

## AVALIAÇÃO DE DADOS SAR POLARIMÉTRICOS DO SENTINEL-1A PARA DISCRIMINAR TIPOLOGIAS DE COBERTURA DA TERRA EM UMA ÁREA DE DOMÍNIO DE FLORESTA TROPICAL

Natalia Cristina Wiederkehr<sup>1</sup>, Fabio Furlan Gama<sup>1</sup>, João Roberto dos Santos<sup>1</sup>, Ieda Del'Arco Sanches<sup>1</sup>, Polyanna da Conceição Bispo<sup>2</sup>, Paulo Bernardo Neves e Castro<sup>3</sup>, Juliana Maria Ferreira de Souza Diniz<sup>1</sup>, Heiko Balzter<sup>2</sup>

<sup>1</sup>Instituto Nacional de Pesquisas Espaciais, Caixa Postal 515-12227-01 – São José dos Campos/SP – Brasil, natalia.wiederkehr@inpe.br, fabio@inpe.br, joao.roberto@inpe.br, ieda.sanches@inpe.br, juliana.diniz@inpe.br

<sup>2</sup>Center for Landscape and Climate Research, School of Geography, Geology and Environmental, University of Leicester, Bennett Building University Road – Leicester LE1-7RH. Leicester, United Kingdom, pdcbl@leicester.ac.uk, hb91@leicester.ac.uk

<sup>3</sup>Universidade Federal de Ouro Preto, Campus Universitário, Morro do Cruzeiro – Ouro Preto/MG – Brasil, paulo.castro@aluno.ufop.edu.br

### RESUMO

O presente trabalho tem como objetivo avaliar a capacidade dos dados polarimétricos do Sentinel-1A para discriminar tipologias de cobertura da terra em uma área de influência da Floresta Amazônica. Neste estudo, utilizou-se uma imagem SAR nas polarizações VV e VH no formato *Single Look Complex*. Com base nesta imagem foi gerada a matriz de Covariância e aplicado o teorema de decomposição de alvos H-Alpha, que permitiu obter os atributos Entropia e Ângulo alfa. Também foi realizada a calibração radiométrica, para obter os coeficientes de retroespalhamento nas polarizações VV e VH. Em seguida, foi realizada a seleção dos atributos e coeficientes que apresentaram maior potencial para discriminar as classes. Para a classificação da imagem, foi utilizado o algoritmo *Support Vector Machine* e, a partir da combinação do coeficiente de retroespalhamento na polarização VH e do atributo polarimétrico Entropia, obteve-se uma exatidão global de 81,0% e Índice Kappa de 0,75.

**Palavras-chave** — Sentinel-1A, SAR/banda C, polarimetria, coeficientes de retroespalhamento, uso e cobertura da terra.

### ABSTRACT

This work aimed to evaluate the capacity of polarimetric data from Sentinel-1A to discriminate land cover typologies in area of influence of the Amazon forest. This study used a SAR image in the VV and VH polarizations in the configuration *Single-Look-complex*. A covariance matrix was generated from the image and the H-Alpha target decomposition theorem was applied. Based on this, the attributes Entropy and Alpha angle were generated. The radiometric calibration was also performed, which enabled the extraction of the backscattering coefficients for the VH and VV polarizations. Following, the attributes and coefficients that had the best potential for class discrimination were selected. The Support Vector Machine algorithm was used for the image classification, and a 0.75 Kappa with global accuracy of 81.0% was achieved from the combination of the backscattering in the VH polarization and the polarimetric attribute Entropy.

**Key words** — Sentinel-1A, C-band SAR, polarimetry, backscattering coefficient, land use and land cover.

### 1. INTRODUÇÃO

Radares de abertura sintética (SAR - *Synthetic Aperture Radar*) são sensores ativos que produzem sua própria fonte de energia e operam na faixa espectral de micro-ondas, sendo, pouco influenciados pelas condições atmosféricas. Essas características permitem que o imageamento seja realizado a qualquer hora do dia, independente da presença da luz solar [1]. Além disso, os dados SAR são sensíveis às variações da estrutura florestal [2] e [3], o que permite a discriminação de diferentes classes de cobertura da terra nos domínios da floresta tropical [4] e [5].

Dados polarimétricos SAR apresentam informações de amplitude e fase, possibilitando um maior entendimento sobre as características físicas e dielétricas dos alvos. A aplicação de teoremas de decomposições de alvos em dados polarimétricos possibilita identificar os tipos de mecanismos de espalhamento que ocorrem durante o processo de interação entre a radiação eletromagnética e o alvo, facilitando a discriminação dos alvos na superfície da Terra [6].

Por outro lado, atributos extraídos a partir do sinal de retroespalhamento, indicam a intensidade do processo de retroespalhamento da radiação nos canais polarimétricos que podem ser gerados a partir de uma única polarização (HH ou VV), dupla (HH e VH, VV e VH ou HH e VV) ou quádrupla polarização (HH, VV, HV e VH).

Lançado em 2014, o satélite Sentinel-1A é equipado com o sensor C-SAR que opera na banda C (~5 cm). Este sensor opera nos modos de polarização HH ou VV, HH e VV e, VV e VH e apresenta resolução espacial em torno de 10 m, podendo variar de 5 a 40 m, dependendo do modo de aquisição [7]. A grande vantagem do uso dos dados do Sentinel-1 A e B é que eles são disponibilizados gratuitamente pela ESA (*European Space Agency*) e apresentam cobertura global com alta resolução temporal (12 dias quando se considera o Sentinel-1A e 6 dias quando se considera o Sentinel-1A e o 1B). Diante disso, é importante desenvolver metodologias que possam explorar o potencial desses dados para contribuir com os sistemas de monitoramento e análises das dinâmicas do uso e cobertura da terra.

Neste contexto, o presente trabalho teve como objetivo avaliar a potencialidade da imagem SAR do satélite Sentinel-1A, com dupla polarização (VV e VH), para discriminar tipologias de cobertura da terra em uma região de influência da Floresta Amazônica.

## 2. MATERIAIS E MÉTODOS

### 2.1. Área de estudo

A área de estudo está localizada entre as latitudes 2°49'49" e 3°14'6" Sul e longitudes 55°0'42" e 54°44'54" Oeste, abrangendo uma porção da Floresta Nacional do Tapajós (FNT) e de áreas próximas a Rodovia BR-163 que liga Santarém à Cuiabá.

A paisagem da área de estudo que abrange parte da FNT é constituída por porções de remanescentes de floresta densa e aberta com diferentes estágios sucessionais, além de áreas destinadas a exploração madeireira em regime sustentável. Enquanto, as áreas adjacentes à FNT, próximas a margem esquerda da BR-163, são formadas principalmente por extensas áreas de agricultura mecanizada, pastagens, e também por regiões de agricultura familiar, além de fragmentos de floresta degradada.

### 2.2. Processamento SAR

A imagem utilizada foi adquirida no modo IW (*Interferometric Wide swath*), o qual apresenta resolução espacial de 5x20 m e largura da faixa de imageamento de 250 km, com nível de processamento L1 – SLC (*Single Look Complex*), sendo imagens complexas compostas pelas informações de amplitude e fase. A imagem utilizada neste estudo foi adquirida no dia 29 de setembro de 2016 e apresenta polarização dupla: VV e VH. Todas as etapas de processamento foram realizadas no *software* SNAP (*Sentinel Application Platform*) 4.0.

Na etapa de pré-processamento da imagem SLC, foi realizado o procedimento de TOPSAR *deburst*, remoção térmica do ruído e a calibração radiométrica. Sequencialmente, aplicou-se o procedimento de reamostragem por meio da média espacial (*multilook*) 3x1 pixels, sendo, o espaçamento entre os pixels convertido de 2,33 e 14,05 m nas direções em *range* e *azimute*, respectivamente, para 14,05 m em ambas as direções.

Com o intuito de reduzir o ruído *Speckle* e preservar as bordas e detalhes das feições, a imagem foi filtrada com o filtro *Lee* [8] com uma janela com tamanho de 5x5 pixels. Após a filtragem, obtiveram-se os coeficientes de retroespalhamento nas polarizações VV ( $\sigma_{VV}$ ) e VH ( $\sigma_{VH}$ ). O  $\sigma_{VV}$  indica a porção de energia retornada ao sensor a partir da superfície num sentido vertical, já o  $\sigma_{VH}$  indica maior sensibilidade ao espalhamento do tipo volumétrico. Como última etapa deste processamento, foi realizada a correção geométrica dos atributos através da geocodificação.

Para extrair os atributos polarimétricos, também foi realizada a etapa de pré-processamento supracitada. Posteriormente, gerou-se a matriz de Covariância [C2] que também foi submetida a um procedimento de reamostragem e filtrada com o filtro *Refined Lee* [9] com janela de tamanho de 5x5 pixels. Após a filtragem, foi realizada a decomposição polarimétrica H-Alpha [10] para extrair os atributos de entropia (H) e ângulo alfa ( $\alpha$ ). E como última etapa deste processamento foi aplicada a correção geométrica dos atributos através da geocodificação.

### 2.3. Seleção de atributos e classificações

A seleção das amostras de referência representativas das classes temáticas foi realizada com base no método de amostragem aleatória

estratificada. Para avaliar o desempenho das classificações foi realizada a validação cruzada dos dados, através do método *holdout*. O conjunto amostral foi separado em dois grupos: um para a etapa de treinamento e outro para a validação das classificações. Utilizou-se um conjunto amostral de 113 amostras coletadas em campo, divididas em 76 amostras de treinamento e 37 amostras de validação. Todas as amostras foram previamente georreferenciadas.

As tipologias de cobertura da terra consideradas no presente estudo são: Floresta em estágio avançado (Floresta Primária e Sucessão Secundária Avançada – SS3), Sucessão Secundária Intermediária (SS2), Sucessão Secundária Inicial (SS1), Floresta Degradada (em função do fogo e pela exploração madeira indiscriminada - FDG), Pasto (Limpo e Sujo – PA), Solo em Pousio/Solo Exposto (SP) e Área Cultivada (AC).

Após a etapa de processamento da imagem e seleção das amostras, foi realizada a seleção dos diferentes atributos que apresentaram potencial para discriminar as classes temáticas investigadas. Este grupo foi denominado subconjunto ótimo.

A técnica de seleção de atributos foi realizada através da combinação entre o avaliador *InfoGainAttributeEval* [11], que seleciona atributos medindo a taxa de ganho do atributo em relação a cada classe, junto ao método de busca *Ranker* [12], que ranqueia e seleciona os atributos através do ganho de informação e da redução da entropia. Essa etapa da seleção de atributos foi realizada no ambiente WEKA (*Waikato Environment for Knowledge Analysis*).

Posteriormente, foi gerada uma máscara sobre a imagem, com o objetivo de excluir as áreas com coberturas de corpos d'água e, a partir da seleção de atributos supracitada, todos os grupos foram classificados pelo classificador SVM (*Support Vector Machine*) no *software* ENVI 5.3. Com os resultados classificatórios, obteve-se a matriz de confusão, onde foram calculados os valores de exatidão global, Índice Kappa, e a acurácia do produtor e do usuário.

## 3. RESULTADOS

De acordo com o *rank* de medidas de importância (Figura 1), dentre os atributos selecionados, o atributo H apresentou maior sensibilidade na discriminação das classes temáticas, seguido pelo atributo  $\alpha$ ,  $\sigma_{VH}$  e  $\sigma_{VV}$ , respectivamente. Pode-se observar um decaimento de aproximadamente 22,7% entre os atributos H e  $\alpha$ . O maior decaimento do *ranking* de medidas de importância ocorreu entre o atributo H e  $\sigma_{VV}$ , com 79,5%.




Figura 1 – *Ranking* das medidas de importância dos atributos.

A partir da análise das medidas de importância dos atributos, foram realizadas as melhores combinações dos mesmos, considerando o potencial discriminatório das classes temáticas de acordo com os

valores de exatidão global e os Índices *Kappa*, conforme pode ser observado na Tabela 1.

Atributos	Número de atributos	Exatidão global (%)	Índice <i>Kappa</i>
H e $\alpha$	02	78,0	0,71
H, $\sigma$ VH e $\sigma$ VV	03	80,0	0,73
H	01	80,0	0,74
H e $\sigma$ VH	02	81,0	0,75

Tabela 1 – Classificações das melhores combinações de atributos.

O melhor resultado classificatório foi obtido pela combinação de H e  $\sigma$ VH, que exibiram uma exatidão global de 81,0% e Índice *Kappa* de 0,75. Este resultado é considerado bom, segundo os valores de referência da “escala de importância” [13]. Dentre os subconjuntos ótimos apresentados na Tabela 1, pode-se ainda observar uma pequena variação dos valores de exatidão global e dos Índices *Kappa*.

Como podem ser observados na Tabela 2, os melhores resultados a partir dos atributos H e  $\sigma$ VH foram obtidos para as classes SS3 e SP, com 100,0% de acerto, seguido pela classe AC com 88,3% de acerto. A classe SS1 apresentou o menor desempenho classificatório, sendo 76,8% das suas amostras classificadas erroneamente como PA e 17,3% como AC. A classe FDG também apresentou muita confusão na classificação, com um total de 90,0% das suas amostras classificadas como sendo SS1, PA e AC.

CLASSIFICAÇÃO (%)	REFERÊNCIA (%)							Acurácia do Usuário (%)
	SS3	SS2	SS1	FGD	PA	SP	AC	-
SS3	100,0	42,8	0,0	0,0	0,0	0,0	0,0	95,0
SS2	0,0	57,2	0,0	0,0	0,0	0,0	0,0	100,0
SS1	0,0	0,0	5,9	20,0	6,2	0,0	0,0	25,0
FGD	0,0	0,0	0,0	10,0	0,0	0,0	0,0	100,0
PA	0,0	0,0	76,8	60,0	56,3	0,0	11,7	42,0
SP	0,0	0,0	0,0	0,0	0,0	100,0	0,0	100,0
AC	0,0	0,0	17,3	10,0	37,5	0,00	88,3	74,0
Acurácia do Produtor (%)	100,0	57,0	6,0	10,0	56,0	100,0	88,0	
	Exatidão global: 0,81			<i>Kappa</i> : 0,75				

Tabela 2 – Matriz de Confusão da classificação dos atributos H e VH

Os coeficientes  $\sigma$ HV e  $\sigma$ VV classificados conjuntamente exibiram exatidão global de 55,5% e um Índice *Kappa* de 0,41. Já o coeficiente  $\sigma$ VH apresentou uma exatidão global de 55,0% e Índice *Kappa* de 0,38. A partir das análises, foi elaborado o mapa de cobertura da terra utilizando os melhores resultados obtidos no processo de classificação, que é apresentado na Figura 2.




Figura 2 – Mapa de cobertura da terra da área de estudo a partir da classificação dos atributos H e  $\sigma$ VH.

#### 4. DISCUSSÃO

Com base nas análises realizadas, pode-se constatar que o atributo polarimétrico H, proveniente da decomposição de alvos H-Alpha, combinado com o  $\sigma$ VH apresentou as maiores potencialidades na discriminação temática proposta. Destaca-se a maior sensibilidade do atributo polarimétrico H para discriminar a classe SS3, evidenciando que múltiplos mecanismos de espalhamentos contribuíram de modo equivalente para o sinal retornado ao sensor. A sensibilidade desse atributo e a importância da diversidade de mecanismos de espalhamento são também citadas por [14] ao mapearem e modelaram a estrutura da vegetação na várzea amazônica, obtiveram bons resultados classificatórios a partir de dados SAR polarimétricos de banda C.

Os atributos polarimétricos classificados individualmente, conjuntamente e/ou associados aos coeficientes de retroespalhamento também apresentaram sensibilidade para discriminar as classes com pouca presença da vegetação (SP, AC e PA). No entanto, de forma geral, constatou-se que os atributos e os coeficientes não apresentaram bom desempenho, principalmente na discriminação das classes SS1, FDG e PA.

As maiores confusões na classificação, que ocorreram na classe SS2 em relação a SS3, podem estar relacionadas com a complexidade estrutural própria desses estágios de regeneração natural e a predominância de um certo mecanismo de espalhamento que condiciona as respostas polarimétricas desses dois alvos florestais mencionados.



No que concerne às confusões apresentadas na classe SS1 em relação principalmente as classes PA e AC, pode ser em virtude da composição da estrutura do dossel da classe SS1 se apresentar com tamanhos menores de diâmetro e altura dos troncos, podendo espectralmente ser confundido com pastos sujos e com culturas agrícolas em estágios de crescimento vegetativo mais avançados.

A classe FDG também apresentou confusão no processo de classificação. É importante ponderar que a classe FDG tem características fisionômico-estruturais semelhantes às classes sucessionais de maior porte (SS3 e SS2), dependendo do grau de distúrbio nela realizado historicamente, contanto que muitas delas também estão em processo de recomposição natural florística. Parte das confusões da classe FDG com as classes sucessionais também pode estar relacionada por estas classes se encontrarem próximas umas das outras, além de, FDG incluir áreas florestais onde houve exploração madeireira indiscriminada.

Os coeficientes  $\sigma_{HV}$  e  $\sigma_{VV}$  classificados individualmente e/ou conjuntamente, apresentaram os menores desempenhos classificatórios quando comparados com os atributos polarimétricos. Este resultado encontra-se em consonância com as menores medidas de importância obtidos no ranking de importância dos atributos analisados. Contudo, ao associá-los com o atributo polarimétrico H obteve-se um melhor desempenho classificatório, com um aumento 52,0% do Índice Kappa.

Estudos realizados por [15] obtiveram bons resultados classificatórios para o mapeamento de cobertura da terra a partir de diferentes atributos extraídos dos coeficientes  $\sigma_{HV}$  e  $\sigma_{VV}$  provenientes do Sentinel-1A. Em consonância com a referência supracitada, especialistas [16] sugerem também que dados de retroespalhamento em banda C, adquiridos em uma única data, podem não distinguir muito bem entre as áreas florestadas e culturas agrícolas densas, indicando assim, que classificações com apenas uma única data podem levar a altas taxas de erros de classificação.

## 5. CONCLUSÕES

Constatou-se que os atributos provenientes da decomposição H-Alpha, combinados ou não, e/ou associado aos coeficientes de retroespalhamento apresentam melhores resultados classificatórios quando comparados aos obtidos somente pelos coeficientes de retroespalhamentos nas polarizações VV e VH, na classificação de cobertura da terra proposta. Os resultados preliminares deste estudo sugerem que os dados IW do Sentinel-1 podem ser uma importante fonte de informações para o mapeamento da cobertura da terra no domínio das florestas tropicais, uma vez se mostraram capazes de distinguir adequadamente aquelas de configuração fisionômico-estrutural primária e da fase de cronossequência sucessional avançada das demais feições tipológicas da cobertura vegetal, bem como solo em pousio/exposto e área cultivada. Para pesquisas futuras, sugere-se a análise textural das imagens IW e a utilização de outros métodos de classificações, além de imagens com distintas datas de aquisição.

## AGRADECIMENTOS

Os autores agradecem a CAPES e ao INPE, bem como ao ICMBio (Processo 38157-5) e ao Programa de Grande Escala da Biosfera-Atmosfera na Amazônia – LBA/Santarém. Os autores também

agradecem ao European Union's Horizon 2020 research and innovation programme under the Marie Skłodowska-Curie grant agreement no 638 660020, Royal Society Wolfson Research Merit Award (2011/R3), Natural Environment Research Council's National Center for Earth Observation.

## 6. REFERÊNCIAS

- [1] Asner, G.P.; Cloud cover in Landsat observations of Brazilian Amazon, *International Journal of Remote Sensing*, vol.22, n.18, pp.3855-3862, 2001.
- [2] Kasischke, E.S.; Melack, J.M.; Dobson, M.C.; The use of imaging radars for ecological applications—A review, *Remote Sens. Environ.* v.57, n.2, pp.141-156, 1997.
- [3] Santos, J.R. et al.; Analysis of airborne SAR data (L-band) for discrimination land use /land cover types in the Brazilian Amazon Region. In: *IEEE International Geoscience and Remote Sensing Symposium*, 2007.
- [4] Li, G. et al.; A comparative analysis of ALOS/PALSAR L-band and RADARSAT-2 C-band data for land-cover classification in a tropical moist region. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol.70, pp.26-38, 2012.
- [5] Pereira, L.O. et al.; ALOS/PALSAR data evaluation for land use and land cover mapping in the Amazon region, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol.9, n.12, pp. 5413-5423, 2016.
- [6] Boerner, W., S.; Polarimetry in radar remote sensing: basic and applied concepts. In: Lewis, A.J.; Henderson, F.M.; Ryerson, R.A. (eds.); *Principles and Applications of Imaging Radar: Manual of Remote Sensing*, New York: John Wiley & Sons, v.5. pp. 271-356.
- [7] European Space Agency (ESA); Copernicus: Sentinel-1 – The SAR imaging constellation for land and ocean services, disponível em <https://earth.esa.int/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-1>, acesso em: 09 ago.2018.
- [8] Lee, J.S.; Speckle analysis and smoothing of synthetic aperture radar images, *Computer Graphics and Image Processing*, v.17, pp.24-32, 1981.
- [9] Lee, J.S.; Grunes, M.R.; De Grandi, G.; Polarimetric SAR speckle filtering and its implication for classification, *IEEE Transactions on Geoscience and Remote Sensing*, v.37, n.5, pp.2363-2373, 1999.
- [10] Cloude, S.R.; Pottier, E.; An entropy based classification scheme for land application of polarimetric SAR, *IEEE Transactions on Geoscience and Remote Sensing*, v.35, n.1, pp.68-78, 1997.
- [11] Mitchell, T.M.; Machine learning, ed. Book News Ind: Portland, pp.432, 1997.
- [12] Hall, M.; Frank, E.F.; Reutemann, P.; Witten, I.H.; The weka data mining software: an update, *SIGKDD Explorations*, v.11, n.1, pp.10-18, Nov. 2009.
- [13] Landis, J.R.; Koch, G.G.; The measurement of observer agreement for categorical data, *Biometrics*, v. 33, n.1, pp.159-174, Mar. 1977.
- [14] Furtado, L.F.A.; Silva, T.S.F.; Novo, E.M.L.M.; Dual-season and full-polarimetric C band SAR assessment for vegetation mapping in the Amazon várzea wetlands, *Remote Sensing of Environment*, 174, pp.212-222, 2016.
- [15] Balzter, H. et al.; Mapping CORINE land cover from Sentinel-1A SAR and digital elevation model data using random forests, *Remote Sensing*, v.7, n.11, pp.14876-14898, 2015.
- [16] Saraiva, C.; Navarro, A. Avaliação do potencial das imagens Sentinel-1 para identificação de culturas agrícolas, *Conferência Nacional de Cartografia e Geodesia*, pp.1-9, 2015.