

## **Análise comparativa dos métodos de classificação SVM e Maxver-ICM Polarimétrico em imagem de radar ALOS PALSAR**

Luciana de Oliveira Pereira  
Ana Elisa Pereira Silva  
Rogério Galante Negri  
Sidnei João Siqueira Sant'Anna  
Luciano Vieira Dutra  
Corina da Costa Freitas  
Guaraci José Erthal

Instituto Nacional de Pesquisas Espaciais - INPE  
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil  
{luciano, anaelisa}@dsr.inpe.br; {rogerio, sidnei, corina, dutra, gaia}@dpi.inpe.br

**Abstract.** Optical remote sensing are of restricted use over highly cloudy areas when they are applied in Amazon, especially during rainy season. Synthetic Aperture Radar imagery has been an alternative, since data acquisition is independent of weather conditions. Thus, the scientific community has been developing and testing techniques for processing and classification of such imagery in order to enhance information extraction. In this context, this paper aims to compare the techniques of supervised classification of polarimetric Maxver-ICM and SVM Radial Basis Function (RBF) in the radar image ALOS PALSAR (Amplitude), using statistical analysis, overall accuracy, Kappa and Tau index highlighting the advantages and disadvantages of operational applications. It was concluded that the Maxver-ICM polarimetric showed better results in classification than the SVM, except for the class Forest. Also the ICM procedure uses de context to improve final classification, results which is not available for SVM. It is noteworthy that the main advantage of Maxver-ICM polarimetric is the processing time and the gratuity.

**Palavras-chave:** remote sensing, radar image, classification, sensoriamento remoto, imagem de radar, classificação.

### **1. Introdução**

Os estudos da Floresta Amazônica têm aumentado consideravelmente devido à preocupação mundial com as alterações no uso e ocupação do solo, com ênfase no desmatamento. As atividades antrópicas vêm modificando a paisagem local, tornando seu monitoramento necessário para a preservação da biodiversidade e controle do avanço de áreas agrícolas e pecuárias. Porém, o monitoramento destas áreas é uma tarefa difícil, pois o bioma Amazônia possui grande extensão territorial e de difícil acesso, devido a vários fatores, dentre eles a vegetação densa e a presença de uma rede de drenagem com rios caudalosos. Desta forma, técnicas de sensoriamento remoto têm se mostrado uma alternativa eficiente na análise e monitoramento ambiental, pois fornece uma visão sinótica e periódica da região citada.

Porém, em épocas chuvosas é difícil a aquisição de imagens ópticas de qualidade devido à presença de nuvens, assim, o monitoramento da área sofre sérias restrições. Neste contexto, os sensores que operam na faixa das microondas diferem-se dos ópticos na forma de aquisição dos dados e por serem capazes de adquirir dados sob condições atmosféricas adversas e independentemente da iluminação solar (HESS et al., 1990). Assim, apresentam vantagens em relação aos dados ópticos quando utilizados em estudos em regiões tropicais (LEWIS, 1998).

Para melhorar a interpretação das imagens de radar e detectar alterações na cobertura vegetal, algumas técnicas de processamento são aplicadas nas imagens, entre elas a classificação digital que separa grupos de pixels com características espectrais similares em classes de uso ou cobertura do solo (CENTENO, 2004). Esta classificação digital pode ser de três tipos: supervisionada, não supervisionada e semi-supervisionada. Na classificação supervisionada, os dados de treinamento de um conjunto de classes pré-definidas são amostrados pelo analista,

assim a classificação é realizada a partir de uma informação conhecida. Na classificação não supervisionada, não há dados de treinamento nem conhecimento prévio das classes, isto é, o usuário não influencia na classificação. As classes são definidas segundo o algoritmo e ou critérios do classificador. Na classificação semi-supervisionada, são adicionados dados de treinamento quando a classe é conhecida pelo analista, semelhante à classificação supervisionada. Contudo, o usuário também tem a informação de um conjunto de áreas classificadas que a princípio não pertencem a nenhuma classe pré-definida, semelhante ao classificador não supervisionado. (THEODORIDIS e KOUTROUMBAS, 2009).

Neste trabalho, foram utilizados dois classificadores supervisionados: Maxver-ICM (*Maximum Likelihood Iterative Conditional Mode*) e SVM (*Support Vector Machine*). O Maxver-ICM é um classificador pontual, contextual e iterativo que demonstra eficiência ao classificar imagens SAR (*Synthetic Aperture Radar*), e normalmente é escolhido pelo menor tempo e custo computacional no processamento do algoritmo (HUBERT-MOY et al., 2001). Já o classificador que utiliza um algoritmo de aprendizado de máquina (SVM) têm como característica a determinação de limites de decisão que maximizem a margem (hiperplanos) entre as classes no espaço de atributos. Estes fatos resultam numa separação ótima entre as classes com a finalidade de minimizar os erros de classificação (VAPNIK, 1995). O SVM como um método de classificação aplicado ao sensoriamento remoto tem apresentado resultados comparáveis e até mesmo superiores às demais técnicas de classificação, pois apresenta boa capacidade de apreender e reconhecer padrões (FOODY e MATHUR, 2006).

Neste contexto, o presente trabalho tem o objetivo de comparar as técnicas de classificação supervisionada do Maxver-ICM e SVM *Radial Basis Function* (RBF) na imagem de radar ALOS a bordo do satélite PALSAR (Amplitude), usando as análises estatísticas exatidão global, índice Kappa e Tau, apresentando as vantagens e desvantagens operacionais dos aplicativos.

## 2. Metodologia

### 2.1 Áreas de estudo e dados

Este trabalho abrange uma área do município de Belterra, estado do Pará-Brasil, entre as coordenadas 55°0'42"W 3°2'56"S e 54°54'42"W 3°13'46"S (Figura 1). A região apresenta grande diversidade quanto à cobertura do solo e uso da terra, variando desde floresta primária até áreas agrícolas e pastagem. Para o desenvolvimento deste trabalho foi utilizado um recorte de uma imagem polarimétrica do sensor ALOS a bordo do satélite PALSAR que possui ângulo de visada de 34,4° e resolução espacial de 12m. Esta imagem foi adquirida em 28/05/2009 no Instituto Nacional de Pesquisas Espaciais (INPE), cujos dados foram processados para o formato amplitude. Também foram usadas informações coletadas no trabalho de campo realizado 07/09/2009.

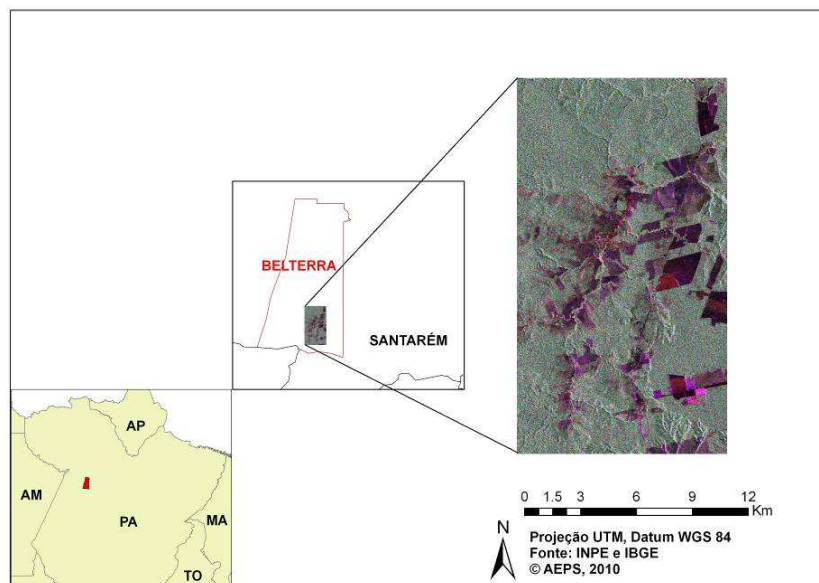


Figura 1. Localização da área de estudo.

## 2.2 Processamento da imagem

O pré-processamento da imagem de radar foi realizado através da conversão da matriz de espalhamento para a matriz de covariância das polarizações (HH, HV, VH, VV) para extrair dados de intensidade. Para minimizar o efeito do ruído speckle a imagem foi processada em multivisadas (3 looks) e também filtrada com o filtro Gamma. Nesta filtragem usou-se uma janela de processamento de 5x5 pixels, o que resultou em um pixel de aproximadamente 27 x 27 metros. Em seguida, os dados foram transformados para amplitude.

Para a seleção das regiões de interesse (ROI - Region of interest) na imagem, foi utilizado o banco de dados do trabalho de campo realizado em 07/09/2009 que contém a localização geográfica, fotos e comentários sobre as áreas visitadas. Após consultar e analisar as informações contidas no banco de dados foram definidas as classes e o número de pixels para cada uma delas. Estas informações podem ser encontradas na Tabela 1. As ROI(s) de treinamento e validação foram editadas no software ENVI 4.7, sendo que as ROI(s) para validação da classificação foram selecionadas de modo aleatório.

Tabela1. Classes de interesse e quantidade de pixel de treinamento e validação.

Classes	Treinamento	Validação
Agricultura 1	733	367
Agricultura 2	1644	757
Agricultura 3	1058	669
Floresta	4613	1768
Pasto Limpo	2789	648
Pasto Sujo	3314	1657
Regeneração	3273	1382

As classes Agricultura 1, 2, 3 referem-se a regiões visivelmente distintas na imagem de radar que podem representar diferentes culturas agrícolas. A distribuição de cada classe coletada na imagem de radar pode ser observada na Figura 2.

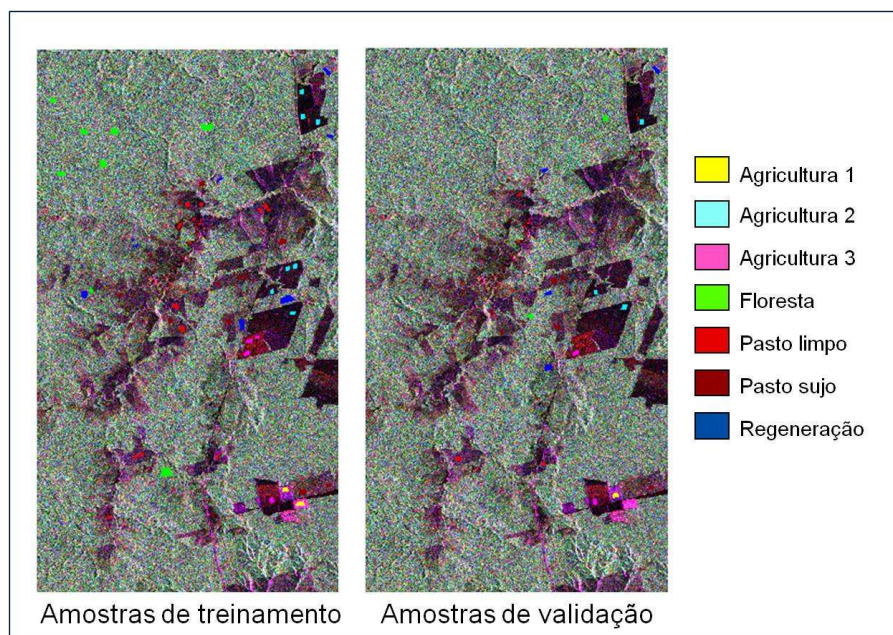


Figura 2. Amostras coletadas na composição R(HH) G(VV) B(HV).

### 2.3 Métodos de classificação

No processo de classificação Maxver é admitido uma distribuição normal para cada uma das classes e extrai um vetor de atributos através da qual calcula as probabilidades de um pixel pertencer a uma das classes determinadas na fase de treinamento, associando-o em seguida à classe a qual apresenta a maior probabilidade de pertencer. Neste contexto, o risco de uma decisão errada dado um vetor de atributos, é minimizado, ou seja, calcula-se a separabilidade das classes minimizando a probabilidade de erro. Já o Maxver-ICM, possui características semelhantes a do classificador Maxver, porém associa à classificação, informação contextual e espacial da imagem (GABOARDI, 2002). Este classificador foi executado no software Polarimétrico-7 (INPE), que leva em considerações as propriedades estatísticas inerentes aos dados de radar (disponível em <http://www.dpi.inpe.br/cursos/ser410/laboratorio.php>).

O SVM consiste em uma técnica de classificação não estatística para reconhecer padrões das amostras das classes pré-definidas. Baseia-se na montagem de um hiperplano ideal ( $L$ ) de separação entre as classes, focalizando as amostras à margem das classes ( $L_1$ ,  $L_2$ ) de modo a maximizar a distância entre elas (Figura 3) (FOODY e MATHUR, 2006). O algoritmo do classificador apresenta uma função para minimizar a expectativa de erro, sendo esta uma das suas maiores vantagens (NASCIMENTO et al., 2009).




Figura 3. Classificação SVM, modificado de Huang et al. (2002) e Melgani e Bruzzone (2004).

Neste trabalho foi utilizado a função não linear RBF, pois segundo Brown et al. (2000) é a mais adequada na discriminação de classes em que o hiperplano não apresenta linearidade (Figura 4).

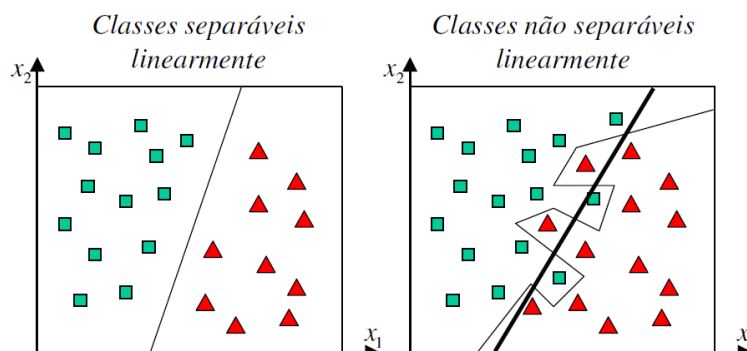


Figura 4. Separação das classes por um hiperplano, modificado de Erthal (2010).

Alguns parâmetros do classificador são definidos pelo usuário, dentre podem ser citados a penalidade e o  $\sigma$ . A penalidade é um parâmetro utilizado durante a classificação de dados não separáveis. Altos valores deste parâmetro implicam em menores índices de erro durante o treinamento, porém, podem ocasionar perda de generalidade do modelo. Já o  $\sigma$  é um parâmetro da função *kernel* RBF (*Radial Basis Function*), responsável em modelar a flexibilidade do hiperplano de separação fornecida pelo SVM.

Para o classificador SVM, adotando RBF como função *kernel*, foram realizadas diversas classificações na imagem de radar, a fim de determinar as configurações dos parâmetros  $\Gamma$  e Penalidade que resultam no melhor índice  $Kappa$  e  $Tau$ , e possivelmente na melhor classificação. Este procedimento foi realizado de forma automática com o auxílio da linguagem IDL e das funções presentes na biblioteca ENVI 4.7. Os melhores valores dos parâmetros selecionados de acordo com o critério descrito foram:  $\Gamma = 0,73$  e Penalidade = 90.

A Figura 5 mostra o fluxograma da metodologia do trabalho.

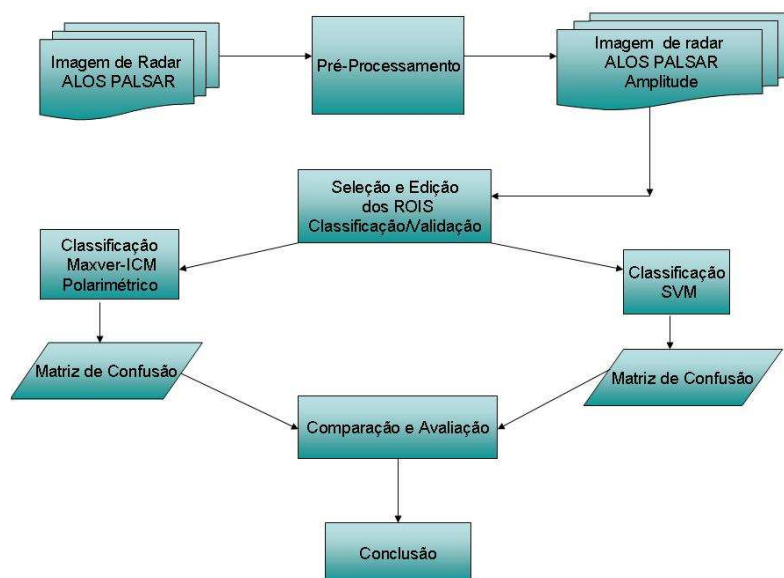


Figura 5. Fluxograma das etapas desenvolvidas no trabalho.

### 3. Resultados

As classificações resultantes da aplicação dos classificadores Maxver-ICM e SVM podem ser observados na Figura 6.

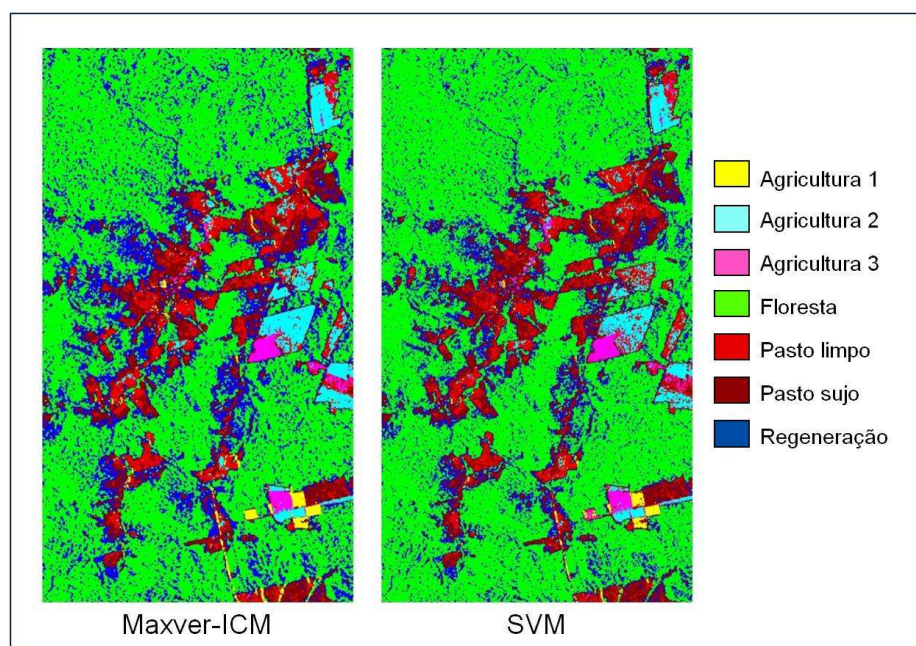


Figura 6. Resultado das classificações Maxver-ICM e SVM.

Em uma análise visual, o classificador SVM apresentou melhor resultado do que o Maxver-ICM, devido à classe com maior área (Floresta) apresentar maior porcentagem de acerto e menor confusão com as outras classes. Para analisar a confusão entre todas as classes, é necessário observar as matrizes de confusão dos classificadores Maxver-ICM e SVM (Tabelas 2 e 3, respectivamente).

Tabela 2. Matriz de confusão (em porcentagem) do classificador Maxver-ICM.

	Agricultura 1	Agricultura 2	Agricultura 3	Floresta	Pasto Limpo	Pasto Sujo	Regeneração	Total
Agricultura 1	<b>99,47</b>	0	0	0	0	0	0	5,15
Agricultura 2	0	<b>100</b>	3,44	0	10,03	0	0	11,64
Agricultura 3	0	0	<b>91,03</b>	0	0	0	0	8,39
Floresta	0	0	0	<b>85,41</b>	0	0	57,96	31,85
Pasto Limpo	0,53	0	5,23	0	<b>76,7</b>	15,18	0	15,39
Pasto Sujo	0	0	0,30	0	13,27	<b>83,37</b>	16,21	18,77
Regeneração	0	0	0	14,59	0	1,45	<b>25,83</b>	8,81
Total	100	100	100	100	100	100	100	100

Pode-se observar pela análise da matriz que as classes Agricultura 1, 2 e 3 obtiveram respectivamente 99,47%, 100% e 91,03% de acerto, mostrando um ótimo desempenho do Maxver-ICM em discriminar estas classes. A classe Agricultura 3 apresentou um pouco de confusão com a classe Pasto Limpo e Agricultura 2. A classe Floresta apresentou 85,41% de acerto, com confusão com a classe Regeneração de 14,59%. Já a classe Regeneração obteve baixa porcentagem de acerto 25,83% confundindo consideravelmente com Floresta 57,96% e Pasto Sujo 16,21%, demonstrando a dificuldade do classificador em separar estas classes, pois a Regeneração é um estágio intermediário do ciclo sucessional entre as classes Pasto Sujo e Floresta.

Tabela 3. Matriz de confusão (em porcentagem) do classificador SVM.

	Agricultura 1	Agricultura 2	Agricultura 3	Floresta	Pasto Limpo	Pasto Sujo	Regeneração	Total
Agricultura 1	<b>95,74</b>	0	0	0	0	0	0	4,96
Agricultura 2	0	<b>90,62</b>	5,23	0	4,78	0	0	10,36
Agricultura 3	0	0,13	<b>83,86</b>	0	0,31	0,18	0	7,81
Floresta	0	0	0	<b>91,12</b>	0	0	62,45	34,11
Pasto Limpo	4,26	9,25	7,47	0	<b>67,28</b>	27,22	0	14,10
Pasto Sujo	0	0	3,44	0,4	27,62	<b>70,37</b>	16,93	22,16
Regeneração	0	0	0	8,48	0	2,23	<b>20,62</b>	6,50
Total	100	100	100	100	100	100	100	100

Comparando as matrizes de confusão do Maxver-ICM e SVM foi possível observar que o índice de acerto deste último foi maior para a classe Floresta (91,12%) com menor confusão com Regeneração (8,48%), mostrando assim maior eficiência do classificador SVM em discriminar a classe citada. Já as demais classes obtiveram menores índices de acerto.

Segundo Congalton (1991) o índice Kappa é melhor para analisar o desempenho do classificador do que exatidão global, pois este expressa matematicamente somente o acerto da diagonal da matriz. Já o índice Kappa considera em seu cálculo todos os valores da matriz, além de descontar o acerto aleatório. O índice Tau considera a suposição de igualdade de probabilidades para as classes.

Para comparação dos resultados dos classificadores foram utilizados a exatidão global e os índices de concordância Kappa e Tau, demonstrados na Tabela 4.

Tabela 4. Avaliação das classificações obtidas.

	Maxver-ICM	SVM
Exatidão global (%)	80,26	74,23
Índice Kappa	0,769	0,699
Índice Tau	0,731	0,649

A exatidão global e os demais índices usados na análise refletiram os resultados das matrizes de confusão, com valores melhores para o classificador Maxver-ICM Polarimétrico. Foi realizado o teste de hipótese z para verificar se os valores dos índices Kappas eram diferentes a 5 % de significância. O resultado mostrou que os Kappas são significativamente diferentes, com um p-valor de 0.0032.

#### 4. Conclusões

Conclui-se que o classificador paramétrico Maxver-ICM e o classificador não paramétrico SVM apresentaram significativa diferença no resultado dos índices Kappa, sendo que o maior valor foi observado no classificador Maxver-ICM polarimétrico. Este resultado pode ser atribuído ao fato do classificador considerar as propriedades estatísticas inerentes da imagem de radar como o ruído *speckle* e também ao fato de levar em consideração a informação contextual da imagem. Na porcentagem de acerto o Maxver-ICM apresentou valores maiores em todas as classes, exceto na classe Floresta, a qual o classificador SVM demonstrou maior capacidade de discriminação. Nesse contexto, vale ressaltar que o custo operacional e computacional para a execução do classificador SVM é superior ao Maxver-ICM, principalmente para a definição dos melhores parâmetros (*Gamma* e Penalidade). Portanto, o classificador Maxver-ICM apresentou melhores resultados na classificação da imagem de radar e uma considerável vantagem operacional e computacional além de estar disponível em um aplicativo livre.

## Referências Bibliográficas

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.

Centeno, J.A.S. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Curitiba: Universidade Federal do Paraná, 2004. 209 p.

Congalton, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35-46, 1991.

Erthal, G.J. 2010. Notas de aulas.

Foody, G.M.; Mathur, A. The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM. **Remote Sensing of Environment**, v. 103, p. 179-189, 2006.

Gaboardi, C. Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional do Tapajós. 2002. 139 p. (INPE-9612-TDI/842). Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2002.

Hess, L.L.; Melack, J.M.; Simonett, D.S. Radar detection of flooding beneath the forest canopy: a review. **International Journal of Remote Sensing**, v. 11, p. 1313-1325, 1990.

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.

Hubert-Moy, L.; Cotonnec, A.; Le Du, L.; Chardin, A.; Perez, P. A Comparison of Parametric Classification Procedures of Remotely Sensed Data Applied on Different Landscape Units. **Remote Sensing of Environment**, v. 75, p. 174-187, 2001.

Lewis, H. **Principle and applications of imaging radar: Manual of remote sensing**. Maryland, USA: American Society for Photogrammetry and Remote Sensing, 1998. 811 p.

Melgani, F.; Bruzzone, L. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 8, p. 1778-1790, 2004.

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 (SBSR), 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. Artigos, p. 2079-2086.

Theodoridis, S.; Koutroumbas, K. **Pattern Recognition**. Canada: Academic Press, 2009. 961 p.

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