

Universidade Federal de Santa Maria

Ci. Fl., Santa Maria, v. 31, n. 3, jul./set., 2021

DOI: 10.5902/1980509837586

ISSN 1980-5098

Submissão: 01/04/2019 • Aprovação: 27/01/2021 • Publicação: 06/09/2021



## Artigo de Revisão

### Utilização de imagens SAR na classificação de formações florestais brasileiras

Use of SAR images for classification of Brazilian forest formations

Janisson Batista de Jesus<sup>I</sup>

Tatiana Mora Kuplich<sup>II</sup>

<sup>I</sup> Engenheiro Florestal, Doutorando, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil  
<https://orcid.org/0000-0001-8372-5557> – janisson.eng@gmail.com

<sup>II</sup> Bióloga, Tecnologista, Instituto Nacional de Pesquisas Espaciais, Santa Maria, RS, Brasil  
<https://orcid.org/0000-0003-0657-4024> – tatiana.kuplich@inpe.br

## RESUMO

O Brasil tem uma vasta área territorial com várias tipologias florestais compostas por diferentes fisionomias. É necessário o mapeamento das áreas de florestas no país, com o intuito de se conhecer sua distribuição espacial, bem como de avaliar sua dinâmica de expansão ou redução. Uma forma eficiente e confiável de se obter tais informações se dá por meio de técnicas de sensoriamento remoto, podendo ser aplicado o imageamento por radar (micro-ondas), que por sua vez tem sido o foco de muitos pesquisadores. Sendo assim, o objetivo do presente estudo é reunir as produções científicas relacionadas à utilização de imagens de radar aplicadas ao mapeamento das diferentes florestas no Brasil, analisando as mais recentes abordagens e técnicas de classificação. Notou-se uma significativa aplicação de imagens SAR em florestas do bioma Amazônia, principalmente para a detecção do desmatamento. As imagens do sistema do radar de banda L do ALOS/PALSAR foram as mais utilizadas nos mapeamentos das tipologias florestais, associadas a vários algoritmos classificadores, tais como: *Iterated Conditional Modes*, *Máxima Verossimilhança* e *random forest*. Os tipos de dados trabalhados nas classificações variaram de acordo com a capacidade polarimétrica de cada imagem, com destaque à maior utilização dos coeficientes de retroespalhamento e atributos extraídos das decomposições de suas matrizes. Observou-se ainda que a maioria dos trabalhos relacionaram os dados SAR com os obtidos por sensores ópticos. Portanto, o presente estudo possibilitou reunir várias aplicações de técnicas de classificação para a discriminação de diferentes formações florestais no Brasil utilizando o imageamento por micro-ondas, indicando a potencialidade dos vários classificadores nos dados SAR, mostrando que os sistemas de radar são uma importante tecnologia utilizada para o mapeamento de florestas no país.

**Palavras-chave:** Sensoriamento remoto; Vegetação; Radar de abertura sintética; Algoritmo classificador

## ABSTRACT

Brazil has a large territorial area with a large cover of vegetation and several forest typologies with different physiognomies. It is

necessary to map the forest areas in the country in order to know the spatial distribution and the dynamics of each forest formation. An efficient and reliable way to obtain this information is using remote sensing techniques, and radar – SAR - imaging can be applied, which in turn has been the focus of many researchers. Thus, the objective of the present study is to gather scientific productions related to the use of radar images applied to the mapping of different forests in Brazil, analyzing the most recent approaches and classification techniques. There was a significant application of SAR images in forests of the Amazon biome, mainly for the detection of deforestation. The images of the ALOS/PALSAR L-band radar system were the most used in the mapping of forest typologies, associated to several classifier algorithms, such as: Iterated Conditional Modes, Maximum Likelihood and random forest. The data types worked in the classifications varied according to the polarimetric capacity of each image, with emphasis on the greater use of backscattering coefficients and attributes extracted from matrix decompositions. It was also observed that most studies related SAR data to those obtained by optical sensors. Therefore, the present study made it possible to gather several applications of classification techniques for the discrimination of forest formations in Brazil using microwave imaging, indicating the potentiality of the various classifiers with SAR images, and showing that radar systems are an important technology that is being used for mapping forests in the country.

**Keywords:** Remote sensing of vegetation; Synthetic aperture radar; Classification algorithm

## 1 INTRODUÇÃO

O registro de dados por meio de técnicas de sensoriamento remoto é resultado da interação das ondas eletromagnéticas com os objetos na superfície terrestre, os sensores podem ser ópticos ou radares ativos (JOSHI *et al.*, 2016). A tecnologia de imageamento por meio dos sensores remotos possibilita mapear extensas áreas da Terra, apresentando uma alta resolução temporal com constantes revisitas, e viabilizando, portanto, o amplo uso de seus produtos para o mapeamento das formações florestais do globo ou em menores regiões (QIN *et al.*, 2017).

O sensoriamento remoto orbital é uma importante ferramenta para se obter dados consistentes, confiáveis e atualizados sobre os recursos florestais, e é fundamental para a avaliação e o monitoramento das florestas em uma escala global (MARTONE *et al.*, 2018). Os tipos de imagens mais comumente utilizados para mapeamento das florestas são provenientes de sensores a bordo de satélites e fotografias aéreas, porém, produtos de sensores ópticos possuem limitação relacionada à presença da cobertura de nuvens que impede a obtenção de dados, problema este parcialmente solucionado pela tecnologia do imageamento do radar de abertura sintética (SAR - *Synthetic Aperture Radar*), o qual fornece imagens que têm sido utilizadas para estudos da cobertura florestal (RAHMAN; SUMANTYO, 2012).

Os radares de abertura sintética são sensores que operam na região das micro-ondas (com maiores comprimentos de onda em relação à região dos dados ópticos), são sistemas ativos que não dependem da iluminação solar nem das condições meteorológicas, e podem ser utilizados sob condições atmosféricas adversas, dependendo do comprimento de onda, mostrando-se úteis na geração de informações na área florestal (ABOUD NETA; FREITAS; DUTRA, 2010; FREITAS; SANO; SOUZA, 2014), além de apresentarem potencial para complementar ou até mesmo substituir os sensores ópticos no mapeamento ou monitoramento do desmatamento, como na Amazônia (ALMEIDA-FILHO *et al.*, 2007).

O mapeamento de florestas tropicais tem sido crescentemente realizado por meio da utilização das imagens SAR, em especial devido aos satélites de observação global (QIN *et al.*, 2017), pois, além de não sofrerem influência da cobertura de nuvens, apresentam alguns produtos com uma melhor taxa de repetição quando comparados com alguns sistemas ópticos (HAGENSIEKER, *et al.*, 2017). Essa possibilidade de análise de áreas com elevada presença de nuvens, como em áreas tropicais, favoreceu o uso e a disseminação desse tipo de produto, aumentando, conseqüentemente, o desenvolvimento e a aplicação de metodologias de processamento digital dessas imagens. Contudo, as imagens SAR fornecem dados característicos do sistema, o que exige um conhecimento técnico para o entendimento das respostas resultantes da interação das micro-ondas com os objetos imageados (SILVA; SANTOS, 2011).

A classificação das imagens é resultado do reconhecimento dos padrões dos *pixels* processados por algoritmos classificadores. Apesar dos classificadores individuais serem considerados mais práticos, a combinação de vários classificadores pode melhorar a precisão da classificação, identificando o classificador de melhor desempenho. Para isso, existem vários tipos de classificadores como: *maximum likelihood classifier* (MLC), *artificial neural network* (ANN), *k-nearest neighbour* (KNN), *support vector machine* (SVM), *classification tree analysis* (CTA) e *object-based classification* (OBC), e posteriormente, a partir da avaliação da acurácia, indicam a qualidade da classificação (LU *et al.*, 2014).

A partir disso, o objetivo do presente estudo é reunir as produções científicas relacionadas à utilização de imagens de radar aplicadas ao mapeamento das diferentes formações florestais no Brasil, analisando as mais recentes abordagens e técnicas de classificação.

## 2 DESENVOLVIMENTO

### 2.1 Características das imagens SAR

Os radares são classificados em função de seus parâmetros, geralmente do comprimento de onda/frequência utilizados e da presença de uma ou mais polarizações. O comprimento de onda e a polarização emitidos pelo radar são definidos para o sistema e são constantes, ao passo que o ângulo de incidência varia numa determinada faixa de acordo com a posição dos objetos na faixa imageada (KUPLICH, 2012). Esses parâmetros SAR e as variáveis dos objetos na superfície terrestre (como geometria, conteúdo hídrico e rugosidade) determinarão imagens com diferentes características, por isso a importância de conhecer os parâmetros SAR ao selecionar o tipo de imagem e as características dos objetos ou coberturas estudadas (KUPLICH, 2012).

Os sistemas SAR registram, além da amplitude, a fase do retroespalhamento, que tem utilização em técnicas de análise como a polarimetria. Essa técnica lida com a natureza vetorial do campo elétrico da radiação eletromagnética e baseia-se na diferença de fase entre duas medidas SAR tomadas com polarizações diferentes. Existem muitos métodos de processamento e análise de dados SAR polarimétricos cujos fundamentos são diferentes dos métodos tradicionais de processamento digital de imagens. Os dados SAR polarimétricos são complexos e coerentes (com fase relativa constante) e simulados em matrizes de espalhamento (HENDERSON; LEWIS, 1998).

A polarimetria SAR (PolSAR) é uma técnica cada vez mais empregada na classificação de coberturas da terra e extração de parâmetros dos objetos na superfície terrestre. A polarimetria lida com dados SAR em matrizes de espalhamento, que relacionam a energia incidente com a energia (retro)espalhada, em todas as possíveis combinações de polarizações. As abordagens mais utilizadas em polarimetria são a análise estatística da informação polarimétrica para classificação de imagens (FREITAS *et al.*, 2008) e os modelos que buscam explicar a física dos processos de espalhamento (CLOUDE; POTTIER, 1997; FREEMAN; DURDEN, 1998). A decomposição de alvos é técnica polarimétrica que busca a separação das contribuições dos diferentes espalhadores para, dessa forma, identificá-los. A matriz de espalhamento (que pode assumir diversas formas em função do tipo de dado SAR e dos mecanismos de espalhamento considerados) é analisada para extrair a informação sobre os processos de espalhamento (KUPLICH, 2012).

A imagem SAR polarimétrica permite a extração de vários atributos como entropia, anisotropia, ângulo alfa, espalhamento superficial, volumétrico e *double-bounce*, assim como o coeficiente de retroespalhamento nas diferentes polarizações e os índices gerados pela combinação destes (WIEDERKEHR *et al.*, 2019).

Considerando estudos de imagens SAR para vegetação, devem-se considerar alguns mecanismos de espalhamento como o espalhamento direto dos troncos das árvores, espalhamento da interação tronco-solo (associado ao *double-bounce*), espalhamento da interação dossel-solo, e o espalhamento múltiplo dentro do dossel (espalhamento volumétrico) (SANTOS; GONÇALVES, 2009). De forma geral, a utilização de imagens SAR multipolarizadas permite uma maior discriminação de feições e, portanto, de classes de uso da terra e vegetação quando comparadas com as monopolarizadas (GUERRA; MURA;

FREITAS, 2010).

Atualmente, vários satélites com sistemas SAR estão em órbita, com uma crescente oferta de sensores que combinam diferentes frequências, em missões como: TerraSAR-X/TanDEM-X e Cosmo-SkyMed (banda X ~ 1 cm), RADARSAT-2 e Sentinel-1 (banda C ~ 5 cm), ALOS/PALSAR e ALOS-2 (banda L ~ 23 cm). Esses sistemas permitem aquisição de dados SAR com variadas frequências e polarizações, além da informação polarimétrica (HAGENSIEKER; WASKE, 2018; WIEDERKEHR *et al.*, 2019), facilitando o mapeamento de uso/cobertura da terra e especificamente de formações florestais.

## 2.2 Aplicações de imagens SAR na classificação de florestas no Brasil

Mapeando todo o globo terrestre, incluindo as diversas formações florestais, Shimada *et al.* (2014) realizaram a classificação de floresta/não floresta, examinando o retroespalhamento da banda L do ALOS/PALSAR da Amazônia brasileira e o Acre como uma região específica de classificação. Os autores mapearam tanto a área florestada como desmatada de 2007 a 2010, verificando que a polarização HV favoreceu uma melhor discriminação das classes floresta e não floresta. Além disso, a pesquisa teve uma elevada precisão da classificação de florestas e não florestas em nível global com variações regionais quando comparada com projetos como *Degree Confluence Project*, *Forest Resource Assessment* e *Google Earth* com uma concordância geral de 85%, 91% e 95%, respectivamente.

Martone *et al.* (2018) apresentaram o primeiro estudo global para o mapeamento de áreas florestadas e não florestadas a partir de dados interferométricos da banda X do TanDEM-X, na polarização HH. Os autores utilizaram o fator de correlação de volume derivado da quantidade de perda da coerência ocasionada pelos fenômenos de espalhamento de volume, que, por sua vez, ocorrem na presença da vegetação, utilizando o classificador baseado na lógica *fuzzy*. O mapeamento resultou em mais de 90% de concordância geral em relação a outras referências. A floresta amazônica foi analisada neste estudo, com uma área-teste no estado de Rondônia, na qual foi verificada a potencialidade deste sensor para monitorar as áreas florestais.


Considerando o continente como área de estudo, Qin *et al.* (2017) mapearam as florestas de toda a América do Sul com dados do ALOS/PALSAR em combinação com dados MODIS de 2007 a 2010, obtendo a menor acurácia geral de 96,48% em 2009, e uma máxima de 99,21% em 2008 para diferenciar floresta de não floresta. Apesar disso, os autores afirmam que nas regiões com cobertura esparsa e nas bordas limítrofes das florestas existe alta incerteza na discriminação da cobertura florestal. No entanto, há pouca incerteza nas áreas com densa cobertura florestal da Bacia Amazônica. Os autores indicam ainda a combinação de imagens de ambos os sensores para melhorar a precisão e reduzir as incertezas no mapeamento anual de florestas no continente.

Almeida-Filho *et al.* (2007) analisaram quatro classes de cobertura da terra (floresta primária, áreas recém-cortadas, queimadas e regeneração da vegetação) em uma região da floresta Amazônica do estado de Rondônia, a partir de dados SAR do *Japanese Earth Resources Satellite* (JERS-1) em conjunto com imagens *Landsat/Thematic Mapper* (TM). Os autores conseguiram detectar desmatamento florestal, bem como outros estágios da vegetação (Figura 1), e contradisseram a ideia geral de que florestas primárias sempre apresentam altos valores de retroespalhamento, uma vez que observaram que as áreas desmatadas, em algumas circunstâncias, podem ter um retroespalhamento mais forte, dependendo da cobertura da terra. Destacaram, portanto, o potencial das polarizações HH e HV no mapeamento da vegetação, evidenciando o uso da banda L aplicado ao mapeamento do desmatamento em florestas tropicais.

Em um trecho da floresta Amazônica situada no estado do Pará, Liesenberg e Gloaguen (2013) utilizaram dados de diferentes modos de polarização (única, dupla e quádrupla) do ALOS/PALSAR para a classificação de fisionomias florestais (floresta primária, ripária e em estágios sucessionais). Utilizaram o algoritmo SVM para classificação da intensidade de retroespalhamento, das características polarimétricas, da coerência interferométrica e de parâmetros de textura. Foi observado que o modo com quatro polarizações mostrou maior acurácia na classificação, porém constataram que a precipitação afetou este processo. Os autores sugerem ainda a integração de dados SAR com ópticos, uma vez que verificaram redução do erro na classificação, atingindo uma precisão global de 85% ao combinar com imagens do Landsat.

Figura 1 – Mapeamento de diferentes classes de vegetação na Amazônia: (1) desmatamento antes de outubro de 1995, (2) floresta primária não perturbada, (3) regeneração de vegetação e (4) floresta recém-cortada/queimada

Figure 1 – Mapping of different vegetation classes in the Amazon: (1) deforestation prior to October 1995, (2) undisturbed primary forest, (3) vegetation regrowth, and (4) newly slashed/burned fores



Fonte: Almeida-Filho *et al.* (2007)

Source: Almeida-Filho *et al.* (2007)

Li *et al.* (2012) testaram vários classificadores (MAXVER, CTA, *fuzzy* ARTMAP - um método de rede neural, KNN, OBC e SVM) em imagens da banda L do ALOS/PALSAR e C do RADARSAT-2 com medidas de textura (variância, homogeneidade, dissimilaridade, contraste, entropia, segundo momento) em conjunto com as diferentes polarizações, na região de Altamira, estado do Pará. Os autores notaram que o uso de atributos isolados gera menores precisões na classificação, indicando, portanto, a combinação de retroespalhamento e textura. Além disso, a imagem na banda L forneceu melhor acurácia na classificação para classes que incluem florestas e sucessão florestal, obtendo uma precisão geral de 72%, enquanto que na banda C essa precisão foi de apenas 54,7%. Quanto ao algoritmo classificador, os métodos CTA e *fuzzy* ARTMAP foram superiores aos demais analisados, enquanto que o KNN apresentou o pior desempenho.

Ainda em Altamira, no Pará, Lu *et al.* (2014) também compararam a classificação de estágios sucessionais (inicial, intermediário e avançado) na floresta Amazônica com dados ALOS/PALSAR e os diferentes algoritmos (MAXVER, ANN, KNN, SVM, CTA e OBC) e concluíram que imagens deste sensor não permitem a distinção destes estágios da vegetação. Contudo, observaram que a fusão dos dados PALSAR com Landsat fornece uma classificação mais acurada do que quando utilizados separadamente. E de forma geral, recomendaram o MAXVER para a classificação da vegetação em área tropical úmida usando fusão das imagens ópticas e SAR.


Carreiras *et al.* (2017), utilizando as imagens dos mesmos sensores orbitais em uma análise temporal (de 2007 a 2010), mapearam a floresta secundária (Amazônia) nos municípios de Manaus, Santarém e Machadinho d'Oeste utilizando o algoritmo *random forest* (RF). Nesse estudo foi avaliada a combinação entre as intensidades nas polarizações HH e HV e as reflectâncias do visível e infravermelho próximo e de ondas curtas. Os autores chegaram a uma acurácia geral de 95-96% na discriminação da floresta madura, floresta secundária e área não florestal, com maior erro entre a classificação das duas classes de floresta nas quais foram observados os maiores erros de omissão e comissão para a floresta secundária, a qual apresentava confusão com a classe de floresta madura.

Utilizando imagens da banda C com polarizações VV e VH do Sentinel-1, Diniz (2019) avaliou a potencialidade deste sensor no mapeamento em duas caracterizações: 1- da floresta com outras classes; 2- dentro da classe floresta, a fim de, possivelmente, discriminá-la em: floresta degradada, floresta primária e sucessões secundárias avançada, intermediária e

inicial, na região Amazônica de Ariquemes, Rondônia. Foram testados os atributos relacionados aos coeficientes de retroespalhamento (nas polarizações VV, VH e a razão VH/VV), da decomposição polarimétrica (H e  $\alpha$ ) e da coerência interferométrica ( $\gamma_{VH}$ ,  $\gamma_{VV}$ ), a partir do uso dos classificadores SVM e RF, em comparação com a classificação de imagens ópticas do Sentinel-2. O estudo mostrou que a utilização conjunta de todos os atributos obtidos do Sentinel-1 possibilitou uma melhor acurácia global com o uso de ambos os classificadores, porém o RF mostrou melhores resultados para o mapeamento (85,7% e 71,6%, respectivamente às duas caracterizações avaliadas), sendo capaz de detectar as feições florestais (Figura 2).

Figura 2 – Resultado dos mapeamentos das caracterizações 1 e 2

Figure 2 – Classifications results for characterizations 1 and 2



Fonte: Modificado de Diniz (2019)

Em que: a) Classificação SVM; b) Classificação RF e c) Diferença entre SVM e RF.

Source: Modified from Diniz (2019)

In where: a) SVM classification; b) RF classification and c) Difference between SVM and RF.

Sheldon, Xiao e Biradar (2012) mapearam a floresta perenifólia da Amazônia a partir da associação de imagens MODIS (500 m) e ALOS/PALSAR, obtendo cerca de 96,7% de concordância entre os *pixels* identificados como floresta com uso do classificador árvore de decisão, o que se tornou uma alternativa de identificação e mapeamento florestal nesta área, capaz também de detectar o seu desmatamento.

Cremon, Rossetti e Zani (2014) notaram uma classificação mais acurada das fitofisionomias na Amazônia (94% de acurácia global) ao integrar dados ópticos, no caso o Landsat 5, com o ALOS/PALSAR, também com o método de árvore de decisão. Consideraram que as polarizações SAR HV e HH se destacaram na discriminação das classes de floresta (HV) e vegetação aberta (HH), e na classificação dos tipos de vegetação aberta (vegetação aberta arbórea e arbustiva).

Watanabe *et al.* (2018) observaram, utilizando a banda L do PALSAR-2, que o coeficiente de retroespalhamento por área normal ao ângulo de incidência ( $\gamma^0$ ) tanto HH como HV pode ser útil na detecção de desmatamento da floresta amazônica. Foi

verificado que  $\gamma_{HH}^0$  pode ser um bom parâmetro para detectar um desmatamento em estágio inicial, e o  $\gamma_{HV}^0$  para desmatamentos em estágio avançado, este por ter maior sensibilidade aos ramos deixados no solo e rugosidade superficial e maior sensibilidade à biomassa florestal.

Diferentes combinações de canais individuais (HH, HV e VV), aos pares (HH+HV, HV+VV e HH+VV) e em conjunto (HH+HV+VV) de imagens ALOS/PALSAR e os classificadores MAXVER-ICM (*Iterated Conditional Modes*) (*pixel a pixel*) e *Bhattacharyya* (por regiões) foram testados por Aboud Neta, Freitas e Dutra (2010), que verificaram que o segundo classificador obteve maior acurácia em comparação com o mapa do PRODES (Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite, feito pelo INPE desde 1988). Os autores constataram também que a polarização dual HH+HV foi a melhor para discriminar o incremento do desflorestamento em uma área localizada na Floresta Nacional de Tapajós, apresentando menor perda de informação e maior acurácia na classificação. Analisando individualmente as polarizações, os autores observaram que a HV rendeu melhores resultados na separação da classe floresta de incremento de desmatamento, quando comparada com HH e VV.

Guerra, Mura e Freitas (2010), utilizando um sensor aerotransportado de banda L instalado no veículo R99 da Força Aérea Brasileira, avaliaram o desmatamento da Amazônia na região Sudeste do Estado do Acre por meio da classificação MAXVER seguida do algoritmo ICM. Os autores obtiveram uma boa acurácia através do par HH+HV com o mapa de referência do PRODES, apresentando um índice *Kappa* de 0,68, com menores valores deste índice quando polarizações individuais foram utilizadas.

Souza *et al.* (2012) compararam dados do ALOS/PALSAR com imagens de radar obtidas com a aeronave R99 para verificar áreas desmatadas na região amazônica dos municípios de Machadinho d'Oeste (RO), Confresa (MT) e Medicilândia (PA), conseguindo acurácias de 86,4%, 84,4% e 83%, respectivamente. Os pesquisadores obtiveram maior precisão nos resultados da classificação semiautomática se comparados aos obtidos pela classificação manual realizada pelo Sistema de Proteção da Amazônia (SIPAM), que atualmente é o Centro Gestor e Operacional do Sistema de Proteção da Amazônia (Censipam), ligado ao Ministério da Defesa e tem o objetivo de promover, entre outros, o desenvolvimento sustentável da Amazônia Legal. Os autores também chamam a atenção para o período de aquisição das imagens. Avaliações tanto na estação chuvosa como na seca permitem compreender melhor a variabilidade do retroespalhamento, tendo em vista que na estação chuvosa foi observado um aumento abrupto do retroespalhamento nas polarizações HH e HV decorrente de uma maior constante dielétrica, assim como de um maior volume da vegetação, enquanto que na estação seca foi destacada uma exposição do solo.

Rahman e Sumantyo (2012) testaram o classificador híbrido de duas bandas C e L, respectivamente, do SIR-C e ALOS/PALSAR, com dados Landsat para classificação da vegetação da região Amazônica do Mato Grosso. O objetivo era quantificar o desmatamento, e observaram que ambas as bandas foram capazes de distinguir as categorias de não floresta e floresta, com uma acurácia superior a 90% para classe de floresta. Porém, obtiveram uma redução considerável ao separar a categoria de não floresta em diferentes classes como floresta em regeneração e pastagem sazonalmente inundada.

Em área de várzea, Nunes, Souza Filho e Ferreira (2011) avaliaram a discriminação de fitofisionomias das Reservas de Desenvolvimento Sustentável Amanã e Mamirauá, e áreas adjacentes, utilizando dados SAR aerotransportado R99 (QUAD-POL/Banda L) a partir do algoritmo ICM de classificação contextual e com classificador pontual ou *pixel a pixel* (MAXVER) em imagens com amplitude em variadas polarizações (HH-HV; HH-HV-VV; HH-HV-VV-Textura) e em conjunto com uma banda de textura (contraste). Os autores obtiveram uma melhor classificação das fitofisionomias existentes na Floresta de Várzea, com um índice *Kappa* de 0,8963 ao adotarem a abordagem utilizando polarizações variadas associadas à banda de textura (HH-HV-VV-Textura) com o classificador ICM.

A classificação de diversos *habitats* em sub-regiões no Pantanal contendo até 10 classes associadas à vegetação, incluindo florestas e fitofisionomias do Cerrado, também pode ser realizada com acurácia de 80% utilizando a banda L do ALOS/PALSAR e C do RADARSAT-2. Foi testada uma combinação de limiares refinados, regras hierárquicas e o algoritmo

*supervised nearest neighbour algorithm (eCognition Feature Space Optimization)* (EVANS *et al.*, 2014). Os autores verificaram que a combinação das duas bandas nas polarizações HH e HV associadas com limites médios, regras hierárquicas e a ferramenta *Feature Space Optimization* utilizando parâmetros adicionais resultou em uma alta precisão geral.

Com os mesmos sensores (ALOS/PALSAR e RADARSAT-2), e com as imagens da banda C do ENVISAT/ASAR, Evans *et al.* (2013) avaliaram diferentes resoluções espaciais (12,5 m e 50 m) na classificação da região da Baixa Nhecolândia no Pantanal, analisando também em escala regional cada sub-região do Pantanal, a partir do método de classificação orientado ao objeto, para definirem as formações florestais existentes nessas regiões. O estudo indicou que imagens de maior resolução espacial (12,5 m) possibilitaram maior precisão na classificação (83%), sugerindo que em ambientes de alta heterogeneidade das paisagens sejam aplicadas imagens de resolução espacial mais fina. Considerando 10 classes e todas as sub-regiões do Pantanal, os autores encontraram uma acurácia de 80% na classificação, recomendando avaliações com imagens de melhor resolução espacial para se verificar o possível aumento deste valor. Sugerem ainda a adição de dados das bandas C e L para classificação de vários estágios do ciclo hidrológico nesse tipo de estudo.

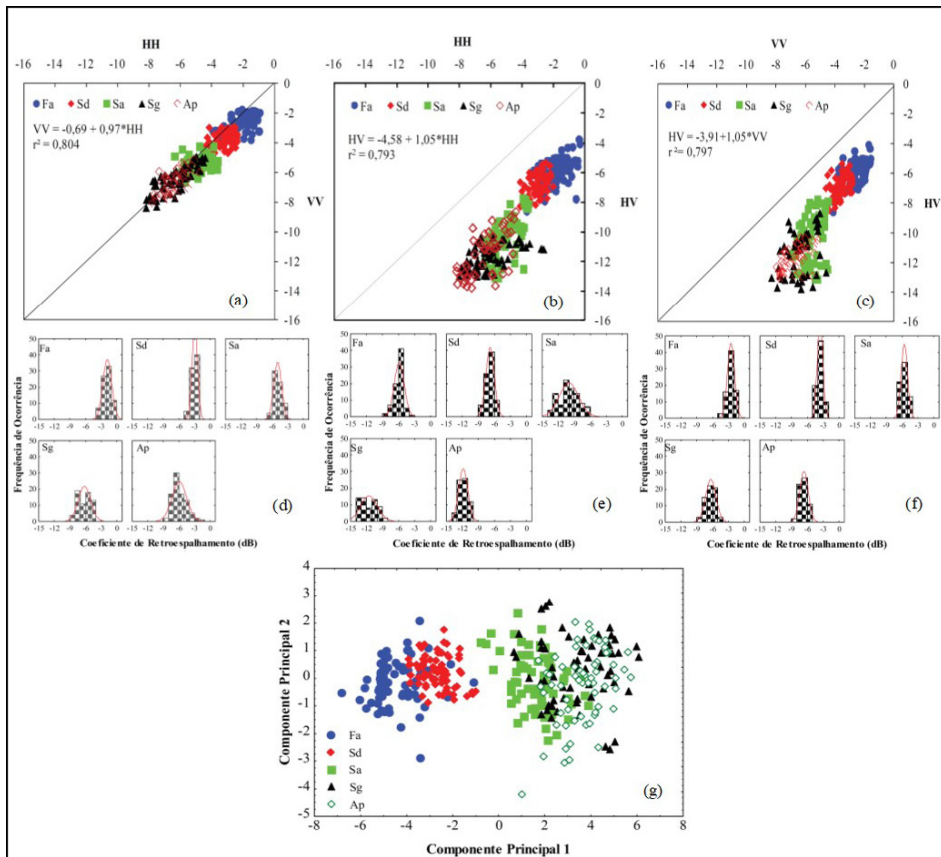
A potencialidade do ALOS/PALSAR na discriminação da cobertura vegetal do bioma Cerrado na região do Médio Taquari, Mato Grosso do Sul, também foi constatada por Freitas, Sano e Souza (2014), que tiveram sucesso na separação das classes analisadas de vegetação em todas as polarizações (HH, HV e VV, apesar da última ter sido a melhor), com exceção apenas da distinção entre Savana Gramíneo-Lenhosa e Pastagens Cultivadas. Os autores observaram uma forte relação linear entre as polarizações analisadas, com coeficientes de determinação superiores a 0,79, denotando que, independentemente do tipo de polarização, quanto maior a estrutura da vegetação, maiores serão os valores dos coeficientes de retroespalhamento, mostrando ainda a distinção de três grupos de vegetação com redução consecutiva dos valores que correspondem respectivamente à Floresta Estacional, Savana Densa e demais vegetações menos arborizadas (Figura 3 (a), (b) e (c)).

Além disso, os autores notaram que estas classes apresentam diferentes comportamentos estatísticos em relação à intensidade do retroespalhamento nas polarizações utilizadas, o que pode favorecer o processo de discriminação, uma vez que foram verificados valores menores para o coeficiente de retroespalhamento na polarização HV, juntamente com uma pequena tendência de maiores valores da HH em relação à VV (Figura 3 (d), (e) e (f)). Verificando os resultados da análise discriminante, os autores constataram que a polarização VV apresentou melhor capacidade de discriminação, sendo a variável mais importante para explicar a Componente Principal 1, a qual indicou a diferenciação dos grupos com maiores estruturas vegetais (Floresta Estacional, Savana Densa e Savana Arborizada (Figura 3 (g))).

Figura 3 – Dispersão de valores de retroespalhamento entre as polarizações HH e VV (a), HH e HV (b) e VV e HV (c), distribuição histogrâmica dos coeficientes de retroespalhamento HH (d), HV (e) e VV (f), e relação entre componentes principais 1 e 2 (g)

Figure 3 – Backscatter values dispersion between HH and VV (a), HH and HV (b) and VV and HV polarizations (c), histogram distribution of backscatter coefficients HH (d), HV (e) and VV (f), and relation between principal components 1 and 2 (g)





Fonte: Modificado de Freitas, Sano e Souza (2014)

Onde: Fa = Floresta Estacional; Sd = Savana Densa; Sa = Savana Arborizada; Sg = Savana Gramíneo-Lenhosa; e Ap = Pastagem Cultivada.


Source: Modified from Freitas, Sano and Souza (2014)

Where: Fa = Seasonal Forest; Sd = Dense Savanna; Sa = Woody Savannah; Sg = Gramineous-Woody Savanna; and Ap = Cultivated Pasture.

No bioma Caatinga, Silva e Santos (2011) avaliaram imagem do ALOS/PALSAR no mapeamento da caatinga (arbórea, arbórea-arbustiva e arbustiva) na região semiárida do Brasil, no sertão do estado de Pernambuco. Para isso, utilizaram a classificação MAXVER-ICM e Wishart, analisando imagens filtradas em pares e/ou conjunto de componentes derivadas da matriz de covariância. Constatou-se que o melhor desempenho ocorreu com utilização da classificação MAXVER-ICM a partir do conjunto de componentes  $[A_{HH}, A_{HV}, A_{HH+HV}]$  (Figura 4), com um índice *Kappa* de 0,58 e uma exatidão global de 66%. Apesar do resultado da matriz de confusão com esses três componentes se diferenciar estatisticamente ao nível de 5% de significância das demais, não foi verificada, entre as classificações, uma redução nos erros de inclusão entre as classes de vegetação para permitir uma melhor discriminação das fisionomias da caatinga. Os autores ressaltam ainda a importância de se integrar dados de outras frequências provenientes de outros sensores SAR, bem como uma análise multitemporal para se poder obter melhor estratificação temática das fisionomias de caatinga.

Figura 4 – Imagem ALOS/PALSAR em composição colorida (R ( $A_{HH}$ ) G ( $A_{HH+HV}$ ) B( $A_{HV}$ )) da região de Serra Talhada (Pernambuco) (a) e resultado da classificação MAXVER-ICM  $[A_{HH}, A_{HV}, A_{HH+HV}]$  (b)

Figure 4 – ALOS/PALSAR image in color composition (R ( $A_{HH}$ ) G ( $A_{HH+HV}$ ) B ( $A_{HV}$ )) of Serra Talhada region (Pernambuco) (a) and its classification using MAXVER-ICM  $[A_{HH}, A_{HV}, A_{HH+HV}]$  (b)




Fonte: Silva e Santos (2011)

Source: Silva and Santos (2011)

Pereira, Kampel e Cunha-Lignon (2012) realizaram o mapeamento da vegetação de manguezais na costa sul do estado de São Paulo utilizando imagens multipolarizadas da banda L do ALOS/PALSAR, ambos baseados em 10 atributos incoerentes: coeficientes de retroespalhamento ( $\sigma^0$ ) para as polarizações HH, HV e VV, razão de polarização paralela ( $R_p$ ), razão de polarização cruzada ( $R_c$ ) utilizando o denominador HH e VV, e potência total (Pt). Três deles são índices de vegetação SAR: índice de biomassa, índice de estrutura de dossel e índice de espalhamento de volume. Os índices, junto à polarização HH, foram os atributos mais relevantes no mapeamento deste tipo de fisionomia florestal, e uma pequena diferença foi verificada na classificação entre estes dados, com a utilização de todos os atributos incoerentes, apresentando a classificação (Figura 5) com a maior acurácia global (80,73%), enquanto que apenas com o uso dos índices de vegetação atingiu o valor de 80,36%, respectivamente. Os autores ainda alertam para a confusão entre as classes de mangue e área urbana em ambas as abordagens (pelo fenômeno de *corner reflection* ou refletores de canto, que causa retornos extremamente altos em ambas as classes).

Figura 5 – Identificação da classe de mangue destacada em amarelo uma imagem R (HH) G (HV) B (VV), a partir da classificação contextual baseada em frequência usando 10 atributos incoerentes como parâmetros de entrada

Figure 5 – Identification of mangue class highlighted in yellow an image R (HH) G (HV) B (VV), from the frequency-based contextual classification using 10 incoherent attributes as input parameters



Fonte: Modificado de Pereira, Kampel e Cunha-Lignon (2012)

Source: Modified from Pereira, Kampel and Cunha-Lignon (2012)

Apesar da quantidade relevante de estudos para classificação de florestas no Brasil, existem lacunas em estudos mais específicos das fitofisionomias. Essas informações podem servir para compreender melhor as interações entre o sinal polarizado e as florestas, assim como os mecanismos de espalhamento (SANTOS; GONÇALVES, 2009). Adicionalmente, poucos trabalhos focam na integração de dados de diferentes bandas (frequências) de micro-ondas para o mapeamento da cobertura da terra (HAGENSIEKER; WASKE, 2018), o que, por sua vez, também poderia ser aplicado nas diversas formações florestais ao longo do território brasileiro. Além disso, é importante ressaltar a importância da utilização de diferentes sensores conforme indicado por Joshi *et al.* (2016), que constatarem, em seu estudo de revisão sobre a fusão de imagens ópticas e de radar aplicado ao mapeamento e monitoramento do uso da terra, que a maior parte dos estudos apresentam resultados mais acurados de classificação a partir da combinação destes dois tipos de imagens.

### 3 CONSIDERAÇÕES FINAIS

O estudo permitiu reunir diversos estudos sobre a aplicação de imagens SAR nos diferentes tipos de formações florestais ao longo do território brasileiro, com a avaliação de variados algoritmos classificadores, com a utilização de várias técnicas e abordagens, mostrando que essa tecnologia de imageamento pode ser uma ferramenta a ser utilizada em trabalhos de mapeamento da vegetação, e indicando a relevância do uso dessas imagens para a comunidade científica do sensoriamento remoto.

Foi possível também verificar que a maior parte dos trabalhos está voltada à floresta amazônica, principalmente quando relacionados à identificação de desmatamento e diferenciação entre floresta e outras coberturas vegetais. Ficou evidenciado que as imagens SAR podem ser utilizadas nas demais tipologias florestais existentes no país, cujos estudos ainda são escassos. Espera-se um aumento no número de estudos com dados SAR para as florestas brasileiras, com a utilização das imagens SAR gratuitas da missão Sentinel-1.

### REFERÊNCIAS

ABOUD NETA, S. R.; FREITAS, C. C.; DUTRA, L. V. Uso de imagens ALOS/PALSAR multipolarizadas para detecção de incremento de desflorestamento na Amazônia. **Revista Brasileira de Cartografia**, Uberlândia, v. 62, p. 417-431, 2010.

- ALMEIDA-FILHO, R. *et al.* Detecting deforestation with multitemporal L-band SAR imagery: a case study in western Brazilian Amazônia. **International Journal of Remote Sensing**, Abingdon, v. 28, n. 6, p. 1383-1390, 2007.
- CARREIRAS, J. M. B. *et al.* Mapping major land cover types and retrieving the age of secondary forests in the Brazilian Amazon by combining single-date optical and radar remote sensing data. **Remote Sensing of Environment**, Amsterdam, v. 194, p. 16-32, 2017.
- CLOUDE, S. R.; POTTIER, E. An entropy based classification scheme for land applications of polarimetric SAR. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 35, p. 68-78, 1997.
- CREMON, É. H.; ROSSETTI, D. de F.; ZANI, H. Classification of vegetation over a residual megafan landform in the amazonian lowland based on optical and SAR imagery. **Remote Sensing**, Basel, v. 6, p. 10931-10946, 2014.
- DINIZ, J. M. F. de S. **Avaliação do potencial dos dados polarimétricos Sentinel-1A para mapeamento do uso e cobertura da terra na região de Ariquemes-RO**. 2019. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.
- EVANS, T. L. *et al.* Large-scale habitat mapping of the Brazilian Pantanal wetland: a synthetic aperture radar approach. **Remote Sensing of Environment**, Amsterdam, v. 155, p. 89-108, 2014.
- EVANS, T. L. *et al.* A SAR fine and medium spatial resolution approach for mapping the Brazilian Pantanal. **Geografia**, Rio Claro, v. 38, p. 25-43, 2013.
- FREEMAN, A.; DURDEN, S. L. A. A three component scattering model for polarimetric SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 36, n. 3, p. 963-973, 1998.
- FREITAS, C. *et al.* Land Use and Land Cover Mapping in the Brazilian Amazon Using Polarimetric Airborne P-Band SAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 46, p. 2956-2970, 2008.
- FREITAS, D. M. de; SANO, E. E.; SOUZA, R. A. de. Potencial das imagens multipolarizadas do satélite ALOS/PALSAR na discriminação de cobertura vegetal do bioma pantanal: estudo de caso na região do médio Taquari, MS. **Revista Brasileira de Cartografia**, Uberlândia, v. 66, n. 2, p. 209-221, 2014.
- GUERRA, J. B.; MURA, J. C.; FREITAS, C. C. Discriminação de incrementos de desflorestamento na Amazônia com dados SAR R99B em banda L. **Acta Amazonica**, Manaus, v. 40, n. 3, p. 557-566, 2010.
- HAGENSIEKER, R. *et al.* Tropical land use land cover mapping in Pará (Brazil) using discriminative Markov random fields and multi-temporal TerraSAR-X data. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, v. 63, p. 244-256, 2017.
- HAGENSIEKER, R.; WASKE, B. Evaluation of Multi-Frequency SAR Images for Tropical Land Cover Mapping. **Remote Sensing**, Basel, v. 10, p. 257, 2018.
- HENDERSON, F. M.; LEWIS, A. J. (ed). Principles and Applications of Imaging Radar. Manual of Remote Sensing. 3rd ed. New York: John Wiley, 1998. v. 2.
- JOSHI, N. *et al.* A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. **Remote Sensing**, Basel, v. 8, n. 1, p. 70, 2016.
- KUPLICH, T. M. A vegetação através de dados SAR. *In*: PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. (ed.). **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. p. 113-133.
- 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**, Amsterdam, v. 70, p. 26-38, 2012.
- LIESENBERG, V.; GLOAGUEN, R. Evaluating SAR polarization modes at L-band for forest classification purposes in Eastern Amazon, Brazil. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, v. 21, p. 122-135, 2013.
- LU, D. *et al.* Comparative analysis of approaches for successional vegetation classification in the Brazilian Amazon. **GIScience & Remote Sensing**, Abingdon, v. 51, n. 6, p. 695-709, 2014.
- MARTONE, M. *et al.* The global forest/non-forest map from TanDEM-X interferometric SAR data. **Remote Sensing of Environment**, Amsterdam, v. 205, p. 352-373, 2018.
- NUNES, G. M.; SOUZA FILHO, C. R. de; FERREIRA, L. G. Discriminação de fitofisionomias de floresta de várzea a partir do algoritmo *Iterated Conditional Modes* aplicado aos dados SAR/R99 (QUAD-POL/Banda L). **Acta Amazonica**, Manaus, v. 41, n. 4, p. 471-480, 2011.
- PEREIRA, F. R. de S.; KAMPEL, M.; CUNHA-LIGNON, M. Mapping of mangrove forests on the southern coast of São Paulo, Brazil, using synthetic aperture radar data from ALOS/PALSAR. **Remote Sensing Letters**, Abingdon, v. 3, n. 7, p. 567-576, 2012.
- QIN, Y. *et al.* Annual dynamics of forest areas in South America during 2007–2010 at 50- m spatial resolution. **Remote Sensing of Environment**, Amsterdam, v. 201, p. 73-87, 2017.
- RAHMAN, M. M.; SUMANTYO, J. T. S. Quantifying deforestation in the Brazilian Amazon using Advanced Land Observing Satellite Phased Array L-band Synthetic Aperture Radar (ALOS PALSAR) and Shuttle Imaging Radar (SIR)-C data. **Geocarto International**, Abingdon, v. 27, n. 6, p. 463-478, 2012.

SANTOS, J. R; GONÇALVES, F. G. Polarimetric responses patterns and scattering mechanisms of forest targets from L-band radar. **Revista Brasileira de Cartografia**, Uberlândia, v. 61, n. 4, p. 391-397, 2009.

SHELDON, S.; XIAO, X.; BIRADAR, C. Mapping evergreen forests in the Brazilian Amazon using MODIS and PALSAR 500-m mosaic imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 74, p. 34-40, 2012.

SHIMADA, M. *et al.* New global forest/non-forest maps from ALOS PALSAR data (2007-2010). **Remote Sensing of Environment**, Amsterdam, v. 155, p. 13-31, 2014.

SILVA, F. F. da; SANTOS, J. R. Imagens ALOS/PALSAR na classificação da cobertura vegetal da região semiárida brasileira. **Revista Brasileira de Cartografia**, Uberlândia, v. 63, p. 75-83, 2011.

SOUZA, E. L. *et al.* Mapeamento semi-automatizado de áreas desmatadas na Amazônia utilizando imagens multitemporais do satélite ALOS, sensor PALSAR. **Revista Brasileira de Cartografia**, Uberlândia, v. 64, n. 3, p. 349-366, 2012.

WATANABE, M. *et al.* Early-stage deforestation detection in the tropics With L-band SAR. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, New York, v. 11, n. 6, p. 2127-2133, 2018.

WIEDERKEHR, N. C. *et al.* Analysis of the target decomposition technique attributes and polarimetric ratios to discriminate land use and land cover classes of the Tapajós region. **Bulletin of Geodetic Sciences**, Curitiba, v. 25, n. 1, e2019002, 2019.

## **Contribuição de Autoria**

### **1 – Janisson Batista de Jesus**

Contribuição: Conceituação, Curadoria de dados, Investigação, Metodologia, Administração do projeto, Visualização de dados, Escrita – primeira redação

### **2 – Tatiana Mora Kuplich**

Contribuição: Análise Formal, Supervisão, Escrita – revisão e edição