

Classificação da Cobertura do Solo na Amazônia Utilizando Dados Polarimétricos do Sensor ALOS PALSAR

Rogério Galante Negri¹, Corina da Costa Freitas¹, Luciano Vieira Dutra¹

¹Instituto Nacional de Pesquisas Espaciais – Divisão de Processamento de Imagens
Caixa Postal 515 – São José dos Campos – SP – Brazil

{rogerio, corina, dutra}@dpi.inpe.br

***Resumo.** O objetivo deste estudo foi analisar a capacidade de discriminação de alvos na região da Floresta Nacional de Tapajós a partir da utilização de diferentes combinações entre as componentes das imagens polarimétricas do sensor ALOS PALSAR, associadas a diferentes métodos de classificação de imagens. Foi possível observar que a componente HV possui informações capazes de proporcionar melhor discriminação entre os alvos.*

1. Introdução

A Floresta Amazônica possui aproximadamente cinco milhões de quilômetros quadrados, exerce fundamental importância nos ciclos biogeoquímicos e concentra parte considerável da biodiversidade e do planeta. No entanto, esta floresta é constantemente modificada em função da intervenção antrópica. Sendo assim, torna-se fundamental a contínua aquisição de dados dessa região para seu monitoramento.

Fatores atmosféricos típicos desta floresta, como a intensa presença de nuvens, prejudicam a aquisição de informações a partir de sensores ópticos, o que não ocorre como 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 do solo, 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, um deles é o PALSAR (*Phased Array Type L-band Synthetic Aperture Radar*), um radar imageador capaz de captar imagens em alta resolução.

Classificação de imagens é uma metodologia fundamentada a partir de conceitos de uma área de pesquisa da Ciência da Computação denominada Reconhecimento de Padrões, cuja finalidade é identificar e separar objetos em imagens digitais. Basicamente, essas técnicas analisam os *pixel* da imagem e os associam a um conjunto de elementos com determinada característica comum.

Neste contexto, os métodos de classificação de imagens MaxVer e SVM foram aplicados utilizando a informação das diferentes componentes sintetizadas pelo sensor PALSAR, com objetivo de verificar a capacidade de discriminação dos alvos.

2. Fundamentação Teórica

Métodos de classificação de imagens podem ser considerados formas de Reconhecimento de Padrões, onde são identificadas as características associadas a cada *pixel*,

[Mather 1999].

Estes métodos são discriminados por três características fundamentais: tipo, aprendizagem e abordagem.

Com relação ao tipo, os classificadores podem ser **pontual** ou **por região**, o aprendizado em **supervisionado** e **não-supervisionado** e a abordagem, principalmente em, **estatística**, **determinística** e **estrutural**.

Os métodos MaxVer e SVM, empregados neste trabalho, são classificadores pontuais de aprendizado supervisionado com abordagem, respectivamente, estatística e determinística.

2.1. MaxVer

O MaxVer (Máxima Verossimilhança) é um dos métodos de classificação de imagens mais utilizados em dados de Sensoriamento Remoto, [Richards 1986]. As etapas deste método consistem em:

- Extração de amostras das classes consideradas no processo de classificação
- Associação de uma função densidade de probabilidade para cada uma dessas classes
- Classificação de cada *pixel* da imagem segundo a função que proporciona maior probabilidade

Formalmente, dado um problema que envolve a classificação de um conjunto de dados dentre as classes $\omega_1, \omega_2, \dots, \omega_n$, é definida a seguinte regra de decisão:

$$\hat{\omega}(\mathbf{x}) = \operatorname{argmax}_{\Omega} p(\mathbf{x}|\Omega)$$

onde $\Omega = \{\omega_1, \dots, \omega_n\}$ e $p(\mathbf{x}|\Omega)$, denominada a função de verossimilhança, indica as probabilidades de \mathbf{x} pertencer a cada uma das classes de Ω .

A figura 1 ilustra o comportamento de três classes segundo funções densidade de probabilidade. Por sua vez, uma regra de decisão é definida para cada classe, dada por intervalos onde a probabilidade é maximizada.

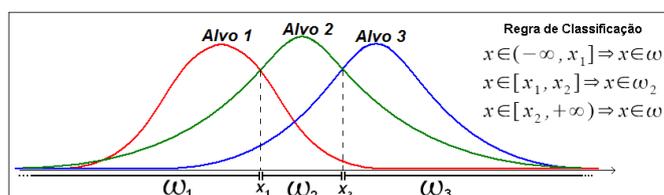


Figura 1. Representação da regra de decisão utilizada pelo MaxVer para três classes

2.2. SVM

Support Vector Machine (SVM) pode ser definida como uma máquina de aprendizado universal baseada em uma superfície de decisão, a qual é parametrizada por um conjunto de vetores suporte e seus respectivos pesos.

Dado um conjunto de treinamento rotulado por $\{\mathbf{x}_i, y_i\}$, com $i = 1, 2, \dots, N$, $y_i \in \{-1, 1\}$ (os rótulos) e $\mathbf{x}_i \in \mathcal{R}^l$, o objetivo é encontrar um hiperplano que classifique corretamente todos as N amostras de treinamento.

Este método busca pelo hiperplano ótimo, definido pela maior margem entre as duas classes, como ilustra a figura 2. Neste exemplo, ambos hiperplanos são capazes de separar as amostras de treinamento, no entanto, o hiperplano 1 define uma separação cuja margem é máxima.

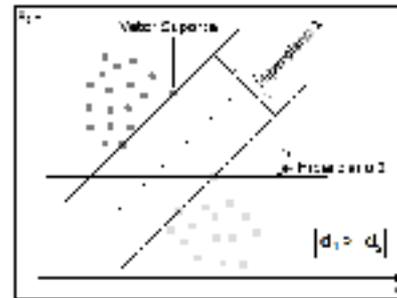


Figura 2. Hiperplano ótimo de separação entre duas classes

Para definição desta margem ótima, o seguinte problema de otimização deve ser resolvido [Theodoridis and Koutroumbas 2006]:

$$\max_{\lambda} \left(\sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j y_i y_j K(x_i, x_j) \right)$$

$$\text{sujeito a: } \begin{cases} 0 \leq \lambda_i \leq C, i = 1, 2, \dots, N \\ \sum_{i=1}^N \lambda_i y_i = 0 \end{cases}$$

Com a otimização deste problema, os coeficientes λ_i (Multiplicadores de Lagrange) são empregados para definição da função discriminante $g(x)$, ou regra de decisão, deste classificador.

$$g(x) = w^T \cdot x + w_0 \begin{cases} > 0 \rightarrow x \in \omega_1 \\ < 0 \rightarrow x \in \omega_2 \end{cases}$$

dado que:

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

onde ω_1 e ω_2 são as classes envolvidas no problema e SV é o conjunto composto pelos vetores suporte.

Neste modelo, C é um parâmetro que atua como um limitante superior para os valores de λ_i . Quanto maior for o valor de C , menos classificações incorretas são permitidas.

No caso de dados não-linearmente separáveis, funções simétricas capazes de satisfazer as condições de Mercer podem ser empregadas [Theodoridis and Koutroumbas 2006], as quais são frequentemente denominadas por funções *kernel* ($K(x_i, x_j)$). No entanto, as superfícies de separação não devem necessariamente serem lineares. Alguns exemplos de funções *kernel* são o produto interno e a função de base radial, definidas por:

$$K_{Linear}(x_i, x_j) = (x_i^T \cdot x_j). \quad K_{RBF}(x_i, x_j) = e^{\left(\frac{-\|x_i - x_j\|^2}{\sigma^2}\right)}$$

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].

Neste trabalho foram empregadas a função *kernel* de base radial e a estratégia multiclasse Um-Contra-Todos, onde, para um problema que envolve a discriminação de d classes, são definidos d classificadores binários capazes de distinguir cada uma das classes das demais.

3. Materiais e Métodos

Neste estudo foi utilizada uma imagem do sensor ALOS PALSAR em modo de operação PLR e nível de processamento 1.5, cujas características principais são: dados polarimétricos (componentes HH, HV, VH e VV em amplitude), resolução espacial de 20 m, geometria *ground range* e data de imageamento referente a 21 de outubro de 2006.

A figura 3 ilustra a área de estudo, localizada na Floresta Nacional de Tapajós, Estado do Pará. Na figura 4 é apresentada a imagem PALSAR utilizada, juntamente com as amostras de treino (regiões sólidas) e validação (regiões hachuradas). Com base nestes dados foram realizadas diferentes classificações a partir dos métodos MaxVer e SVM, utilizando combinações entre as componentes HH, HV e VV. Devido a presença de um ruído característico das imagens de radar, denominado *speckle*, foi aplicado o filtro Gamma 5x5, capaz de reduzir a quantidade de *speckle* na cena, no entanto, sem danificar o comportamento das bordas dos alvos.

Para aplicação do método MaxVer foi utilizado o *software Polarimetric Classifier 0.7*, desenvolvido por [Correia 1998], já para o método SVM, foi utilizado o *software ENVI 4.4*.

A avaliação dos resultados será baseada em índices de concordância *kappa*, calculados a partir das amostras de validação apresentadas na figura 4.

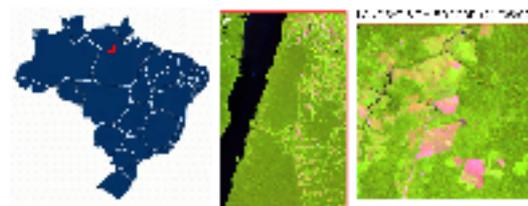


Figura 3. Área de estudo, Floresta Nacional de Tapajós – PA

4. Resultados

De modo geral, a utilização do filtro Gamma proporcionou melhora significativa na acurácia das classificações.

A utilização de apenas uma componente torna-se insuficiente para representação adequada dos alvos indicados na figura 4, além de algumas classes, como “Agricultura”, tornar-se sensível ao método de classificação.

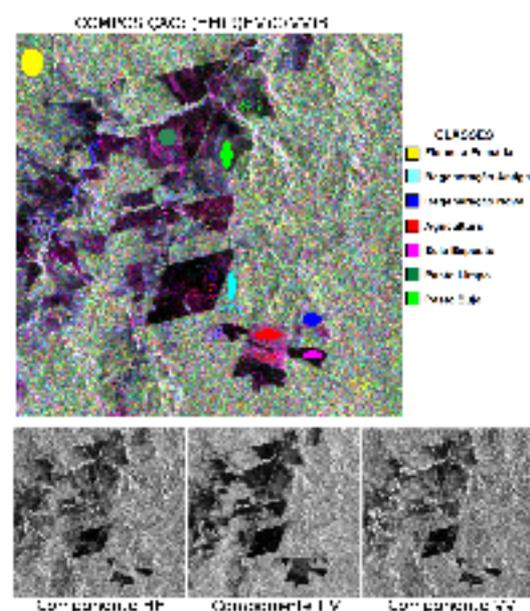


Figura 4. Imagem utilizada, amostras de treino e validação dos resultados

Tabela 1. Índices de concordância *kappa* das classificações obtidas

		HH	HV	VV	HH-HV	HH-VV	HV-VV	HH-HV-VV
Sem Filtro	Max Ver	0,29	0,30	0,36	0,56	0,34	0,56	0,58
	SVM	0,35	0,46	0,33	0,65	0,43	0,63	0,67
Com Filtro	Max Ver	0,42	0,54	0,36	0,63	0,56	0,83	0,86
	SVM	0,59	0,59	0,50	0,82	0,52	0,83	0,84

A combinação envolvendo três componentes apresentou resultados muito próximos aos resultados obtidos pela combinação das componentes HV e VV. Todas as classificações foram incapazes de discriminar adequadamente a classe “Regeneração Antiga”.

Por fim, a presença da componente HV proporcionou melhor separação entre os alvos.

A tabela 1 apresenta os índices de concordância *kappa* de cada uma das classificações realizadas. As figuras 5, 6 e 7 apresentam, respectivamente, as melhores classificações obtidas com o uso de uma, duas e três componentes, com e sem filtragem, para ambos os métodos de classificação empregados.

Agradecimento

Negri, R. G. agradece a FAPESP (Proc. 2007/02139-5) pelo suporte financeiro.

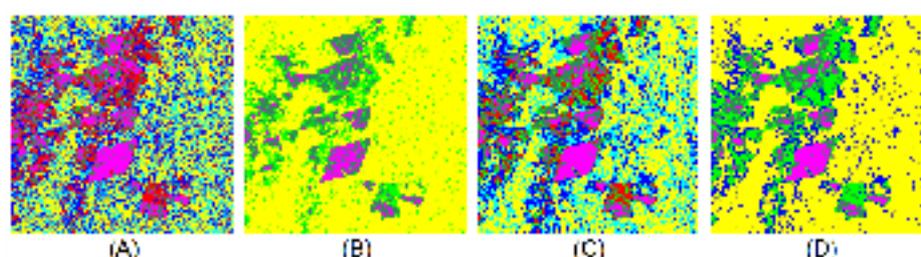


Figura 5. Melhores resultados obtidos com empregos de apenas uma componente. (A) MaxVer sob VV sem filtragem (B) SVM sob HV sem filtragem (C) MaxVer sob HV com filtragem (D) SVM sob HV com filtragem

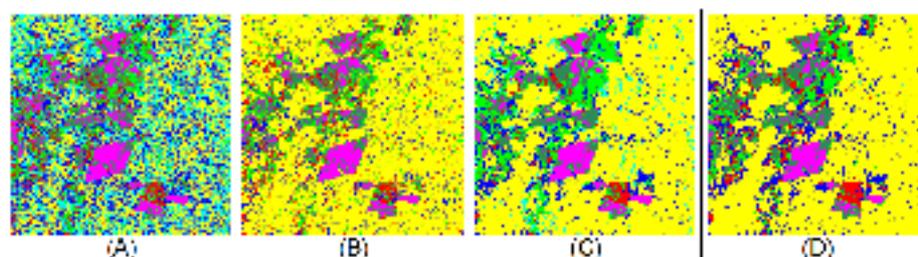


Figura 6. Melhores resultados obtidos com emprego simultâneo das componentes HV e VV. (A) MaxVer sem filtragem (B) SVM sem filtragem (C) MaxVer com filtragem (D) SVM com filtragem

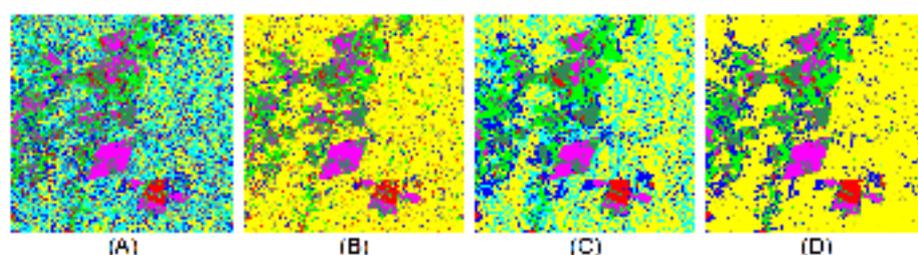


Figura 7. Melhores resultados obtidos com emprego simultâneo das componentes HH, HV e VV. (A) MaxVer sem filtragem (B) SVM sem filtragem (C) MaxVer com filtragem (D) SVM com filtragem

Referências

- Correia, A. H. (1998). Desenvolvimento de classificadores de máxima verossimilhança e icm para imagens sar polarimétricas.
- Mather, P. M. (1999). *Computer Processing of Remotely-Sensed Images – A Introduction*. John Wiley & Sons, second edition.
- Richards, J. A. (1986). *Remote Sensing Digital Image Analysis*. Springer-Verlag, Berlin.
- Shimada, M. (2007). *Alos handbook*. Earth Observation Research Center, JAXA - Japan Aerospace Exploration Agency.
- Theodoridis, S. and Koutroumbas, K. (2006). *Pattern Recognition*. Academic Press, San Diego.
- Webb, A. (2002). *Statistical Pattern Recognition*. Wiley.