

Classificação da cobertura da terra na Amazônia utilizando Imagens Polarimétricas em Banda L e Máquina de Vetores Suporte

Rogério Galante Negri
Luciano Vieira Dutra
Corina da Costa Freitas
Graziela Balda Scofield
Daniel Luís Andrade Silva
Sumaia Resegue Aboud Neta

Instituto Nacional de Pesquisas Espaciais – INPE
Caixa Postal 515 – 12245-970 – São José dos Campos – SP, Brasil
{rogerio, dutra, corina, graziela, andrade, sumaia}@dpi.inpe.br

Abstract. For scientific purposes the ALOS PALSAR sensor can, sporadically, provide full polarimetric SAR data (HH, HV and VV) In this paper the deterministic supervised classifier Support Vector Machines (SVM), have been studied to determine how much the use of full polarized (HH, VV and HV, no phase information) PALSAR data information can improve, or not, the overall classification accuracy in comparison with the standard products, which, for PALSAR instrument, is the HH (like JERS-1) or the dual polarization product HH-HV. The overall performance of this type of classifier is also of interest. The study area, Tapajós National Forest at the south of Santarém City, in the Brazilian Amazon, Pará State, has being object of intensive scientific observation and a set of seven classes were used to this assessment: primary forest, secondary forest, bare soil, two types of soy beans, pasture and degraded forest. The three polarimetric channels have also been filtered before the classification process by a 5×5 gamma filter, but the unfiltered channels were also put to test. Results showed that HH and HV filtered channels combination provided the best classification performance with 65%, but did not realize a very good separation between Primary and Secondary Forest.

Keywords: Image Classification, SVM, ALOS PALSAR. Classificação de Imagens, SVM, ALOS PALSAR.

1. Introdução

A Floresta Amazônica possui aproximadamente cinco milhões de quilômetros quadrados, exerce fundamental importância nos ciclos biogeoquímicos e concentra parte considerável da biodiversidade do planeta. No entanto, esta floresta é constantemente modificada em função da intervenção antrópica, o que torna fundamental seu monitoramento visando a preservação da biodiversidade local e a contenção de impactos ambientais. Nestas condições o uso de Sensoriamento Remoto torna-se conveniente.

Em contrapartida, fatores atmosféricos típicos desta região, como a intensa presença de nuvens, prejudicam a aquisição de informações a partir de sensores ópticos, o que não ocorre com a utilização dos radares imageadores.

O satélite ALOS foi desenvolvido para contribuir com pesquisas relacionadas ao monitoramento de desastres, análise de recursos naturais e de cobertura da terra, além de buscar a expansão de conhecimento sobre as tecnologias de observação da Terra adquiridas no desenvolvimento e utilização dos antecessores JERS-1 e ADEOS (SHIMADA, 2007).

Este satélite possui três sensores, sendo um deles o radar polarimétrico PALSAR (*Phased Array Type L-band Synthetic Aperture Radar*).

Relacionado às metodologias de monitoramento, métodos de classificação de imagens são frequentemente adotados. Classificação de imagens são técnicas fundamentadas a partir de conceitos de Reconhecimento de Padrões, cujo objetivo é identificar e separar objetos em imagens digitais. Basicamente, essas técnicas analisam cada *pixel* da imagem segundo determinado critério e o associa a um conjunto de elementos com características comuns.

Maquina de Vetores Suporte, do inglês, *Support Vector Machine* (SVM), é um método de classificação de imagens baseado em um algoritmo de otimização que define hiperplanos de separação ótimos entre as amostras.

Neste trabalho, o método SVM foi aplicado sobre diferentes combinações de informações provenientes das componentes polarimétricas sintetizadas pelo sensor PALSAR, com o objetivo de verificar a capacidade de discriminação dos alvos a partir dessas informações quando associadas a este método.

2. Fundamentação Teórica

Métodos de classificação de imagens são concebidos como técnicas de Reconhecimento de Padrões, as quais buscam identificar características associadas a cada *pixel* da imagem (MATHER, 1999).

Estes métodos são discriminados por três características fundamentais: tipo, aprendizagem e abordagem. Assim, um classificador pode ser do tipo pontual ou por região, de aprendizado supervisionado ou não-supervisionado, seguindo uma abordagem estatística, determinística ou estrutural.

SVM é uma recente técnica de Aprendizado de Máquina cujo objetivo inicial esteve ligado à resolução de problemas de Reconhecimento de Padrões. Esta técnica, introduzida por Vapnik mostra-se muito poderosa, e em pouco tempo tem superado muitos sistemas em uma ampla variedade de aplicações (CRISTIANINI; SHAW-TAYLOR, 2000). Sua idéia principal é mapear não linearmente a informação (vetores do espaço de entrada) para um espaço de característica de alta dimensionalidade através de um mapeamento escolhido *a priori*. Nesse espaço uma superfície de decisão linear é construída, constituindo assim um hiperplano de separação ótima entre exemplos (DIAS, 2007).

Formalmente, dado dois conjuntos de dados, este método define um hiperplano capaz de separá-los da melhor forma possível. A Figura 1 ilustra dois exemplos de hiperplanos de separação entre dois conjuntos, onde o *Hiperplano 1* define a maior margem de separação.




Figura 1: Hiperplano ótimo de separação

O modelo mais simples de SVM é o classificador binário de margem máxima, funcional apenas para dados linearmente separáveis no espaço característico, o qual não se aplica a maioria dos problemas do mundo real. No entanto esse modelo é ponto de partida para o desenvolvimento de SVM's mais complexas, capazes de resolver problemas de separação que envolva mais de duas classes, e também dados não linearmente separáveis.

Considerando um problema binário linearmente separável definido por um conjunto $\Omega = \{(\mathbf{x}_i, y_i) | \mathbf{x}_i \in \mathbb{R}^l; y_i \in \{-1, +1\}; i = 1, \dots, n\}$, a classificação é realizada pela seguinte regra de decisão:

$$g(\mathbf{x}) = w^T \cdot \mathbf{x} + w_0 \Rightarrow \begin{cases} > 0 \rightarrow \mathbf{x} \in \omega_1 \\ < 0 \rightarrow \mathbf{x} \in \omega_2 \end{cases} ; \omega_1, \omega_2 \subset \Omega \quad (1)$$

onde $g(\mathbf{x})$ representa o hiperplano de separação.

Para obtenção da margem ótima, e consequentemente do hiperplano ótimo de separação, é necessário a solução de um problema de otimização, formulado a partir do conceito de distância entre ponto e reta.

A distância entre cada dado (ponto) e o hiperplano (reta) pode ser calculado através da relação:

$$Z(\mathbf{x}) = \frac{|g(\mathbf{x})|}{\|w\|} \quad (2)$$

A largura da margem é determinada a partir dos vetores suporte. O termo *vetor suporte* deriva dos vetores que definem a margem de separação, ou seja, os vetores que proporcionam $g(\mathbf{x}) = \pm 1$. Logo, a partir de dois vetores suporte, \mathbf{x}_α e \mathbf{x}_β , de diferentes classes, a largura (reescalada) da margem pode ser definida por:

$$S = \frac{|g(\mathbf{x}_\alpha)|}{\|w\|} + \frac{|g(\mathbf{x}_\beta)|}{\|w\|} = \frac{|+1|}{\|w\|} + \frac{|-1|}{\|w\|} = \frac{2}{\|w\|} \quad (3)$$

Nessas condições, o hiperplano de separação é obtido com a resolução do seguinte problema de otimização:

$$\min \left(J(w) = \frac{1}{2} \|w\|^2 \right) \text{ Sujeito a: } y_i (w^T \cdot \mathbf{x}_i + w_0) \geq 1 \quad \forall i \quad (4)$$

Outra forma de resolver este problema é a partir do Lagrangeano desta função. O Lagrangeano Primal da Equação 4 é dado por:

$$L_P = \frac{1}{2} w^T \cdot w - \sum_{i=1}^n \lambda_i (y_i (w^T \cdot \mathbf{x}_i + w_0) - 1) \quad (5)$$

onde λ_i são denominados por Multiplicadores de Lagrange.

Para otimização da Equação 5, é necessário que as condições KKT (Karush-Kuhn-Tucker) sejam satisfeitas. São elas:

$$\frac{\partial L_P}{\partial w} = 0 ; \quad \frac{\partial L_P}{\partial w_0} = 0 ; \quad \lambda_i > 0, \forall i \quad \text{e} \quad \lambda_i (y_i (w^T \cdot \mathbf{x}_i + w_0) - 1) = 0, \forall i$$

Por fim, reformulando o problema na forma Dual:

$$\max_{\lambda} \left(\sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right) \text{ Sujeito a: } \begin{cases} \lambda_i \geq 0, \forall i \\ \sum_{i=1}^n \lambda_i y_i = 0 \end{cases} \quad (6)$$

Ao otimizar o problema proposto, os Multiplicadores de Lagrange ótimos são utilizados na definição dos coeficientes w e w_0 a partir das seguintes relações:

$$w = \sum_{SV} \lambda_i y_i x_i \quad \text{e} \quad \lambda_i (y_i (w^T \cdot \mathbf{x}_i + w_0) - 1) = 0$$

onde SV é o conjunto dos vetores suporte. Por sua vez, estes coeficientes são utilizados para definição da Regra de Decisão dada pela Equação 1.

Segundo Theodoridis e Koutroumbas (2006), em muitos casos não há um limite linear capaz de separar as classes, logo, não faz sentido a busca de um hiperplano separador ótimo. A transformação dos dados em um espaço de maior dimensionalidade onde as classes são linearmente separáveis pode resultar em um *over-fitting*, proporcionando perda da capacidade de generalização. Nestas condições, para lidar com dados não linearmente separáveis é inserida uma penalidade C na função objetivo. Assim, para dados não-linearmente separáveis, o problema de otimização consiste em:

$$\max_{\lambda} \left(\sum_{i=1}^n \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right) \quad \text{Sujeito a: } \begin{cases} 0 \leq \lambda_i \leq C, \forall i \\ \sum_{i=1}^n \lambda_i y_i = 0 \end{cases}$$

Outro artifício utilizado para aumentar a capacidade dos hiperplanos de separação é o emprego de funções simétricas capazes de satisfazer as condições de Mercer, denominadas por funções *kernel* ($K(\mathbf{x}_i, \mathbf{x}_j)$) (THEODORIDIS; KOUTROUMBAS, 2006). Estas funções substituem o produto $\mathbf{x}_i^T \mathbf{x}_j$ das equações 6 e 7.

Alguns exemplos de funções *kernel* são o produto interno e a função de base radial, definidas por:

$$K_{Linear}(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \cdot \mathbf{x}_j) \quad K_{RBF}(\mathbf{x}_i, \mathbf{x}_j) = e^{\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{\sigma^2}\right)}$$

Inicialmente o SVM foi desenvolvido para a separação entre apenas duas classes. Na literatura são abordadas diferentes maneiras de lidar com um número maior de classes, denominadas por “Estratégias Multiclasse” (WEBB, 2002).

3. Materiais e Métodos

Neste estudo foi utilizada uma imagem do sensor ALOS PALSAR, originalmente em modo de operação PLR e nível de processamento 1.1. Após a realização de processamento *multi-look* e seleção de uma sub-área para o estudo, as características principais são:

- Data de imageamento: 23/04/07
- Passagem Ascendente
- Dimensão: 1273 x 1776 *pixel*
- Geometria *Ground Range*
- Espaçamento entre *pixel* em direção de *Range* e Azimute: 10,71 m

A Figura 2 ilustra a área de estudo, localizada na Floresta Nacional de Tapajós, Estado do Pará, juntamente com a imagem PALSAR em composição colorida (HH)R(HV)G(VV)B, sem e com utilização de procedimento de filtragem, onde estão presentes as amostras utilizadas para o treino (imagem sem filtragem) e validação (imagem com filtragem) dos resultados. A Tabela 1 informa o número de *pixel*, de cada uma das classes, utilizados para treinamento do método e validação dos resultados.

Tabela 1: Quantidade de *pixel* utilizados para treinamento do método e validação dos resultados

	Flo. Primária	Flo. Degradada	Flo. Secundária	Soja 1	Soja 2	Pastagem	Solo Exposto
Treinamento	1119	1068	1218	1003	1058	1108	1056
Validação	572	675	586	439	591	603	602

Devido à presença de um ruído característico das imagens de radar, denominado *speckle*, foi aplicado o filtro Gamma 5x5, capaz de reduzir a quantidade deste ruído na cena sem danificar o comportamento das bordas dos alvos.

O método SVM foi aplicado sobre diferentes conjuntos de dados compostos a partir da combinação entre as componentes polarimétricas em intensidade, filtradas e não filtradas. Denominou-se dados Univariados o conjunto de dados composto por apenas uma componente, Bivariado composto por duas componentes e Multivariados composto por todas as componentes, uma vez que as componentes utilizadas foram HH, HV e VV em intensidade. Não foram realizadas combinações entre dados filtrados e não filtrados.

A avaliação dos resultados foi baseada em índices de concordância *kappa* e acurácia global, calculados a partir das amostras de validação apresentadas na Figura 2.

Para aplicação do método SVM foi utilizado o *software* ENVI 4.4, utilizando função *kernel* de base radial, com $\sigma^2 = 1$ e $C = 1$, a partir do uso da Estratégia Multiclasse Um-Contra-Um.

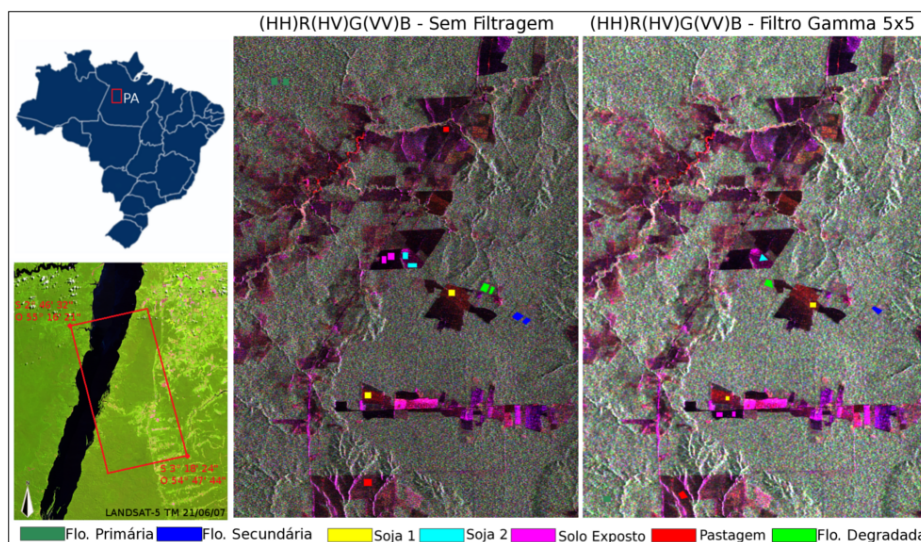


Figura 2: Área de estudo, amostras de treino e validação

4. Resultados e Conclusões

A Tabela 2 apresenta os índices de concordância *kappa* e a acurácia global de cada uma das classificações realizadas. A Figura 3 apresenta as melhores classificações para cada um dos tipos de conjuntos de dados, com e sem aplicação de filtragem *speckle*.

A classe *Floresta Degradada* tornou-se distinta da classe *Floresta Secundária* após a realização do processo de filtragem dos dados. As classes *Pastagem* e *Soja 1*, *Solo Exposto* e *Soja 2* apresentam maior distinção com a utilização de mais de uma componente.

O método empregado, independente dos dados utilizados, foi incapaz de realizar uma separação adequada entre as classes *Floresta Primária* e *Floresta Secundária*.

De modo geral, a utilização de filtragem proporcionou melhora significativa na acurácia das classificações. A utilização de apenas uma componente torna-se insuficiente para discriminação dos alvos indicados na Figura 2.

A combinação envolvendo três componentes apresentou resultados muito próximos aos resultados obtidos pela combinação das componentes HV e VV, que por fim, induz a concluir que a presença da componente HV proporciona a melhor separação entre os alvos.

Tabela 2: Índice de concordância $kappa$ e acurácia global das classificações obtidas

		Univariado			Bivariado			Multivariado
		HH	HV	VV	HH+HV	HH+VV	HV+VV	HH+HV+VV
Sem Filtro	$\hat{\kappa}$	0,1136	0,2238	0,1081	0,3226	0,2052	0,2788	0,3414
	Ac. Global (%)	24,31	33,43	23,89	42,18	32,13	38,54	43,80
Com Filtro	$\hat{\kappa}$	0,1637	0,4249	0,1644	0,5983	0,3180	0,4348	0,5875
	Ac. Global (%)	28,54	50,62	28,66	65,75	41,67	51,47	64,82

Agradecimento

Os autores agradecem à FAPESP (Proc. 2007/02139-5), CAPES e CNPq pelo suporte financeiro e à JAXA pela disponibilização dos dados.

Referências

CRISTIANINI, N.; SHAWE-TAYLOR, J. *An Introduction to Support Vector Machines and other kernel-based learning methods*. First edition. [S.l.]: Cambridge University Press, 2000.

DIAS, M. S. *O uso de máquinas de suporte vetorial para regressão (SVR) na estimação da estrutura a termo da taxa de juros do Brasil*. Dissertação de Mestrado em Matemática — Pontifícia Universidade Católica - Rio de Janeiro, 2007.

MATHER, P. M. *Computer Processing of Remotely-Sensed Images – A Introduction*. Second edition. [S.l.]: John Wiley & Sons, 1999.

SHIMADA, M. ALOS Handbook. In: . Earth Observation Research Center, JAXA - Japan Aerospace Exploration Agency, 2007. Disponível em: <<http://eroc.jaxa.jp/ALOS/doc/>>.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. Fourth edition. [S.l.]: Academic Press, San Diego, 2006.

WEBB, A. *Statistical Pattern Recognition*. First edition. [S.l.]: Wiley, 2002.

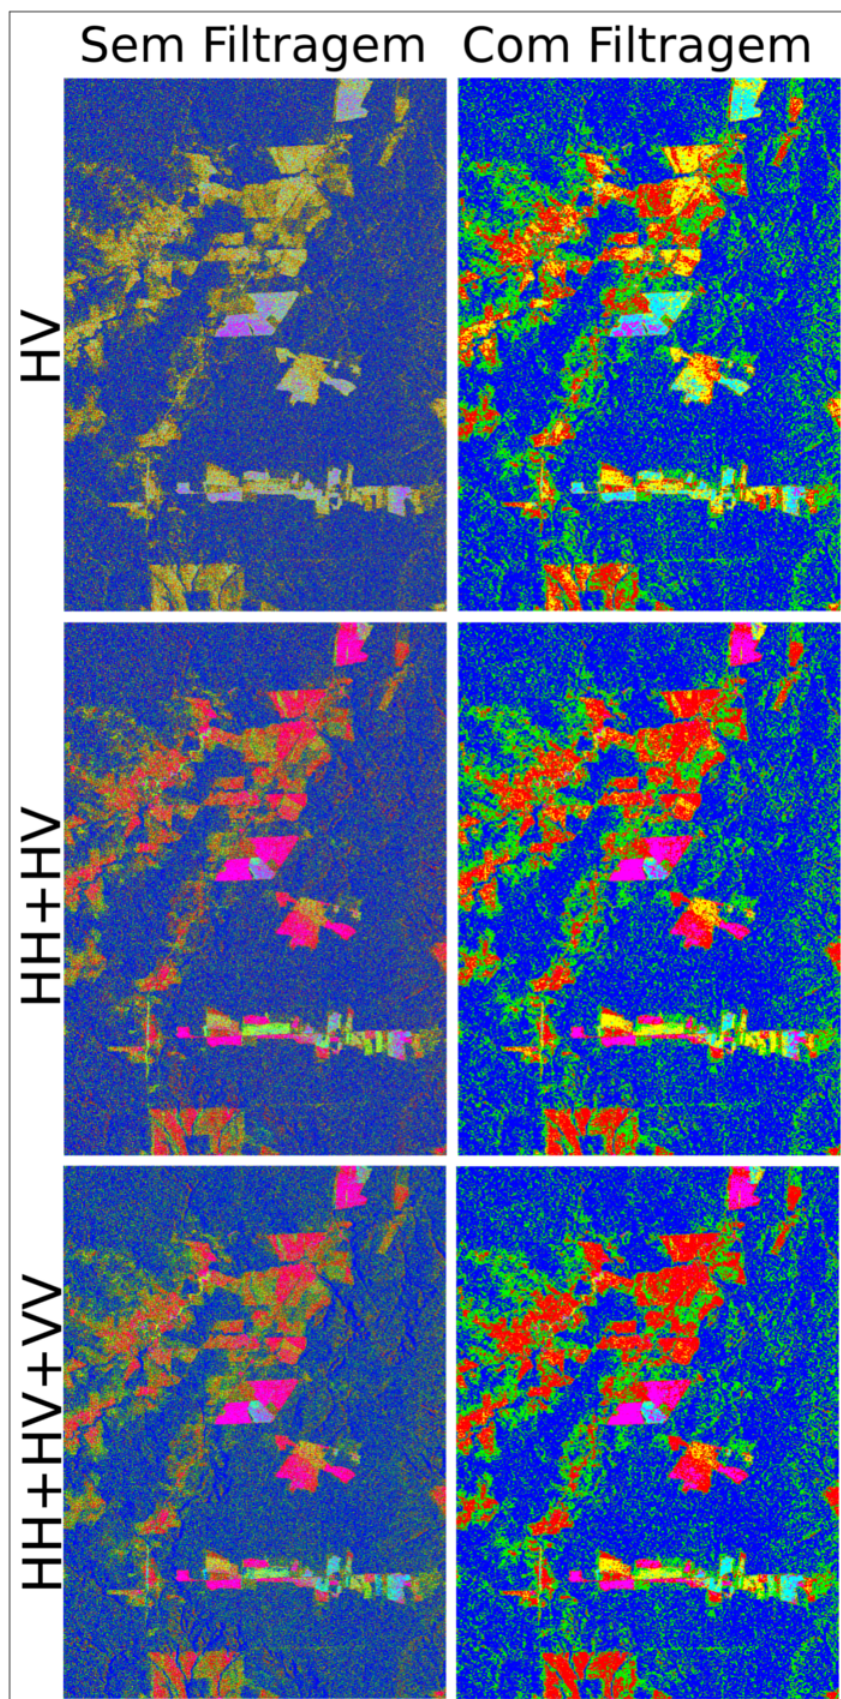


Figura 3: Melhores resultados obtidos