostras de treinamento $\{x_i, y_i\}$, com $i=1,2,\dots, D$, onde $x_i \in \mathcal{R}^M$ é uma representação vetorial de um conjunto e $y_i \in \{-1,1\}$ é sua classe associada. Neste processo existe uma distribuição de probabilidade $P(x, y)$ desconhecida da qual os dados de treinamento serão retirados. Ou seja, o processo de treinamento consiste em treinar um classificador de forma que este aprenda um mapeamento $x \mapsto y$ por meio de exemplos (classes) de treinamento $\{x_i, y_i\}$ de forma que a máquina seja capaz de classificar um exemplo (x, y) ainda não visto que siga a mesma distribuição de probabilidade (P) dos exemplos de treinamento.

O diferencial do SVM consiste em minimizar a expectativa de erro $\mathcal{E}(\zeta)$ em uma classificação tal que $\mathcal{E}(\zeta)$ é dado por $\mathcal{E}(\zeta) = \int \frac{1}{2} |y - f(x, \zeta)| dP(x, y)$.

A distribuição de probabilidade $P(x, y)$ não é conhecida (como discutido acima) não sendo possível então computar esta equação. Por outro lado, o risco empírico, $\mathcal{E}_\nu(\zeta)$, definido como a média da taxa de erro nos elementos do conjunto de treinamento pode ser

definido como $\varepsilon_{\psi}(\zeta) = \frac{1}{2D} \sum_{i=1}^D |y_i - f(x_i, \zeta)|$. Sendo que $\varepsilon_{\psi}(\zeta)$ é fixo para um ζ arbitrário e um conjunto de treinamento $\{x_i, y_i\}$.

A separação ótima entre classes ocorre por meio de um hiperplano condicional (L) (Figura 1), tal que este plano é orientado para maximizar a margem (distância entre as bordas, L_1 e L_2) e pelo ponto mais próximo de cada classe.




Figura 1: Esquema de classificação por meio do SVM, modificado de Huang et al. (2002) e Melgani e Bruzzone (2004).

O SVM possui quatro funções, sendo elas (i) linear, (ii) quadrática, (iii) polinomial e (iv) função de base radial. Neste estudo será utilizada a função de base radial (FBR). Esta função foi escolhida, pois todas as outras três funções são variações da FBR e segundo Brown et al. (2000), Huang et al. (2002), Melgani e Bruzzone (2004) o FBR apresenta os melhores resultados na separação ótima de classes.

1.2 Área de estudo

Para testar a eficiência do método SVM na classificação de imagens CCD-CBERS-2, a região da bacia de drenagem do reservatório de Itumbiara foi selecionada. A escolha desta área de estudo foi ditada pela presença de uma grande diversidade de classes de ocupação do solo e por ser objeto de estudo do projeto FAPESP 2007/08103-2, que tem entre seus objetivos estudar a evolução do uso e ocupação na área.

O Reservatório da UHE Itumbiara (18°25'S, 49°06'W) está localizado no bioma cerrado, na divisa dos estados de Minas Gerais, no Triângulo Mineiro, e Goiás. É formado principalmente pelo represamento dos rios Paranaíba, Araguari e Corumbá. Possui forma dendrítica, com 814 Km² de área inundada (Figura 2).

2. Metodologia

Para execução deste trabalho foram adquiridas duas cenas do sensor CCD do satélite CBERS-2 (órbita/ponto 158/120 e 158/121) referentes à 02/09/2007 (bandas 2 (0,52-0,59 μm), 3 (0,63-069 μm) e 4 (0,77-089 μm), as quais recobrem a bacia de drenagem do reservatório de Itumbiara. A correção geométrica foi realizada utilizando-se como referência uma cena ortorretificada disponibilizada pelo *Global Land Cover Facility* (<http://glcf.umiacs.umd.edu/index.shtml>).

As imagens CCD-CBERS-2 foram restauradas segundo procedimentos descritos por Fedorov e Fonseca (1995) e parâmetros de EIFOV (campo de visada efetivo do sensor) definidos por Gouvêa *et al.* (2007) obtidos por meio de técnicas de mineração de dados. Segundo Gonzalez (2001) a restauração permite a recuperação de uma imagem que foi degradada por meio do conhecimento *a priori* da causa desta degradação. Após a restauração

as cenas 158/120 e 158/121 foram submetidas ao procedimento de mosaico. Foram então definidas as classes a serem classificadas por meio do SVM.

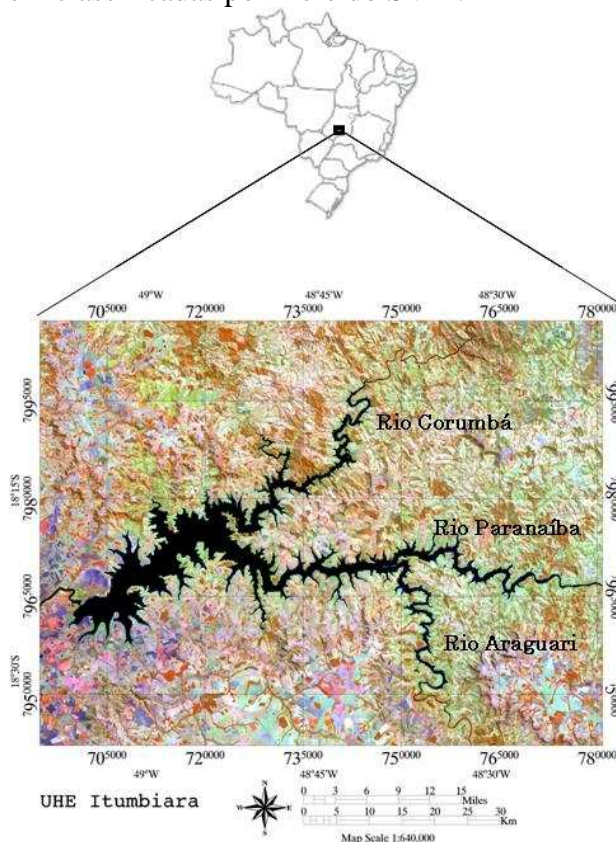


Figura 2: Localização da UHE de Itumbiara.

A definição das classes foi realizada de acordo com o Sistema de Classificação de Cobertura do Solo (LCCS), versão 2, da FAO (*Food and Agriculture Organization of the United Nations*; Di Gregório, 2005), conforme descrito na Tabela 1.

Tabela 1: Classes utilizadas na classificação da cena CCD-CBERS-2.

Áreas terrestres cultivadas e gerenciadas	Áreas onde a vegetação natural foi removida ou modificada e substituída por outros tipos de cobertura vegetal de origem antrópica, essa vegetação requer cuidados humanos para mantê-la em longo prazo;
Vegetação natural e semi-natural	Áreas onde a cobertura vegetal está em equilíbrio com os fatores bióticos e abióticos, e vegetação não plantada pelo homem, mas influenciada por suas atividades, respectivamente. Em vegetação semi-natural encontram-se os pastos;
Superfícies artificiais e áreas associadas	Referem-se a áreas que possuem cobertura artificial resultante de atividades humanas como, por exemplo, cidades e vias de transporte;
Áreas expostas	Áreas que não apresentam uma cobertura artificial resultante de atividades humanas. Essas áreas incluem áreas com menos de 4% de cobertura vegetal, como rochas e desertos;
Corpos d'água naturais e artificiais	Áreas naturalmente cobertas por água, como lagos e rios, e áreas cobertas por água devido à construção de artefatos, como reservatórios, canais e lagos artificiais. No caso da área de estudo essa classe se refere aos rios e ao reservatório de Itumbiara

Posteriormente, foi aplicado o algoritmo *Support Vector Machine* no mosaico CCD-CBERS-2, utilizando-se as classes definidas na Tabela 1. Dentre as funções de Kernel

disponíveis no SVM optou-se por utilizar a de base radial por ter apresentado bons resultados em outros trabalhos (Melgani e Bruzzone, 2004). A seguir, o desempenho do algoritmo foi avaliado por meio da matriz de confusão, do coeficiente Kappa e dos erros de omissão e inclusão utilizando um mapa temático de referência. As principais etapas desse trabalho encontram-se resumidas na Figura 3.

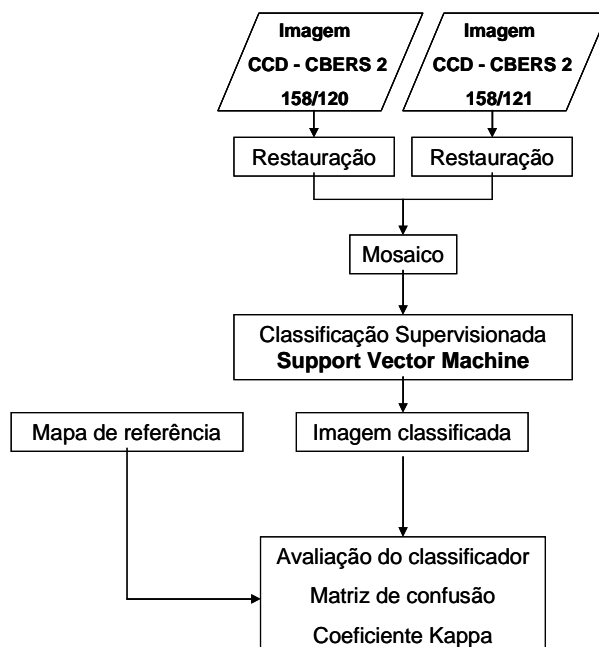


Figura 3. Seqüência metodológica utilizada no presente trabalho.

3. Resultados e Discussão

O uso conjunto do método de restauração de imagens desenvolvido por Fedorov e Fonseca (1995) com os parâmetros de EIFOV definidos por Gouvêa *et al.* (2007) resultou em uma imagem de melhor qualidade visual (Figura 4).

A avaliação do SVM resultou em uma acurácia total de aproximadamente 75%, obtida através da soma do número de pixels classificados corretamente, dividida pelo número total de pixels. Em estudos recentes, o classificador SVM foi comparado com outros métodos de classificação, como redes neurais, e árvores de decisão para imagens de sensoriamento remoto e superou todos em robustez e acurácia (Huang *et al.*, 2002; Foody e Mathur, 2004; Pal e Mather, 2005).

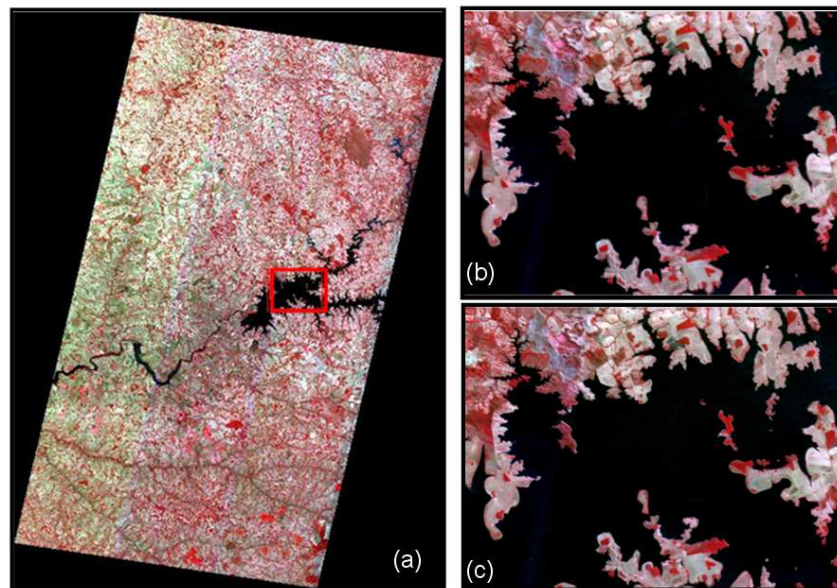


Figura 4: (a) Mosaico das cenas CCD-CBERS-2 do Reservatório de Itumbiara (R4G3B2) de 02/009/2007, (b) detalhe da imagem original delimitado pelo retângulo em vermelho, (c) detalhe da imagem restaurada.

A matriz de confusão mostrou que a classe “Corpos d’água naturais ou artificiais” foi a melhor classificada (Tabela 2), com 95% de exatidão.

Tabela 2: Matriz de confusão (em porcentagem) do classificador SVM.

	Corpos d’água	Vegetação	Áreas cultivadas e gerenciadas	Superfícies artificiais	Áreas expostas	Total
Corpos d’água	95,06	0,09	0,19	0,08	0,01	10,2
Vegetação	2,57	91,92	18,67	11,42	30,03	37,4
Áreas cultivadas e gerenciadas	1,64	4,66	60,17	26,55	26,89	28,89
Superfícies artificiais	0,54	3,27	20,73	61,52	0,08	9,74
Áreas expostas	0	0,07	0,25	0,43	42,97	4,48
Total	100	100	100	100	100	100

De uma forma geral, todas as classes apresentaram uma classificação satisfatória, porém as classes “Corpos d’água naturais ou artificiais”, “Áreas terrestres cultivadas e gerenciadas” e “Áreas expostas” foram subestimadas. Já as classes “Vegetação terrestre natural e semi-natural” e “Superfícies artificiais e áreas associadas” foram superestimadas.

A Figura 5 permite a comparação do resultado da aplicação do algoritmo SVM à CCD-CBERS-2 em relação ao mapa de referência. O algoritmo foi inadequado para classificar as áreas urbanas, representadas pela classe “Superfícies artificiais e áreas associadas”, o que também pode ser comprovado pela análise da matriz de erros (Tabela 2). Esta matriz mostra os erros de inclusão, que representam os pixels (ou porcentagem) pertencentes a outras classes e que foram erroneamente atribuídos à classe de interesse; e os erros de omissão representam os pixels que pertencem à classe de interesse, mas o classificador atribuiu a outras classes.

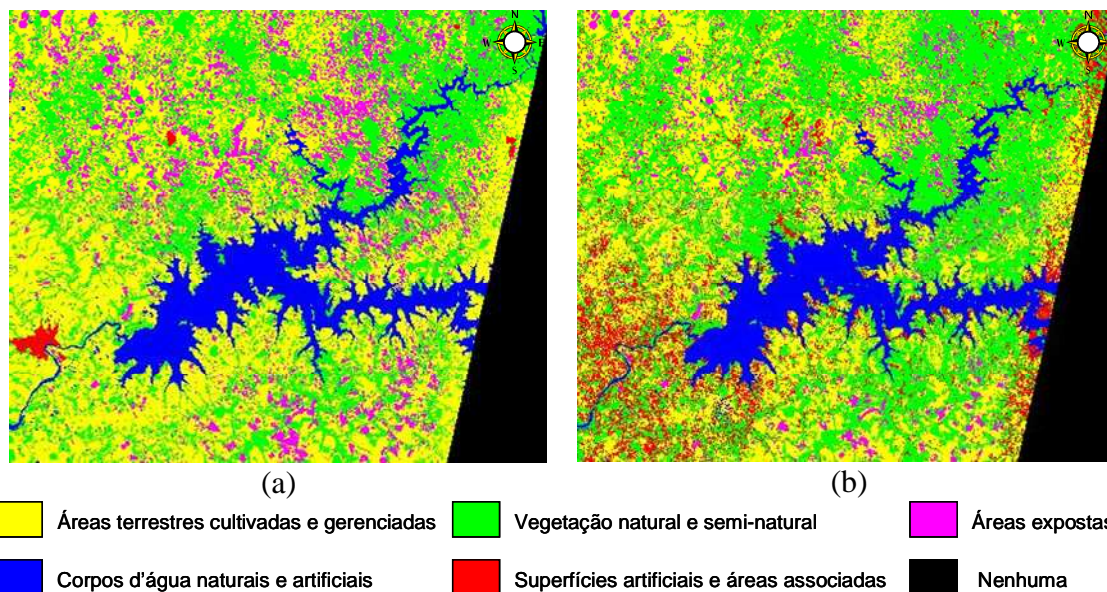


Figura 5: Resultado da classificação das imagens CCD/CBERS-2. (a) mapa de referência e (b) classificação realizada pelo algoritmo do *support vector machine*.

A Tabela 3 mostra que a classe “Áreas expostas” apresentou maior erro de omissão, ou seja, 57% dos pixels que foram classificados como não sendo desta classe, na verdade eram.

Tabela 3: Erros de omissão e comissão (em porcentagem) referentes ao classificador SVM.

	Erros de inclusão (%)	Erros de omissão (%)
Corpos d'água	1,1	4,94
Vegetação	29,36	8,08
Áreas cultivadas e gerenciadas	15,17	39,83
Superfícies artificiais	97,05	38,48
Áreas expostas	2,83	57,03

O coeficiente Kappa encontrado foi de 0,665, ou 66,5%, mostrando que o classificador *Support Vector Machine* obteve uma acurácia satisfatória. De acordo com Landis e Koch (1977) coeficientes que estão entre 0,61 e 0,80 são considerados robustos, o que caracteriza o desempenho do algoritmo SVM como sendo muito bom. Algumas classes apresentaram confusão entre si por apresentarem um comportamento espectral semelhante. Confusão que pode estar associada com a baixa resolução espectral e radiométrica do sensor CCD, aliada à presença de ruídos.

4. Conclusões

Este trabalho teve como objetivo avaliar o classificador SVM na separação ótima de classes em imagens CCD-CBERS-2 da região no entorno da UHE de Itumbiara.

A classificação da cena CCD-CBERS-2 por meio do SVM foi considerada muito boa, o que mostrou uma minimização de erros pelo algoritmo. Este resultado permite que a classificação de uma cena seja realizada de forma mais operacional com menor esforço em edição matricial.

Para um melhor resultado na classificação de cenas CCD-CBERS-2 sugere-se testar as outras funções de *Kernel* (linear, sigmóide e polinomial) do algoritmo SVM.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq;
Ao projeto FAPESP 2007/08103-2.

Referências Bibliográficas

Briassoulis, H. **Analysis of Land Use Change: Theoretical and Modeling Approaches**. Regional Research Institute, West Virginia University, 1999.

Brown, M.; Lewis, H.G.; Gunn, S.R. Linear spectral mixture models and support vector machines for remote sensing. **IEEE Transactions on Geoscience and Remote Sensing**, v. 38, n. 5, p. 2346-2360. 2000

Di Gregório, A. **Land Cover Classification System (LCCS), version 2: Classification Concepts and User Manual**. FAO Environment and Natural Resources Service Series, No. 8 - FAO, Rome, 2005. 208p.

Epiphanyo, J. C. N. ; Soares, J. V. ; Ferreira, H. ; Câmara, G. CBERS - The Chinese-Brazilian Earth Resources Satellite Programme. In: Nicklin, S.; Cornwell, B.; Griffiths, J. (Org.). **The Full Picture - GEO - Group on Earth Observations**. Geneva, Switzerland: Tudor Rose. v. 1, p. 116-117. 2007. ISBN 9789299004708. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m17@80/2007/12.10.17.15>>. Acesso em: 15 set. 2008.

Fedorov, D.; Fonseca, L. M. G. **Restau**: image restoration 0.0.15. São José dos Campos: INPE, Divisão de Processamento de Imagens, 2002.

Foody, G. M.; Mathur, A. A Relative Evaluation of Multiclass Image Classification by Support Vector Machines. **IEEE Transactions on Geoscience and Remote Sensing**, v.42, n.6, 2004.

Gonzalez R. C., Woods, R. E. **Processamento de Imagens Digitais**. Editora Edgard Blücher, 2000. 509 p.

Gouvêa, E. J. C.; Fonseca, L. M. G.; Santos, R. D. C. Ajuste dos parâmetros do algoritmo de restauração de imagens da câmera CBERS-2 CCD por meio de técnicas de Mineração de Dados. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 21 a 26 de abril, 2007, Florianópolis. **Anais... XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, 21-26 abril 2007, INPE, p. 903-910. Disponível em: <http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.15.20.18/doc/903-910.pdf> Acesso: 1 ago 2008.

Huang, C.; Davis, L. S.; Townshend, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, v. 23, n. 4, p. 725-749, 2002.

Landis, J.; Koch, G. G. The measurements of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, Mar 1977.

Mather, P. M. **Computer Processing of Remotely-Sensed Images**. An Introduction. 02 Chichester, England: John Wiley & Sons, 1999. 292p.

Melgani, F.; Bruzzone, L. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 42, No. 8, August 2004.

Pal, M.; Mather, P.M. Support vector machines for classification in remote sensing. **International Journal of Remote Sensing**, v. 26, n. 5, p. 1007-1011. 2005.

Selhorst, D.; Martins, M.H.B.; Silva, S.F. Uso de imagens CCD/CBERS para o monitoramento e fiscalização do desmatamento na Amazônia: uma experiência do IBAMA/ACRE. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 21 a 26 de Abril, 2007, Florianópolis. **Anais... XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, 21-26 abril 2007, INPE, p. 1117-1124. Disponível em: <http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@ /2006/11.16.03.53/doc/1117-1124.pdf> Acesso em 9 de agosto de 2008

Vapnik, V. **The Nature of Statistical Learning Theory**. New York: Springer-Verlag, 1995.