



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E GEODINÂMICA

Utilização de dados SAR multi-bandas na discriminação da vegetação secundária em uma área de *hotspot* de desmatamento na Amazônia Legal brasileira

Bárbara Hass Kiyohara

TESE DE DOUTORADO N° 79

Orientador: Prof. Dr. Edson Eyji Sano – Embrapa Cerrados

Brasília, 2023



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E GEODINÂMICA

Utilização de dados SAR multi-bandas na discriminação da vegetação secundária em uma área de *hotspot* de desmatamento na Amazônia Legal brasileira

Bárbara Hass Kiyohara

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmica, na área de concentração Geoprocessamento e Análise Ambiental, do Instituto de Geociências da Universidade de Brasília (UnB), para obtenção do título de Doutora.

Brasília, 2023

Ficha de identificação da obra

Kiyohara, Bárbara Hass
Utilização de dados SAR multi-bandas na discriminação da
vegetação secundária em uma área de hotspot de desmatamento
na Amazônia Legal brasileira / Bárbara Hass Kiyohara;
orientador Edson Eyji Sano. -- Brasília, 2023.
142 p.

Tese (Doutorado em Geociências Aplicadas) -- Universidade
de Brasília, 2023.

1. Vegetação secundária. 2. SAR. 3. Amazônia. 4. Random
Forest. 5. Support Vector Machine. I. Eyji Sano, Edson,
orient. II. Título.

Bárbara Hass Kiyohara

Título: Integração de dados SAR multi-bandas na discriminação da vegetação secundária em uma área de *hotspot* de desmatamento na Amazônia Legal brasileira

O presente trabalho em nível de doutorado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Dr. Marco Ianniruberto
Universidade de Brasília/Instituto de Geociências

Profa. Dra. Cláudia Maria de Almeida
Instituto Nacional de Pesquisas Espaciais

Prof. Dr. Fábio Furlan Gama
Instituto Nacional de Pesquisas Espaciais

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutora em Geociências Aplicadas e Geodinâmica

Coordenação do Programa de Pós-Graduação

Prof. Dr. Edson Eyji Sano
Orientador

Brasília, 2023

Não basta saber,
é preciso aplicar,
não basta querer,
é preciso também fazer.
(Joham Goethe)

Este trabalho é dedicado à minha filha Sofia.

AGRADECIMENTOS

Primeiramente, gostaria de agradecer a minha família, especialmente ao meu marido Hélio por todo o suporte emocional durante os momentos mais difíceis da minha vida, e por não ter me deixado desistir, apesar de tudo que passamos.

Agradeço ao amor da minha vida, minha filha Sofia. Agradeço a Deus pela oportunidade de ser mãe e gerar uma vida durante o doutorado e em um momento muito difícil com grandes perdas pessoais. Esta tese foi feita em grande parte nas madrugadas enquanto a minha bebê dormia com muito choro e cansaço.

Também agradeço ao Programa de Pós-Graduação em Geociências Aplicadas do Instituto de Geociências da UnB e ao meu orientador, Prof. Dr. Edson Sano, por todo o suporte e condução durante a minha pesquisa e por sempre estar à disposição e me incentivando durante essa caminhada.

Agradeço ao Censipam pela oportunidade da bolsa DTI-B e pela infraestrutura para a minha pesquisa. Aos amigos que eu fiz: Cláudia, Vitor, Cinthya, Tahisa, Dani, Edileuza, Miguel, Cristina.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001 e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

RESUMO

Contextualização: A Amazônia Legal ocupa uma área equivalente a 60% do território brasileiro, reunindo regiões com características paisagísticas similares com o intuito de melhor planejar o desenvolvimento local. Atualmente, essa área tem sofrido significativamente com o desmatamento e degradação de seus recursos naturais. No entanto, as áreas desmatadas por meio de práticas agrícolas, como corte e queima, mudança de cultivo e criação de pastagens, podem ser eventualmente abandonadas e cederem lugar à regeneração natural da floresta. De acordo com os dados levantados pelo TerraClass Amazônia 2014 do Instituto Nacional de Pesquisas Espaciais (INPE) e da Empresa Brasileira de Pesquisa Agropecuária (Embrapa), houve um aumento de 7.200 ha de vegetação em regeneração na região da Amazônia entre os anos de 2004 e 2014. As florestas tropicais em regeneração são um importante sumidouro terrestre de carbono atmosférico, que deve ser considerado nos estudos de mudanças e ciclagem global de nutrientes. Nesse contexto, é importante realizar o diagnóstico da floresta após o desmatamento para a avaliação dos respectivos impactos na diversidade de espécies, hidrologia local e taxa de acumulação de biomassa, dentre outros. Os sensores remotos ópticos são comumente utilizados no mapeamento e monitoramento das florestas, no entanto, a cobertura frequente de nuvens na região amazônica dificulta a obtenção de informações com base nesses sensores. Uma alternativa a essa limitação tem sido o uso de sensores de radar de abertura sintética (SAR).

Objetivo: Discriminar áreas de vegetação secundária, baseando-se em dados SAR, do município de Colniza, Mato Grosso, considerada uma área de *hotspot* de desmatamento na Amazônia Legal Brasileira.

Métodos: Esta pesquisa apresenta uma abordagem de classificação baseada nos algoritmos de aprendizagem de máquina de Floresta Aleatória (*Random Forest* - RF) e Máquina de Vetores de Suporte (*Support Vector Machine* - SVM) aplicados a imagens SAR dos satélites COSMO-SkyMed (banda X), Sentinel-1 (banda C) e ALOS-2/PALSAR-2 (banda L). Foi dada ênfase às técnicas de SAR polarimétrico (PolSAR), SAR interferométrico (InSAR) e geração de atributos de textura baseados na matriz de coocorrência de níveis de cinza (*gray-level co-occurrence matrix* - GLCM).

Resultados: Os melhores resultados foram obtidos pelo algoritmo RF, tendo como parâmetros de entrada a combinação da coerência interferométrica do COSMO-SkyMed com a decomposição polarimétrica de Yamaguchi dos dados polarimétricos ALOS-2/PALSAR-2, apresentando índice Kappa de 0,81 e acurácia global de 87,81%. A integração da coerência interferométrica da banda X com os atributos polarimétricos da banda L teve impacto positivo principalmente na discriminação das classes referentes à floresta primária, vegetação secundária e degradação.

Conclusão: Os resultados demonstraram a viabilidade do uso do método de classificação baseado em algoritmos de aprendizagem de máquina aplicados a dados SAR, reforçando a habilidade desses sensores no monitoramento florestal em épocas de cobertura de nuvens.

Palavras-chave: Vegetação secundária. SAR. Amazônia. *Random Forest*. *Support Vector Machine*.

ABSTRACT

Contextualization: The Legal Amazon occupies an area equivalent to 60% of the Brazilian territory with similar characteristics in its landscape with the aim to facilitate local development planning. Currently, this area has significantly suffered from deforestation and degradation of its natural resources. However, deforested areas through agricultural practices involving slash and burn, burning, and implementation of pastures may eventually be abandoned and followed by natural forest regeneration. According to data produced by the TerraClass Amazon Project of 2014, coordinated by the National Institute for Space Research (INPE) and Brazilian Agricultural Research Corporation (Embrapa), there was an increase of 7.200 hectares of regenerating vegetation in the Amazon region between 2004 and 2014. Regenerating tropical forests are an important sink of atmospheric carbon, which should be considered in studies of global nutrient change and cycling. In this context, it is important to carry out a monitoring of the forest after deforestation in order to assess the respective impacts on the species diversity, local hydrology, and the rate of biomass accumulation, among others. Optical remote sensing data are commonly used in forest mapping and monitoring, however, the frequent cloud cover in the Amazon region makes it difficult to obtain information based on these sensors. An alternative to this limitation has been the use of synthetic aperture radar (SAR) data. The applications of SAR data in tropical forests are diverse and exploit different sensors and processing techniques. It is important to develop methodologies that can explore the potential of different SAR techniques to contribute to forest monitoring systems.

Objective: This work aims to discriminate areas of secondary vegetation based on SAR data in the municipality of Colniza, Mato Grosso, considered an area of hotspot of deforestation in the Brazilian Legal Amazon.

Methods: This research presents a classification approach based on the Random Forest and Support Vector Machine algorithms in SAR images acquired by the COSMO-SkyMed (X-band), Sentinel-1 (C-band), and ALOS-2/PALSAR-2 (L-band). We emphasized the polarimetric (PolSAR) and interferometric (InSAR) techniques and the generation of textural features based on the gray-level co-occurrence matrix (GLCM).

Results: The best results were obtained from the RF classification by combining COSMO-SkyMed interferometric coherence with Yamaguchi polarimetric decomposition of ALOS-2/PALSAR-2 polarimetric data, presenting a Kappa index of 0.81 and an overall accuracy of 87.81%. The integration of the X-band interferometric coherence with the L-band polarimetric attributes had a positive impact mainly on the discrimination of the classes referring to primary forest, secondary vegetation, and degradation.

Conclusion: The results demonstrated the feasibility of the classification method based on machine algorithms applied to SAR data, reinforcing the ability of these sensors to monitor forests under cloud cover.

Keywords: Secondary vegetation. SAR. Amazon. Random Forest. Support Vector Machine.

LISTA DE FIGURAS

Figura 2.1. Espectro eletromagnético. Fonte: Adaptada de Richards (2009).....	21
Figura 2.2 Geometria de imageamento de um sistema SAR. Fonte: Adaptada de Kuplich (2020).....	23
Figura 2.3. a) Atributos da onda: comprimento (λ), amplitude (a), fase (ϕ) e campo elétrico vertical (E_v); (b) Polarização da onda: para uma diferença de fase dos dois componentes polarizados ($\Delta\phi$) de $1/4\pi$ resulta em uma onda com uma polarização elíptica e campo elétrico horizontal (E_h). Fonte: Adaptada de Woodhouse (2006).....	26
Figura 2.4. Tipos de espalhamento da energia transmitida em micro-ondas em um dossel em função do comprimento de onda. Fonte: Adaptada de Omar et al. (2017).....	27
Figura 2.5. Interação dos mecanismos de espalhamento em um dossel florestal. Fonte: Adaptada de Flores-Anderson et al. (2019).....	28
Figura 2.6. Esquematização da técnica InSAR. Fonte: MundoGEO (2022).....	33
Figura 2.7. Ilustração do satélite ALOS-2/PALSAR-2. Fonte: JAXA (2020).....	34
Figura 2.8. Ilustração do satélite europeu Sentinel-1. Fonte: ESA (2020).....	35
Figura 2.9. Ilustração do satélite COSMO-SkyMed. Fonte: Telespazio (2020).	35
Figura 2.10. Orientações referentes aos ângulos para a geração da matriz de coocorrência. Fonte: Duarte (2017).....	36
Figure 3.1. Localization of the study area. The color composite (July 12, 2017) includes the Sentinel 2 bands 11, 8 and 4 in red, green and blue, respectively.....	45
Figure 3.2. Flow diagram of SAR images processing and classification procedures.....	46
Figure 3.3. Samples set of study area. The color composite (July 12, 2017) includes the Sentinel 2 bands 4, 3 and 2 in red, green and blue, respectively.	48
Figure 3.4. Boxplots representing the thematic classes distribution over the attributes derived from the H-alpha decomposition: entropy H (a) and alpha angle α (b). Attributes representing the thematic classes distribution over VV polarization (σ_{VV}) (c), VH polarization (σ_{VH}) (d) and the cross-polarization ratio (CPRA) (e) attributes derived from backscatter.	50
Figure 3.5. Boxplot representing the thematic classes distribution over HH polarization (σ_{HH}) (a) and the GLCM texture metrics: Dissimilarity (b), Second moment (c), Homogeneity (d), and Contrast (e).....	52

Figure 3.6. Contribution of each attribute extracted from Sentinel1 and CSM in PC1-2 to SF1 (a), SF2 (b), and SF3 (c) classes. Homo: Homogeneity GLCM; Dissi: Dissimilarity GLCM; Contr: Contrast GLCM; SM: Second moment GLCM.....	54
Figure 3.7. SVM classification results.	56
Figure 5.1. Location of the study area in the Brazilian Legal Amazon (A) and in the municipality of Colniza, Mato Grosso State (B). The RGB color composite (C) corresponds to the ALOS/PALSAR-2 data (R: HH/HV; G: HH/VV; and B: VV/VH).	86
Figure 5.2. Flowchart showing the main steps of the methodological approach considered in this study.	88
Figure 5.3. Set of samples based LULC classes. The RGB color composite corresponds to the Sentinel-2 MSI data (R: band 4; G: band 3; B: band 2) acquired on 27 July 2016.....	92
Figure 5.4. Backscattering coefficients of clean pasture (CPA), degradation forest (DEG), primary forest (PFO), shrubby pasture (SPA), initial secondary vegetation (SV1), intermediate secondary vegetation (SV2), advanced secondary vegetation (SV3) and water bodies (WAT), derived from L-HH (a), L-HV (b), L-VV (c), and L-VH (d) polarizations. ...	94
Figure 5.5. Interferometric coherence distribution from CSK data of LULC classes.	95
Figure 5.6. User's and producer's accuracy based on Random Forest algorithm.....	97
Figure 5.7. User's and producer's accuracy based on the Support Vector Machine algorithm.....	98
Figure 5.8. Best classification results obtained by the Random Forest algorithm, considering the Yamaguchi technique from full-polarimetric ALOS-2 data with COSMO-SkyMed coherence interferometric addition.	99
Figure 5.9. Area (%) occupied by each land use and land cover class considered in this study, estimated by the Random Forest algorithm based on the Yamaguchi technique with COSMO-SkyMed interferometry coherence.....	100
Figure 5.10. Comparison of two fragments of classifications corresponding to the Yamaguchi technique using the Random Forest classifier, with and without coherence integration.....	101
Figure 5.11. Random Forest's predictor variables importance.	102

LISTA DE TABELAS

Tabela 2.1. Faixas de comprimento de ondas em que operam os sistemas SAR. Fonte: Jensen (2014).	22
Tabela 2.2. Principais medidas de textura propostas por Haralick et al. (1973). Fontes: Adaptadas de Zakeri et al. (2017) e Azevedo et al. (2014).	38
Table 3.1. Number of pixel for each class.....	48
Table 3.2. Percentage of variance explained on each PC [%].....	53
Table 3.3. Confusion matrix of the image classification derived from Sentinel.....	55
Table 3.4. Confusion matrix of the image classification derived from CSM.	56
Table 3.5. LULC areas derived from SVM classification results (km ²).	57
Table 5.1. Characteristics of the ALOS-2/PALSAR-2 images selected for this study.	86
Table 5.2. Characteristics of the COSMO-SkyMed images selected for this study. .	87
Table 5.3. Characteristics of the attributes extracted from the ALOS/PALSAR-2 full-polarimetric data.	89
Table 5.4. Characteristics of the indices extracted from the ALOS/PALSAR-2 full-polarimetric data.	90
Table 5.5. Distribution of training and validation samples for each LULC class.....	92
Table 5.6. Performance of the RF and SVM classifiers.	95

LISTA DE ABREVIATURAS

APC	Análise de Componentes Principais
ASI	L1Agenzia Spaziale Italiana (Agência Espacial Italiana)
BMI	Biomass Index (Índice de Biomassa)
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CBERS	<i>China-Brazil Earth Resources Satellite</i> (Satélite Sino-Brasileiro de Recursos Terrestres)
Censipam	Centro Gestor e Operacional do Sistema de Proteção da Amazônia
CNN	<i>Convolution Neural Network</i> (Rede Neural Convolucional)
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
COSMO-SkyMed	<i>Constellation of Small Satellites for the Mediterranean basin Observation</i> (Constelação de Pequenos Satélites para a Observação da Bacia do Mediterrâneo)
CSI	Canopy Structure Index (Índice de Estrutura do Dossel)
DETER	Sistema de Detecção do Desmatamento em Tempo Real
dB	Decibéis
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ESA	<i>European Space Agency</i> (Agência Espacial Europeia)
EVI	<i>Enhanced Vegetation Index</i> (Índice de Vegetação Realçado)
EW	Extra-Wide (Extra Largo)
GLCM	<i>Gray Level Co-occurrence Matrix</i> (Matriz de Coocorrência de Níveis de Cinza)
H	<i>Horizontal Polarization</i> (Polarização Horizontal)
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
InSAR	<i>Interferometric SAR</i> (SAR Interferométrico)
IW	<i>Interferometric Wide</i> (Largura Interferométrica)
JAXA	<i>Japan Aerospace Exploration Agency</i> (Agência de Exploração Aeroespacial do Japão)
KMO	Kaiser-Meyer-Olkin
LULC	<i>Land Use and Land Cover</i> (Uso e Cobertura da Terra)

ML	<i>Machine Learning</i> (Aprendizagem de Máquina)
NDVI	<i>Normalized Difference Vegetation Index</i> (Índice de Vegetação por Diferença Normalizada)
NIR	<i>Near infrared</i> (Infravermelho Próximo)
PolSAR	<i>Polarimetric SAR</i> (SAR Polarimétrico)
PRODES	Programa de Monitoramento do Desflorestamento na Amazônia Legal
RF	<i>Random Forest</i> (Floresta Aleatória)
RVI	<i>Radar Vegetation Index</i> (Índice de Vegetação por Radar)
SAR	<i>Synthetic Aperture Radar</i> (Radar de Abertura Sintética)
SNAP	<i>Sentinel Application Platform</i> (Plataforma de Aplicação do Sentinel)
SRTM	<i>Shuttle Radar Topography Mission</i> (Missão Topográfica de Radar Embarcado)
SM	<i>Stripmap</i> (Faixas de Imageamento)
SLC	<i>Single Look Complex</i> (Imagem Complexa de Visada Única)
SVM	<i>Support Vector Machine</i> (Máquina de Vetores de Suporte)
TOPSAR	<i>Terrain Observation with Progressive Scans</i> (Observação de Terreno com Varreduras Progressivas)
V	<i>Vertical Polarization</i> (Polarização Vertical)
VSI	<i>Volume Scattering Index</i> (Índice de Volume de Espalhamento)
WV	<i>Wave</i> (Onda)

LISTA DE SÍMBOLOS

R_r	Resolução de alcance
R_{az}	Resolução de azimuth
τ	Tempo de duração do pulso
L	Comprimento da antena
P_r	Potência recebida
P_t	Potência transmitida
σ^0	Coefficiente de retroespalhamento
λ	Comprimento de onda
R	Distância entre o radar e o alvo na direção de alcance
G	Ganho da antena
p_{ij}	Valor de entrada na matriz de coocorrência de níveis de cinza normalizada
N_g	Níveis de cinza da imagem
r_{ij}	Coefficiente de correlação entre as variáveis
a_{ij}	Coefficiente de correlação parcial
H	Entropia
α	Ângulo alfa
A	Anisotropia
$C_{2,3}$	Matriz de covariância 2x2, 3x3
T_3	Matriz de coerência 3x3
λ_i	Autovalor
e_1	Autovetor
P	Potência
f	Contribuição de cada componente de espalhamento
S_{hh}	Elemento complexo de espalhamento na polarização HH
S_{vv}	Elemento complexo de espalhamento na polarização VV
E	Valor esperado
γ	Coerência interferométrica
u e v	Duas imagens complexas corrigidas
v^*	Complexo conjugado de v

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos.....	17
1.1.1	Objetivo geral	18
1.1.2	Objetivos específicos	18
1.2	Justificativa e importância	18
2	FUNDAMENTAÇÃO TEÓRICA.....	21
2.1	Radar de Abertura Sintética (SAR)	21
2.1.1	Polarização das ondas eletromagnéticas	25
2.1.2	Interação dos mecanismos de espalhamento com a floresta.....	26
2.2	PolSAR	29
2.2.1	Decomposição de alvos	29
2.2.1.1	<i>Cloude-Pottier</i>	29
2.2.1.2	<i>Van Zyl</i>	30
2.2.1.3	<i>Freeman-Durden</i>	31
2.2.1.4	<i>Yamaguchi</i>	32
2.3	InSAR	32
2.4	Missões SAR	34
2.4.1	ALOS-2/PALSAR-2.....	34
2.4.2	Sentinel-1	34
2.4.3	COSMO-SkyMed	35
2.5	Textura GLCM	36
2.5.1	Técnica de Análise de Componentes Principais	39
2.6	Classificadores <i>Random Forest</i> e <i>Support Vector Machine</i>	40
3	ARTIGO 1	42
3.1	Introduction.....	42

3.2	Methodologies	44
3.2.1	Study area	44
3.2.2	Radar image processing.....	45
3.2.3	Attribute selection.....	47
3.3	Results	49
3.3.1	Exploratory analysis of the attributes	49
3.3.2	SVM classification results	54
3.4	Discussion.....	57
3.5	Conclusions	59
3.6	References.....	60
4	ARTIGO 2	64
5	ARTIGO 3.....	83
5.1	Introduction.....	83
5.2	Material and Methods	85
5.2.1	Study area	85
5.2.2	SAR Pre-processing.....	86
5.2.3	Methods	87
5.2.3.1	<i>Pre-processing.....</i>	<i>88</i>
5.2.3.2	<i>Polarimetric decomposition processing</i>	<i>89</i>
5.2.3.3	<i>RF and SVM classifications.....</i>	<i>90</i>
5.2.3.4	<i>Feature and samples selection.....</i>	<i>91</i>
5.2.3.5	<i>Accuracy assessment</i>	<i>93</i>
5.3	Results	93
5.3.1	SAR Data Analysis	93
5.3.2	Classification Results.....	95
5.4	Discussion.....	102
5.5	Conclusions	103

5.6	References.....	104
6	CONSIDERAÇÕES FINAIS.....	112
	REFERÊNCIAS.....	114
	APÊNDICE A	122
	APÊNDICE B.....	124
	APÊNDICE C	141

1 INTRODUÇÃO

A Amazônia Legal é uma área instituída pelo governo federal a partir da Lei nº 1.806, de 6 de janeiro de 1953 ([BRASIL, 1953](#)), que abrange nove estados brasileiros, o que corresponde a aproximadamente 5,2 milhões de km² de extensão (equivalente a 59% do total do território brasileiro), reunindo regiões de idênticas características em termos de paisagem, com o intuito de melhor planejar o desenvolvimento socioeconômico da região ([IBGE, 2022](#)). Essa área contém aproximadamente 20% do bioma Cerrado e abriga todo o bioma Amazônia, o mais extenso dos biomas brasileiros, que corresponde a 1/3 das florestas tropicais úmidas do planeta ([IBGE, 2022](#)). A Amazônia Legal tem sofrido significativamente com o desmatamento e degradação de seus recursos naturais ([FREITAS et al., 2018](#); [GARRET et al., 2021](#)). Nesse contexto, é muito importante realizar o diagnóstico da floresta após o desmatamento para a avaliação dos respectivos impactos na diversidade de espécies, hidrologia local e na taxa de acumulação de biomassa, dentre outros ([KUPLICH, 2006](#); [JAKOVAC et al., 2015](#); [NOBRE et al., 2016](#)).

O desmatamento florestal é resultado de muitos fatores, como a expansão agrícola, extração de madeira, atividades de mineração, entre outras. Sabe-se que as áreas desmatadas por meio de práticas agrícolas, como corte e queima, mudança de cultivo e criação de pastagens, podem ser eventualmente abandonadas e cederem lugar à regeneração natural da floresta ([FEARNSIDE, 2000](#)). Entretanto, em áreas sujeitas à perturbação antrópica, a contribuição relativa dessas diferentes fontes de regeneração frequentemente se altera ([UHL et al., 1988](#)).

De acordo com os dados levantados pelo projeto TerraClass Amazônia 2014 do Instituto Nacional de Pesquisas Espaciais (INPE) e da Empresa Brasileira de Pesquisa Agropecuária (Embrapa) ([INPE, 2022](#)), houve um aumento de 7.200 ha de vegetação em regeneração na região Amazônia entre os anos de 2004 e 2014, sendo um terço desse total derivado de áreas de pastagem. A extensão dessa área é maior do que os estados do Rio de Janeiro, Sergipe e Distrito Federal juntos. Os dados do TerraClass apontam ainda que, da área total desmatada na Amazônia Legal brasileira, 23% está em processo de regeneração.

As florestas tropicais em regeneração são um importante sumidouro terrestre de carbono atmosférico (dióxido de carbono - CO₂), que deve ser considerado nos estudos de mudanças e ciclagem global de nutrientes. Sendo assim, o impacto desses fatores para a biodiversidade, para a hidrologia regional e para o ciclo de carbono faz com que seja necessária

uma avaliação do comportamento e desenvolvimento futuro da regeneração natural da floresta (KUPLICH et al., 2005). Estudos demonstram que a estrutura da floresta, de acordo com o estágio da regeneração florestal, está diretamente relacionada ao fluxo de carbono e aos ciclos de nitrogênio e fósforo da mesma (RÖDIG et al., 2018; HEINRICH et al., 2021).

Com a retirada da cobertura florestal original e com a perda da fertilidade do solo após alguns anos de uso, instala-se um processo de recolonização da área por espécies adaptadas a esta condição, que são substituídas ao longo do tempo num processo conhecido por vegetação ou sucessão secundária (BISPO et al., 2019). Em torno dos primeiros 15 anos de regeneração, a biomassa foliar atinge um valor máximo e depois sofre um leve decréscimo (BROWN; LUGO, 1990; AMARAL et al., 1996).

Dessa forma, os sensores remotos ópticos são comumente utilizados no mapeamento e monitoramento das florestas, no entanto, a cobertura frequente de nuvens na região amazônica dificulta a obtenção de informações com base nesses sensores. Uma alternativa a essa limitação tem sido o uso de sensores de micro-ondas ativos, que incluem o radar de abertura sintética (SAR) (REICHE et al., 2015). As aplicações de dados SAR em florestas tropicais são diversas e exploram diferentes sensores e técnicas de processamento. Sensores que operam em comprimentos de onda mais elevados (bandas L e P) permitem maior penetração do sinal na floresta (FURTADO et al., 2016; PEREIRA et al., 2018), ao passo que os sensores de onda mais curta (bandas X e C), interagem mais superficialmente com a estrutura do dossel (AZEVEDO et al., 2014; ULABY; LONG, 2014; TREUHAFT et al., 2015).

Uma das técnicas utilizadas para monitoramento florestal é o uso de dados polarimétricos SAR (PolSAR) a partir da aplicação de teoremas de decomposição de alvos. Essa técnica permite identificar os tipos de mecanismo de espalhamento que ocorrem durante o processo de interação entre as ondas eletromagnéticas e o alvo, facilitando a discriminação de alvos (PÔSSA et al., 2018; WIEDERKEHR et al., 2020). Uma outra técnica muito utilizada é a interferometria SAR (InSAR), que está baseada na combinação de duas imagens SAR, adquiridas sobre a mesma área, com uma geometria de aquisição ligeiramente diferente uma da outra, para garantir o efeito de interferometria, ou diferença de fase (WEGMÜLLER et al., 2015; MIGUEL; SANO, 2019).

Por outro lado, os atributos extraídos do sinal de retroespalhamento, agregados à métricas de textura da matriz de coocorrência de nível de cinza (GLCM) (HARALICK et al., 1973), também são muito utilizados em dados SAR, pois aumentam a capacidade de discriminar

diferentes alvos, de acordo com a intensidade do sinal retroespalhado em uma dada polarização (KUPLICH et al., 2005; ZAKERI et al., 2017).

As imagens SAR podem ser complementares às imagens derivadas de sensores espectrais, pois apresentam a vantagem de serem independentes da iluminação solar e pouco influenciáveis pela cobertura de nuvens e condições climáticas (CHANG; BAI, 2018; PAVANELLI et al., 2018). Nesse contexto, o uso de dados SAR para o mapeamento do uso e cobertura da terra na Amazônia é uma importante ferramenta para o monitoramento ambiental dessa extensa área.

Assim, a escolha de métodos de classificação adequados é fundamental para o sucesso de produção de mapas de uso e cobertura da terra (LU; WENG, 2007; SOTHE et al., 2017; THAN NOI; KAPPAS, 2017; KIYOHARA; SANO, 2022). Técnicas não paramétricas conhecidas como *Machine Learning* (ML), que incluem os classificadores *Random Forest* (RF) e *Support Vector Machine* (SVM), estão entre os métodos mais utilizados devido à sua excelente operação na classificação de imagens (BREIMAN, 2001). Esses algoritmos apresentam grande capacidade de sintetizar funções de dados, com base em dados discretos ou contínuos (BREIMAN, 2001; SOTHE et al., 2017). Além disso, esses métodos são robustos, podendo utilizar diversas variáveis de entrada, apresentando insensibilidade ao ruído e capacidade de lidar com conjuntos de dados distintos e em equilíbrio (PANEQUE-GALVEZ et al., 2013; FURTADO et al., 2016; YU et al., 2017).

Nesse contexto, é importante desenvolver metodologias que possam explorar o potencial de diferentes técnicas SAR para contribuir com os sistemas de monitoramento florestal. Dessa forma, esta pesquisa apresenta uma abordagem de classificação a partir dos algoritmos de aprendizado de máquina RF e SVM em imagens COSMO-SkyMed (banda X), Sentinel-1 (banda C) e ALOS-2/PALSAR-2 (banda L), utilizando técnicas PolSAR, InSAR e atributos de textura GLCM, visando contribuir na discriminação da vegetação secundária no município de Colniza, Mato Grosso, considerada uma área de *hotspot* de desmatamento na Amazônia Legal Brasileira.

1.1 OBJETIVOS

1.1.1 Objetivo geral

O objetivo geral do presente trabalho é explorar a capacidade dos atributos advindos de sensores de diferentes bandas SAR: COSMO SkyMed (banda X), Sentinel-1 (banda C) e ALOS-2/PALSAR-2 (banda L), a partir da extração de textura GLCM, decomposições de alvos, índices polarimétricos e interferometria, em discriminar áreas de vegetação secundária a partir dos algoritmos de aprendizagem de máquina RF e SVM em uma área de *hotspot* de desmatamento na Amazônia Legal Brasileira, localizada no município de Colniza, estado do Mato Grosso.

1.1.2 Objetivos específicos

Os objetivos específicos do presente trabalho são:

Artigo 1: Avaliar o potencial de atributos derivados da decomposição polarimétrica e coeficientes de retroespalhamento de dados SAR de dupla polarização (VV e VH) do Sentinel-1 em relação aos atributos de textura GLCM e coeficiente de retroespalhamento de dados do sensor COSMO-SkyMed (HH), para discriminar áreas de vegetação secundária a partir do algoritmo SVM.

Artigo 2: Avaliar o potencial dos dados SAR de dupla polarização do Sentinel-1 (banda C) e do ALOS-2/PALSAR-2 (banda L) adquiridos na estação chuvosa para discriminar áreas de vegetação secundária. Os dados foram processados para obter coeficientes de retroespalhamento e nove atributos texturais derivados da matriz GLCM. Em seguida, foram classificados a partir dos algoritmos RF e SVM.

Artigo 3: Discriminar diferentes estágios de vegetação secundária e classes de uso da terra a partir da combinação de dados polarimétricos na banda L do ALOS-2/PALSAR-2 e dados de coerência interferométrica adquiridos pelo satélite COSMO-SkyMed na banda X. Os algoritmos RF e SVM também foram aplicados a esses dados.

1.2 JUSTIFICATIVA E IMPORTÂNCIA

Além do exposto na Seção 1 do presente trabalho, o diagnóstico da vegetação secundária é muito importante para a avaliação dos respectivos impactos no ecossistema. As florestas em regeneração acumulam rapidamente carbono na biomassa acima do solo, com taxas de sequestro líquido de carbono do CO₂ atmosférico. A dinâmica e a demografia das áreas de

vegetação secundária influenciam diretamente a fertilidade do solo e a biodiversidade da paisagem, reduzindo o escoamento superficial e o impacto da fragmentação florestal no habitat natural.

Esse estudo nasceu de uma bolsa de Desenvolvimento Técnico Industrial (DTI) da autora no Centro Gestor e Operacional do Sistema de Proteção da Amazônia (Censipam) junto ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pois havia a necessidade de se desenvolver metodologias aplicadas a dados SAR para o monitoramento florestal e diagnósticos de áreas de regeneração no município de Colniza, Mato Grosso. Essa área é de extrema importância, pois ela é considerada um *hotspot* de desmatamento da Amazônia Legal Brasileira e especulação do agronegócio.

A área de estudo não apresenta um inventário florestal, assim como grande parte da Amazônia Legal Brasileira, por isso houve a necessidade de se fazer um levantamento das áreas de vegetação secundária a partir de dados já catalogados produzidos pelos projetos TerraClass, PRODES e MapBiomas. Nesse contexto, este trabalho procurou explorar diferentes técnicas relacionadas ao uso de dados SAR multi-bandas e mapeamento temático a partir de algoritmos de aprendizagem de máquina (*machine learning*).

A tese está dividida em três artigos, com mais um artigo suplementar em apêndice. O primeiro artigo, descrito na Seção 3, apresenta os resultados de testes executados durante o período da bolsa no Censipam. Nele, foram utilizados dados SAR na banda C (satélite Sentinel-1) e na banda X (satélite COSMO-SkyMed) para a classificação de áreas de vegetação secundária no município de Colniza. As áreas de vegetação secundária utilizadas nesse estudo foram extraídas a partir da elaboração de um código de extração de índice de vegetação por diferença normalizada (NDVI) e índice de vegetação realçado (EVI), extraídos a partir de imagens do satélite Landsat na plataforma Google Earth Engine. Esse código encontra-se descrito no **Apêndice C**. O artigo foi aceito para publicação na Revista Ciência Florestal e encontra-se em processo de edição de texto (**Apêndice A**).

O segundo artigo descrito na Seção 4 apresenta uma metodologia de classificação de áreas de vegetação secundária extraídas de dados dos projetos TerraClass Amazônia 2014 e PRODES no período chuvoso na Amazônia, a partir dos dados do Sentinel-1 e ALOS-2/PALSAR-2, aplicado a técnicas de extração de textura GLCM e análise de componentes principais. O artigo foi publicado na Revista *Forests*.

O terceiro artigo, descrito na Seção 5, foi submetido à revista *International Journal of Remote Sensing* (**Apêndice A**) e encontra-se em revisão. Nesse artigo, usaram-se dados polarimétricos do satélite ALOS-2/PALSAR-2 e coerência interferométrica do satélite COSMO-SkyMed para a discriminação de diferentes estágios de vegetação secundária, extraídas a partir de dados do projeto MapBiomas.

O artigo suplementar foi publicado na Revista Brasileira de Geografia Física e encontra-se no **Apêndice B**. Esse artigo abordou o uso de interferometria em uma área de estudo de Cerrado, servindo como treinamento da autora em relação ao processamento de dados SAR interferométricos do Sentinel-1 e classificação do uso e cobertura da terra.

Os artigos que compõem a presente tese estão no idioma e formatação da respectiva revista para as quais foram submetidos.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 RADAR DE ABERTURA SINTÉTICA (SAR)

Os radares de abertura sintética (*synthetic aperture radar* - SAR) são sensores ativos que operam na faixa espectral do micro-ondas. Esses sensores utilizam antenas que emitem a própria radiação eletromagnética a partir de uma série de pulsos de energia que são propagados em direção ao alvo (superfície terrestre) pela antena. Quando o pulso de energia transmitido atinge o alvo, parte dessa energia é retroespalhada de volta à antena. A intensidade dessa energia retroespalhada depende tanto das características de imageamento do sensor, em termos de comprimento de onda, polarização e ângulo de incidência como das características geométricas e dielétricas do alvo (rugosidade, conteúdo de água no solo e na vegetação e estrutura da vegetação) (JENSEN, 2014). A presença e distribuição de dispersores da radiação transmitida (e.g., edifícios, árvores e arbustos e casas) no campo de visada do sensor determina o tempo de retorno da radiação retroespalhada à antena para cada dispersor, constituindo-se em informações de fase, presentes em dados disponibilizados na forma complexa (*single look complex*, SLC) (CHANG; BAI, 2018).

Os pulsos de radiação eletromagnética enviados pela antena possuem um comprimento de onda específico. Os comprimentos de onda utilizados pelos radares são muito mais longos que os comprimentos de onda nos espectros visível e infravermelho de ondas curtas (Figura 2.1), comumente utilizados em sensores passivos (JENSEN, 2014) (Tabela 2.1).




Figura 2.1. Espectro eletromagnético. Fonte: Adaptada de Richards (2009).

Tabela 2.1. Faixas de comprimento de ondas em que operam os sistemas SAR. Fonte: [Jensen \(2014\)](#).

Bandas	Comprimento de onda (cm)	Frequência (GHz)
X	2,4 – 3,8	12,5 – 8,0
C	3,9 – 7,5	8,0 – 4,0
S	7,5 – 15,0	4,0 – 2,0
L	15,0 – 30,0	2,0 – 1,0
P	30,0 – 100,0	1,0 - 0,3

A banda X é a menor faixa de comprimento de onda utilizada para radares orbitais, interagindo mais superficialmente com os alvos. Já os sensores que operam em comprimentos de onda mais elevados (bandas L e P) conseguem maior penetração dos sinais transmitidos pela antena nos alvos, pois a capacidade de penetração da onda nos alvos é diretamente proporcional ao comprimento de onda ([JENSEN, 2014](#)).

Uma imagem SAR possui uma resolução em alcance (R_r), isto é, ao longo da direção de iluminação do pulso de onda e outra em azimuth (R_{az}), que é medida paralelamente à linha de voo do radar e que é determinada pela largura angular do feixe e pela faixa do terreno que é iluminada pelo feixe de radar. A região imageada e localizada próxima ao nadir é denominada de alcance próximo, enquanto a região mais afastada ao nadir é conhecida como alcance distante.

A resolução em alcance de uma imagem de radar depende do cosseno do ângulo de depressão (β), que é complementar ao ângulo de incidência, formado entre o pulso de radar e a vertical ao plano da superfície onde o pulso toca o alvo e do tempo de duração do pulso (τ) ([RICHARDS, 2009](#)) (Eq. 2.1).

$$R_r = \frac{\tau \cdot c}{2 \cdot \cos \beta} \quad (2.1)$$

em que:

c = velocidade da luz ($3 \times 10^8 \text{ m s}^{-1}$).

A largura angular do feixe é inversamente proporcional ao comprimento da antena sintética (L). Isso significa que quanto maior o tamanho da antena do radar, menor será a largura do feixe e maior a resolução em azimuth. Dessa forma, a resolução em azimuth é definida de acordo com a Eq. 2.2:

$$R_{az} = \frac{S \times \lambda}{L} \quad (2.2)$$

em que:

S = distância da antena ao ponto no alcance inclinado do terreno; e

λ = comprimento de onda do sistema SAR.

Portanto, os parâmetros relacionados com a geometria de imageamento que devem ser conhecidos são a direção de azimuth, direção de visada, ângulo de depressão ou o seu ângulo complementar que é o ângulo de incidência e o ângulo azimuthal. A direção de azimuth refere-se à direção de voo da plataforma. Já a direção de visada, também conhecida como direção de alcance, é a direção de iluminação ao longo da propagação do pulso. O ângulo de depressão é formado entre a linha do azimuth e a linha que define a direção de visada, sendo o seu complemento o ângulo de visada. O ângulo de incidência local depende da declividade do terreno, pois é formado pelo pulso de radar que toca o alvo no terreno e a vertical do plano da superfície. Quanto maior for este ângulo, maior será o sombreamento na imagem (RICHARDS, 2009; JENSEN, 2014).

Os sistemas SAR podem operar em plataformas aéreas ou orbitais, sempre com uma visada lateral (alcance inclinado). Consequentemente, há a necessidade de conversão dessas imagens para um plano horizontal (alcance no terreno) (Figura 2.2).




Figura 2.2 Geometria de imageamento de um sistema SAR. Fonte: Adaptada de Kuplich (2020).

A quantidade de energia retroespalhada pelo radar depende da rugosidade da superfície

e da propriedade dielétrica do material. Quanto maior a constante dielétrica de um alvo, maior a sua capacidade de reflexão dos pulsos de energia transmitidos na faixa de micro-ondas. A constante dielétrica possui relação direta com o teor de umidade dos alvos. O aumento do teor de umidade provoca um aumento na constante dielétrica, conseqüentemente, há um aumento na intensidade de retroespalhamento da energia transmitida pela antena. Por isso, as imagens SAR, obtidas em condições de solo úmido, apresentam tonalidade de cinza mais clara em relação às obtidas sob condições de solo seco. A compreensão de como a energia interage com as diferentes condições da superfície terrestre fornece importantes subsídios para a correta interpretação de imagens SAR ([RICHARDS, 2009](#)).

Os alvos terrestres apresentam diferentes características de retroespalhamento da energia transmitida. Alvos com superfície plana e lisa refletem especularmente quase toda a energia emitida pelo radar, isto é, em um ângulo diametralmente oposto ao ângulo de incidência, atuando como refletores especulares. Já os alvos que apresentam superfície rugosa e irregular refletem a energia em diferentes direções e são denominados de refletores difusos. Em regiões onde o terreno é bastante irregular, por exemplo, em regiões de serras e montanhas, pode haver ocorrência de distorções geométricas conhecidas como inversão do terreno (*layover*) e encurtamento de rampa (*foreshortening*) ([WOODHOUSE, 2006](#)).

As imagens de radar apresentam um tipo de ruído conhecido como *speckle* e que é inerente ao próprio processo de formação de uma imagem SAR. Esse ruído apresenta um aspecto granulado, que degrada a qualidade radiométrica da imagem. Ele é encontrado em todos os sistemas SAR, sendo resultado de interferências entre os ecos coerentes dos dispersores individuais dentro de uma célula. Os dispersores presentes dentro de cada unidade de resolução (pixel) de uma imagem SAR causam interferências construtivas ou destrutivas, produzindo pixels com tonalidades de cinza claras ou escuras, respectivamente. O ruído *speckle* pode ser atenuado a partir de um processamento de múltiplas visadas. Entretanto, quanto maior o número de visadas, maior será a degradação da resolução espacial da imagem ([WOODHOUSE, 2006](#); [RICHARDS, 2009](#)).

A equação do radar (Eq. 2.3) mostra a relação entre a potência da energia transmitida (P_t ; unidade em Watts) por uma antena e a potência da energia recebida (P_r) pela mesma antena e é função dos parâmetros do sistema de imageamento e das características biofísicas do alvo. Como os parâmetros do sistema são bem conhecidos, os seus efeitos são normalmente removidos das imagens de radar ([JENSEN, 2014](#); [ULABY](#); [LONG, 2014](#)).

$$P_r = P_t(\sigma^0 \times A) \frac{G^2 \times \lambda^2}{(4\pi)^3 \times R^4} \quad (2.3)$$

em que:

σ^0 = coeficiente de retroespalhamento;

A = área efetiva da antena receptora do radar;

λ = comprimento de onda do SAR;

R = distância entre o radar e o alvo na direção de alcance; e

G = ganho da antena (razão entre a potência por unidade de área ao longo do eixo do feixe de radar pela potência irradiada isotropicamente – valores típicos variam entre 20 a 45 dB).

O σ^0 é definido como a medida quantitativa da intensidade de energia retornada à antena do radar, a partir de uma área unitária no terreno. Os valores de σ^0 são expressos em decibéis (dB), estando diretamente relacionados com as características geométricas e dielétricas do alvo (WOODHOUSE, 2006; JENSEN, 2014; ULABY; LONG, 2014). Os dados de amplitude nos dados SAR estão relacionados com o coeficiente de retroespalhamento (σ^0). O sinal que chega ao radar pode ser expresso por um número complexo, cuja parte real é a amplitude e a parte imaginária correspondente à fase do sinal recebido que também é registrada (WOODHOUSE, 2006; RICHARDS, 2009).

2.1.1 Polarização das ondas eletromagnéticas

Uma das principais características dos sistemas SAR é o uso da energia polarizada. A antena do radar envia e recebe energia polarizada no plano horizontal (H) ou vertical (V) em relação à direção de propagação da onda transmitida (JENSEN, 2014). Assim sendo, uma imagem SAR pode ser obtida com quatro opções de polarização:

- VV: energia transmitida e recebida na polarização vertical;
- HH: energia transmitida e recebida na polarização horizontal;
- HV: energia transmitida na polarização horizontal e recebida na polarização vertical;
- VH: energia transmitida na polarização vertical e recebida na polarização horizontal.

A polarização é um parâmetro particularmente importante do radar, pois as propriedades de dispersão da energia eletromagnética dos alvos da superfície da terra podem ser diferentes de acordo com a polarização incidente. Quando uma energia polarizada atinge o alvo, ela é despolarizada, de modo que a energia retroespalhada pode ser novamente registrada na polarização V ou H (WOODHOUSE, 2006). O tipo de polarização refere-se ao vetor do campo elétrico (Figura 2.3) ao invés do campo magnético, que é considerado invariável para os alvos naturais (RICHARDS, 2009).




Figura 2.3. a) Atributos da onda: comprimento (λ), amplitude (a), fase (ϕ) e campo elétrico vertical (E_v); (b) Polarização da onda: para uma diferença de fase dos dois componentes polarizados ($\Delta\phi$) de $1/4\pi$ resulta em uma onda com uma polarização elíptica e campo elétrico horizontal (E_h). Fonte: Adaptada de Woodhouse (2006).

As polarizações HH e VV geralmente estão mais relacionadas com a rugosidade do terreno (espalhamento superficial), enquanto as polarizações cruzadas HV e VH estão relacionadas com o espalhamento volumétrico dos alvos. A capacidade de registrar diferentes tipos de energia polarizada de um material no terreno resulta em valiosas informações sobre as propriedades e feições dos alvos (JENSEN, 2014).

2.1.2 Interação dos mecanismos de espalhamento com a floresta

A penetração das ondas eletromagnéticas emitidas pelo radar na vegetação depende do teor de umidade e da densidade da cobertura do dossel, bem como do tamanho do comprimento de onda (Figura 2.4). Comprimentos de onda mais longos penetram muito mais na vegetação

do que comprimentos de onda mais curtos. Portanto, os comprimentos de onda curtos produzem informações sobre as camadas superiores da vegetação, enquanto comprimentos de onda mais longos produzem informações sobre as camadas inferiores e do próprio solo, dependendo da densidade de cobertura vegetal (ULABY; LONG, 2014).




Figura 2.4. Tipos de espalhamento da energia transmitida em micro-ondas em um dossel em função do comprimento de onda. Fonte: Adaptada de Omar et al. (2017).

As árvores de um dossel comportam-se como dispersores individuais, no entanto, os seus tamanhos e orientações são caracterizados por distribuições de probabilidade aleatórias. Dessa forma, as polarizações cruzadas HV e VH apresentam melhor contraste com a vegetação devido à orientação aleatória de partes do dossel da vegetação (espalhamento volumétrico) (ULABY; LONG, 2014).

A relação entre biomassa e saturação do sinal varia entre os diferentes tipos e estruturas florestais, por isso é necessário entender as respostas do sinal retroespalhado do SAR (GREEN, 1998). De acordo com Omar et al. (2017), a sensibilidade do sinal retroespalhado depende da estrutura, densidade e elementos da árvore (ou seja, tronco/caule, galhos e folhas) da floresta. Como um dossel florestal é uma estrutura heterogênea, aleatória, e possivelmente anisotrópica, é necessário medir a perda de atenuação do sinal e atraso de fase, para estabelecer os valores médios e as estatísticas associadas a essas características (ULABY; LONG, 2014).

O retroespalhamento de um dossel florestal pode envolver diferentes tipos de mecanismos de espalhamento (Figura 2.5). Segundo Richards (2009), esses mecanismos envolvem desde o retroespalhamento superficial (direto da copa das árvores), o retroespalhamento volumétrico (espalhamento dentro das copas das árvores), o

retroespalhamento direto do tronco e direto do solo, além do retroespalhamento resultante das interações copa-solo e tronco-solo (espalhamento de canto, ou *double bounce*).




Figura 2.5. Interação dos mecanismos de espalhamento em um dossel florestal. Fonte: Adaptada de Flores-Anderson et al. (2019).

Na literatura, é possível encontrar diferentes índices de vegetação derivados dos coeficientes de retroespalhamento nas respectivas polarizações. Kim e Van Zyl (2009) propuseram um índice para separar as superfícies de vegetação das superfícies de solo exposto, conhecido como *Radar Vegetation Index* (RVI), conforme mostra a Eq. 2.4:

$$RVI = \frac{8 \times \sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{VV}^0 + 2 \times \sigma_{HV}^0} \quad (2.4)$$

Pôpe et al. (1994) desenvolveram um índice de espalhamento volumétrico VSI (*Volume Scattering Index*) que pode ser utilizado como um indicador da espessura da copa das árvores de um dossel (Eq. 2.5):

$$VSI = \frac{\sigma_{HV}^0}{\sigma_{HV}^0 + BMI} \quad (2.5)$$

em que:

BMI é o índice de biomassa (*Biomass Index*) que está relacionado à biomassa foliar (Eq. 2.6):

$$BMI = \frac{\sigma_{HH}^0 + \sigma_{VV}^0}{2} \quad (2.6)$$

O índice de estrutura do dossel CSI (*Canopy Structure Index*) é um indicador da importância das estruturas verticais em relação às estruturas horizontais no ambiente florestal imageado (Eq. 2.7):

$$CSI = \frac{\sigma_{VV}^0}{\sigma_{VV}^0 + \sigma_{HH}^0} \quad (2.7)$$

2.2 POLSAR

Grande parte dos alvos na superfície se encontra em ambientes dinâmicos, suscetíveis às variações espacial e temporal (LEE; POTTIER, 2009). Estes alvos são considerados incoerentes, ou seja, são alvos não determinísticos que, ao interagirem com a onda provocam retroespalhamento e polarização (RICHARDS, 2009).

Nesse caso, as matrizes de covariância [C] ou coerência [T] são comumente empregadas, devido à natureza não determinística dos espalhadores (CLOUDE; POTTIER, 1996; LEE; POTTIER, 2009). Essas matrizes viabilizam a análise da relação entre o vetor do campo elétrico emitido e o vetor espalhado, pois ambas apresentam informações sobre amplitude, fase e correlações, com autovalores reais e iguais, mas diferentes autovetores. Essas informações sobre o processo de espalhamento podem ser extraídas a partir de técnicas polarimétricas (PolSAR), como a decomposição de alvos.

2.2.1 Decomposição de alvos

2.2.1.1 Cloude-Pottier

A decomposição Cloude-Pottier (CLOUDE; POTTIER, 1996) é baseada nos parâmetros entropia, ângulo alfa e anisotropia, definida a partir da matriz de coerência [T_3] (Eq. 2.8):

$$[T_3] = \sum_{i=1}^{i=3} T_{3i} = \sum_{i=1}^{i=3} \lambda_i (\vec{e}_i \cdot \vec{e}_i) = \lambda_1 (\vec{e}_1 \cdot \vec{e}_1) + \lambda_2 (\vec{e}_2 \cdot \vec{e}_2) + \lambda_3 (\vec{e}_3 \cdot \vec{e}_3) \quad (2.8)$$

em que:

$[T_3]$ = matriz de coerência 3×3;

λ_i = autovalor; e

e_1 = autovetor.

A entropia (H) é um número real de 0 a 1, que indica o grau de aleatoriedade da distribuição dos mecanismos de espalhamento (Eq. 2.9).

$$H = - \sum_{i=1}^3 P_i \log_3 P_i \quad (2.9)$$

em que: $P_i = \frac{\lambda_i}{\sum_{k=1}^3 \lambda_k}$

A anisotropia (A) é complementar à entropia e é um indicador da importância relativa dos mecanismos de espalhamento secundários, sendo mais representativo quando ocorre média entropia (Eq. 2.10):

$$A = \frac{\lambda_2 - \lambda_3}{\lambda_2 + \lambda_3} \quad (2.10)$$

A partir da matriz de coerência, cada autovetor pode também ser parametrizado em termos de cinco ângulos. Desses ângulos, destaca-se o ângulo alfa (α), que varia de 0° a 90°. Em 0° predomina o espalhamento isotrópico (*odd bounce*), em 45° predomina o espalhamento do tipo dipolo e em 90° há o predomínio de espalhamento do tipo *double bounce* na polarização VV.

2.2.1.2 Van Zyl

A decomposição de van Zyl (VAN ZYL, 1989) apresenta três componentes responsáveis pela descrição dos tipos de espalhamentos, baseados na matriz de covariância $[C_3]$ para terrenos naturais, que apresentam reflexão simétrica e na situação de imageamento monoestático. As componentes de espalhamento descritas pela decomposição de van Zyl são:

i) *even number of reflections* (número inteiro de reflexões divisível por 2);

- ii) *odd number of reflections* (número inteiro de reflexões sem divisão exata por 2); e
- iii) espalhamento difuso (LEE e POTTIER, 2009).

De acordo com o estudo de van Zyl (1989), o espalhamento difuso está mais associado a áreas de vegetação, enquanto a componente *even number of reflections* está mais associada a áreas urbanas. Já a componente *odd number of reflections* é predominante em áreas oceânicas.

2.2.1.3 Freeman-Durden

Freeman e Durden (1998) relataram que uma das principais limitações do teorema de van Zyl é a descrição puramente matemática do espalhamento, sem contar com a descrição do tipo físico de espalhamento predominante. Dessa forma, baseados na decomposição de van Zyl, Freeman e Durden (1998) apresentaram um novo modelo desenvolvido principalmente para a compreensão do retroespalhamento em alvos florestais. Dessa forma, a decomposição de Freeman-Durden é muito útil na discriminação entre áreas florestadas e não florestadas, floresta inundada e não inundada (FREEMAN; DURDEN, 1998; LEE, POTTIER, 2009).

A decomposição Freeman-Durden modela a matriz de covariância $[C_3]$ como sendo a contribuição de três mecanismos de espalhamento (FREEMAN; DURDEN, 1998; LEE, POTTIER, 2009):

- i) espalhamento volumétrico: por exemplo, os dosseis são modelados como um conjunto de espalhadores do tipo dipolo orientados aleatoriamente; a potência que corresponde a esse espalhamento é dada por (Eq. 2.11):

$$P_v = \frac{8}{3} f_v \quad (2.11)$$

- ii) *double bounce*: espalhadores modelados como refletores do tipo diedro; a potência correspondente a esse espalhamento é dada por (Eq. 2.12):

$$P_d = f_d(1 + |S_{hh} + S_{vv}|^2) \quad (2.12)$$

- iii) superficial: espalhadores do tipo *Bragg*, que ocorrem em superfícies ligeiramente rugosas e em superfícies onduladas; a potência correspondente a esse espalhamento é dada por (Eq. 2.13)

$$P_s = f_s(1 + |S_{vv} + S_{hh}|^2) \quad (2.13)$$

em que:

P = potência;

f = contribuição de cada componente de espalhamento;

S_{hh} = elemento complexo de espalhamento na polarização HH; e

S_{vv} = elemento complexo de espalhamento na polarização VV.

2.2.1.4 Yamaguchi

A decomposição de Yamaguchi é baseada em uma modelagem da matriz de covariância $[C_3]$ e é constituída de quatro componentes de espalhamento: *double bounce*, superficial, volumétrico e hélice. Os três primeiros componentes baseiam-se nos seus correspondentes da decomposição de [Freeman e Durden \(1998\)](#).

O que difere desse modelo é a introdução do quarto componente, que modela o espalhamento do tipo hélice. Esse espalhamento refere-se a alvo com forma e/ou estrutura artificial, como um refletor não simétrico capaz de gerar polarizações circulares para a esquerda ou para a direita, sendo mais adequado para descrever alvos não naturais ([YANG et al., 2015](#)). Além dessa modificação, [Yamaguchi et al. \(2005\)](#) realizaram uma modificação na função de densidade de probabilidade referente ao modelo de [Freeman e Durden \(1998\)](#) no espalhamento volumétrico, considerando-se o aspecto da orientação dominante de troncos e ramos de árvores em ambientes florestais.

2.3 INSAR

A técnica de interferometria SAR (InSAR) está baseada na combinação de duas imagens SAR adquiridas sobre a mesma área com uma geometria de aquisição ligeiramente diferente uma da outra (Figura 2.6) para garantir o efeito de interferometria, ou diferença de fase ([TEMPORIM et al., 2017](#)). A comparação entre as diferenças de fase de duas imagens de uma mesma região, obtidas a partir de antenas com ligeira diferença de geometria, torna possível encontrar as localizações dos pixels em três dimensões: latitude, longitude e altitude ([RICHARDS, 2009](#)).




Figura 2.6. Esquematização da técnica InSAR. Fonte: [MundoGEO \(2022\)](#).

A diferença de fase entre pixels de mesma coordenada nas imagens está relacionada à distância entre as duas trajetórias de pulsos de energia eletromagnética durante as aquisições (linha-base) e a altitude correspondente no solo. Por meio destes dados, também se podem-se gerar imagens de coerência interferométrica, muito úteis para fins de classificação ([WEGMÜLLER et al., 2015](#); [OLESK et al., 2016](#); [PÔSSA et al., 2018](#)). A coerência interferométrica (γ) de duas imagens SAR complexas é definida como (Eq. 2.14):

$$\gamma = \frac{E\{uv^*\}}{\sqrt{E\{|u|^2\}E\{|v|^2\}}}$$
 (2.14)

em que:

E = valor esperado;

u e v = duas imagens complexas corregistradas; e

v^* = complexo conjugado de v ([WEGMÜLLER et al., 2015](#)).

Cada pixel de uma imagem de coerência representa a informação do módulo do coeficiente de correlação complexa de um par interferométrico. Este tipo de produto pode contribuir para a estratificação temática da paisagem, considerando que, em regiões florestadas, uma das fontes comuns de descorrelação é o espalhamento volumétrico. Nesse contexto, é esperado o decréscimo da coerência com o aumento da quantidade de vegetação em razão da instabilidade dos componentes florestais. Já outras tipologias de uso e cobertura da terra, como a pastagem, solo exposto e regiões de vegetação esparsa, apresentam maior coerência ([OLESK et al., 2016](#); [PÔSSA et al., 2018](#)).

2.4 MISSÕES SAR

2.4.1 ALOS-2/PALSAR-2

Lançado em 24 de maio de 2014 pela Agência de Exploração Aeroespacial do Japão (JAXA), no centro espacial de Tanegashima, Japão, o satélite ALOS-2 (Figura 2.7) corresponde ao segundo satélite da missão ALOS. O sistema foi desenvolvido com o intuito de fomentar pesquisas científicas e aplicações na área de sensoriamento remoto de radar, fornecendo imagens capazes de apoiar estudos relacionados com desenvolvimento sustentável, monitoramento de desastres naturais, monitoramento ambiental e outras aplicações e pesquisas ([EMBRAPA, 2020](#)).



Figura 2.7. Ilustração do satélite ALOS-2/PALSAR-2. Fonte: [JAXA \(2020\)](#).

O sensor PALSAR-2 a bordo do satélite ALOS-2 é um SAR cuja antena transmite pulsos de radiação eletromagnética na faixa de micro-ondas na banda L, que é menos afetada por nuvens e chuvas por causa do seu comprimento de onda mais longo. Essa capacidade de observação em qualquer clima é adequada para monitorar desastres rapidamente. Além disso, a radiação transmitida na banda L pode atingir os solos sob dosséis vegetais não muito densos ([JAXA, 2020](#)).

2.4.2 Sentinel-1

A missão Sentinel-1 é composta por uma constelação de dois satélites denominados de Sentinel-1A, lançado em 3 de abril de 2014 e Sentinel-1B, lançado em 25 de abril de 2016 (Figura 2.8), pela Agência Espacial Europeia (ESA), obtendo imagens SAR na banda C. Ambos os satélites possuem um tempo de vida útil previsto de sete anos e operam em uma órbita de

693 km de altitude, síncrona com o Sol e quase-polar. Os satélites compartilham a mesma órbita plana com uma diferença de fase de 180° , em um ciclo de 12 dias e 175 órbitas por ciclo (ESA, 2020).

Os dados adquiridos por esta missão são disponibilizados gratuitamente no portal Copernicus Sci-Hub da ESA, de modo a promover o aumento da investigação científica baseada em imagens de radar e o crescimento de ofertas de serviços de observação da Terra. Os satélites possuem uma frequência de repetição (ascendente/descendente) de três dias na linha do equador e menos de um dia no Ártico. O sistema tem a capacidade de operar nos modos de dupla polarização (HH/HV ou VV/VH) e polarização única (HH ou VV), apresentando quatro modos de aquisição distintos: SM (*Stripmap*), IW (*Interferometric Wide*), EW (*Extra-Wide*) e WV (*Wave*) (ESA, 2020).



Figura 2.8. Ilustração do satélite europeu Sentinel-1. Fonte: ESA (2020).

2.4.3 COSMO-SkyMed

A missão COSMO-SkyMed (*Constellation of Small Satellites for the Mediterranean basin Observation*) (Figura 2.9), lançada entre 2007 e 2010, é uma constelação composta por quatro satélites concebida pela Agência Espacial Italiana (ASI) e financiada pelo Ministério de Pesquisa e pelo Ministério da Defesa da Itália (E-GEOS, 2020).



Figura 2.9. Ilustração do satélite COSMO-SkyMed. Fonte: Telespazio (2020).

Cada um dos quatro satélites é equipado com um instrumento SAR que opera na banda X, sendo capaz de adquirir imagens em alta resolução espacial na maioria das condições de visibilidade. O objetivo geral da missão é a observação global da Terra e a exploração de dados relevantes para as necessidades das comunidades militar e civil (TELESPAZIO, 2020). A Telespazio é a principal responsável pelo desenvolvimento do centro de controle da constelação e dos segmentos terrestres, adquirindo, processando e distribuindo os dados coletados pelos satélites para o usuário final (TELESPAZIO, 2020).

2.5 TEXTURA GLCM

A matriz de coocorrência de níveis de cinza (GLCM - *Gray Level Cooccurrence Matrix*) trata de um método estatístico para descrição de texturas que é baseada na ocorrência repetida da configuração dos níveis de cinza e descreve a frequência espacial com que as transições de nível de cinza entre os pares de pixel ocorrem (HARALICK et al., 1973). Os métodos baseados em estatísticas de segunda ordem têm demonstrado um alto índice de capacidade de discriminação em uma grande variedade de imagens, pois permite a identificação de padrões de áreas texturizadas (DUARTE, 2017).

Conforme descrito por Haralick et al. (1973), para a geração da matriz de coocorrência, são necessários um ângulo θ e uma distância d . O ângulo θ representa a direção em que será calculada a matriz, de acordo com a ocorrência das coordenadas de um pixel, podendo ser 0° , 45° , 90° e 135° (Figura 2.10). Já a distância d representa o intervalo entre a ocorrência de um pixel x para um pixel y .




Figura 2.10. Orientações referentes aos ângulos para a geração da matriz de coocorrência. Fonte: Duarte (2017).

Dessa forma, efetuando-se o cálculo da matriz de coocorrência, por meio de alterações na orientação do ângulo θ e da distância d entre os pares de pixels vizinhos, podem ser obtidas 14 medidas estatísticas que são utilizadas para análise da textura ([HARALICK et al., 1973](#)). Na Tabela 2.2, estão listadas algumas das principais medidas estatísticas propostas por [Haralick et al. \(1973\)](#).

A textura de uma imagem é uma propriedade útil e que pode ser utilizada como parâmetro na classificação de imagens de radar, particularmente se o objetivo for discriminar classes que apresentam diferentes tonalidades na imagem ([ULABY; LONG, 2014](#)). Para minimizar o efeito escalar entre os valores dos atributos de textura, a matriz GLCM é comumente padronizada em um intervalo de zero a um ([TSO; MATHER, 2009](#)).

Na literatura, é possível encontrar estudos que utilizaram atributos de textura derivados do método estatístico GLCM para discriminar diferentes classes em áreas florestais. [Kuplich et al. \(2005\)](#) relacionaram medidas de textura GLCM em imagens JERS-1 (banda L) com a biomassa para o diagnóstico de áreas em regeneração em uma área de floresta amazônica. De acordo com os autores, como a estrutura do dossel e a biomassa mudam com o tempo, isso pode influenciar na rugosidade da superfície do dossel e consequentemente na textura de imagem SAR. Uma alta correlação foi encontrada entre a medida de textura contraste e a biomassa, potencializando a precisão com o que os dados SAR do JERS-1 podem ser usados para estimar a biomassa em florestas tropicais.

Tabela 2.2. Principais medidas de textura propostas por [Haralick et al. \(1973\)](#). Fontes: Adaptadas de [Zakeri et al. \(2017\)](#) e [Azevedo et al. \(2014\)](#).

Medidas de Textura	Fórmula	Descrição
Entropia	$-\sum_{i,j} p_{(i,j)} \log\{p_{(i,j)}\}$	Mede a desordem contida na textura
Homogeneidade	$\sum_{i,j} \frac{1}{1 + (i - j)^2} p_{(i,j)}$	Indica a homogeneidade da imagem
Correlação	$\sum_{n=0}^{Ng-1} n^2 \left\{ \sum_i^{Ng} \sum_j^{Ng} p_{(ij)} \right\}_{ i-j =n}$	Mede a dependência linear entre os tons de cinza
Dissimilaridade	$\sum_{i,j} p_{(i,j)} i - j $	Similar ao contraste
Contraste	$\sum_{i,j} p_{(i,j)} (i - j)^2$	Caracteriza-se pela diferença entre os tons de cinza
Média	$\sum_{i,j} i(p_{(i,j)})$	Distribuição textural da imagem
Energia	$\sqrt{\sum_{i,j} \{p_{(i,j)}\}^2}$	Mede a uniformidade textural da imagem a partir de pares de pixels repetidos
Variância	$\sum_{i,j} (i - \mu)^2 p_{(i,j)}$	Variação local de níveis de cinza
Segundo momento angular	$\sum_{i,j} \{p_{(i,j)}\}^2$	Expressa a uniformidade da textura

p_{ij} = valor de entrada na matriz de co-ocorrência de níveis de cinza normalizada; N_g = diferentes níveis de cinza da imagem e μ = média dos níveis de cinza.

2.5.1 Técnica de Análise de Componentes Principais

A Análise de Componentes Principais (APC) é um método estatístico muito utilizado para reduzir a dimensionalidade de um conjunto de dados que se apresenta altamente correlacionado. Esta análise é possível de ser executada, pois alguns dados podem não ser relevantes para o reconhecimento de padrões; assim, pode-se identificar o mínimo de dados ou atributos suficientes para descrever uma região ou discriminar um objeto na imagem (SCHWARTZ, 2005; SILVA et al., 2015).

A APC pode ser entendida como uma transformação linear que usa a distância euclidiana a partir de n características originais como uma medida de dissimilaridade entre p novas características e estas são ordenadas de acordo com a sua relevância. Dessa forma, é calculada a correlação entre os dados de entrada, a partir dos autovalores e autovetores, sendo que os primeiros componentes apresentam a maior variação das variáveis de entrada (MOREIRA, 2007).

Os autovalores são medidos em unidade de variância e caracterizam os comprimentos dos eixos das componentes principais. Para cada componente, existe um vetor unitário chamado autovetor que representa a direção dos eixos das componentes principais (DPI, 2020). Para que a APC possa apresentar algum significado, é necessário que as variáveis sejam correlacionadas. Se as matrizes de covariância e de correlação forem diagonais, a aplicação desta técnica simplesmente vai desenvolver, em alguma ordem, as próprias variáveis originais (SILVA et al., 2015). Nesse contexto, é comum utilizar o teste de esfericidade de Bartlett, que indica a presença ou ausência de correlação entre as variáveis, avaliando a hipótese de que a matriz de correlações pode ser a matriz identidade com determinante igual a 1 (MINGOTI, 2007; MOREIRA, 2007).

Outro teste também utilizado é o Kaiser-Meyer-Olkin (KMO), que é uma estatística da proporção da variância dos dados que pode ser considerada comum a todas as variáveis, ou seja, pode ser atribuída a um fator comum. Quanto mais próximo de 1, melhor será o resultado, ou seja, mais adequada é a APC (MINGOTI, 2007). O teste KMO pode ser descrito de acordo com a Eq. 2.8:

$$KMO = \frac{\sum_{i \neq j} \sum r_{ij}^2}{\sum_{i \neq j} \sum r_{ij}^2 + \sum_{i \neq j} \sum a_{ij}^2} \quad (2.8)$$

em que:

r_{ij} = coeficiente de correlação entre as variáveis; e

a_{ij} = coeficiente de correlação parcial.

2.6 CLASSIFICADORES *RANDOM FOREST* E *SUPPORT VECTOR MACHINE*

O aprendizado de máquinas é um método de análise de dados que automatiza o processo de tomada de decisões por meio de aprendizagem de padrões a partir da inserção de dados em modelos analíticos. Dois algoritmos de aprendizagem de máquinas são muito utilizados para a classificação supervisionada em imagens: o *Random Forest* (RF) e o *Support Vector Machine* (SVM).

O RF é um algoritmo de aprendizagem supervisionado que melhora a precisão das árvores de classificação e regressão por meio da combinação de um grande número de subconjuntos aleatórios de árvores. Cada árvore contribui com apenas um voto, e a classificação final é determinada pela maioria dos votos, levando em consideração todas as árvores de decisão (SOTHE et al., 2017). O RF também é conhecido como um algoritmo *ensemble* (de conjunto) e *bagging* (ensacamento). *Ensemble* porque reúne e emprega um conjunto de classificadores do tipo árvores de regressão. *Bagging* porque as árvores de decisão são criadas a partir de subconjuntos do mesmo conjunto amostral, com reposição (BREIMAN, 2001; BELGIU; DRĂGUȚ, 2016). A ideia principal do método de *bagging* é que a combinação dos modelos de aprendizado aumenta a acurácia do resultado final da classificação.

O algoritmo de RF usa árvores de decisão para aumentar a precisão da classificação por meio de um grande número de combinações de subconjuntos aleatórios de árvores (BREIMAN, 2001; BELGIU; DRĂGUȚ, 2016). A precisão da classificação RF é avaliada usando uma abordagem definida como *out-of-bag* (OOB). Nesta abordagem, o algoritmo RF coleta aproximadamente 75% dos dados como treinamento e o restante é deixado de fora (25%), daí o nome OOB. Em seguida, essas amostras OOB são direcionadas para árvores que ainda não foram utilizadas pelo classificador. Portanto, a diferença entre a classe esperada e a real é usada para estimar os erros de classificação (BREIMAN, 2001). Este método é considerado imparcial, pois à medida que o número de árvores aumenta, o erro tende a diminuir até um determinado limite. Além disso, a importância de cada variável no processo de classificação, em valores brutos e normalizados, é calculada a partir das amostras OOB.

O algoritmo SVM é um algoritmo que é treinado para encontrar um hiperplano de classificação ótimo, minimizando o limite superior do erro de classificação e maximizando a distância dos pontos de dados de cada classe ao hiperplano linear de separação ideal dos eixos criados a partir de cada variável (PETROPOULOS et al., 2011). O modelo SVM é otimizado para procurar um hiperplano não linear em um espaço multidimensional usando uma função Kernel (KARATZOGLOU et al., 2006). As funções Kernel mais utilizadas são: linear, polinomial, função de base radial (RBF) e sigmoide (HUANG et al., 2002).

A função Kernel escolhida mais amplamente utilizada é a RBF. Esta função possui dois parâmetros predefinidos: custo (C) e gama (g). Ambos os parâmetros dependem do intervalo e da distribuição dos dados e diferem de uma classificação para outra.

3 ARTIGO 1

EVALUATION OF POLARIMETRIC DATA AND TEXTURE ATTRIBUTES IN SAR IMAGES TO DISCRIMINATE SECONDARY FOREST IN AN AREA OF AMAZON RAINFOREST

Abstract: This study aims to evaluate the ability of Sentinel-1 polarimetric and backscatter attributes in relation to COSMO-SkyMed (CSM) texture and backscatter features to discriminate secondary vegetation areas in an Amazon Forest domain area, located in Mato Grosso state. In this study, we used polarizations VV and VH from Sentinel-1 Synthetic Aperture Radar (SAR) image and HH from CSM SAR image, both in Single Look Complex format. In the Sentinel-1 image, a covariance matrix was generated and the H-Alpha target decomposition theorem was applied, allowing to obtain the attributes Entropy and Angle alpha. In the CSM image, we obtained the following Gray-Level Co-Occurrence Matrix (GLCM) texture attributes: dissimilarity, contrast, homogeneity and second moment. The Support Vector Machine (SVM) algorithm was used for classification. The Sentinel-1 polarimetric attributes achieved a Kappa index of 0.70 and an overall accuracy of 79.58%, performing better than those derived from CSM, with a Kappa index of 0.56 and an overall accuracy 63.67%. However, the Sentinel-1 and CSM attributes did not present satisfactory results to discriminate the different stages of secondary forest.

Keywords: Amazon; Secondary Vegetation; Remote Sensing

3.1 INTRODUCTION

The Amazon biome has a rich biodiversity, which corresponds to an area with more than 5 million km² of the Brazilian territory (IBGE, 2022). This biome has been significantly from degradation resulting from deforestation (BERNARD; PENNA; ARAÚJO, 2014; GARRET et al., 2021). However, according to TerraClass Amazon data from 2014, there was an increase of 72.713 km² of secondary vegetation in the Amazon region between 2004 and 2014. From the deforested full area in Amazon, 22.8% are in regeneration process (TERRACLASS, 2022). Thus, the secondary vegetation diagnosis after the disturbance is very important for the evaluation of the respective impacts on the ecosystem, such as species diversity, local hydrology, and biomass accumulation rate (KUPLICH et al., 2006; JAKOVAC et al., 2015; NOBRE et al., 2016).

Forest regeneration in Brazilian Amazon increased in extent during the 1970s and 1980s and is known to be a net sink of atmospheric CO₂ (KUPLICH et al., 2005; CARVALHO

et al., 2019; HEINRICH et al., 2021). Optical remote sensors are used for the assessment and characterization of the secondary forest stage (LUCAS et al., 2000; SOTHE et al., 2017), but frequent cloud cover in the Amazon region often makes it difficult to obtain information based on these sensors. An alternative to this limitation has been the use of active microwave sensors, which include synthetic aperture radar (SAR) (DING and WEN, 2017). The SAR data applications in tropical forests are diverse, and they exploit different sensors, with different polarization options and processing techniques (LI et al., 2012). Sensors that operate at higher wavelengths (L and P bands) allow greater signal penetration in the forest (CARTUS et al., 2014; FURTADO et al., 2016), while the shorter microwave sensors (X and C bands) interact more superficially with the canopy structure (KUGLER et al., 2014; TREUHAFT et al., 2015).

One of the techniques used for forest monitoring is the SAR polarimetric data, often explored through target decomposition theorems (CLOUDE and POTTIER, 1996). This technique allows identifying the scattering mechanism types that occur during the interaction process between electromagnetic microwaves and the target, improving their discrimination (WIEDERKEHR et al., 2020). However, the attributes extracted from the backscatter signal, associated with Gray-Level Co-occurrence Matrix (GLCM) texture features (HARALICK et al., 1973) are also used, due to improvement in the identification and ability to discriminate different targets, according to the backscattered signal strength from a respective polarization (KUPLICH et al., 2005).

The Brazilian Government established several programs to monitor Amazon deforestation using optical data like PRODES (*Programa de Monitoramento do Desflorestamento na Amazônia Legal*) and DETER (*Sistema de Detecção do Desmatamento em Tempo Real*) projects from INPE (Instituto Nacional de Pesquisas Espaciais). In 2016, the Censipam (*Centro Gestor e Operacional do Sistema de Proteção da Amazônia*), an agency of the Brazilian Ministry of Defense, developed the first program using SAR data. Through the AmazôniaSAR project, Censipam monitors the forest change process in the Brazilian Amazon, with images from the COSMO-SkyMed (Constellation of Small Satellites to Observe Mediterranean Beaches) SAR sensor, band X (~ 2.4 - 3.8 cm), in periods of great cloudiness (SIPAM, 2021).

Currently, with the free availability by European Space Agency (ESA), the Sentinel-1A satellite, which operates in the C band (~ 3.9 – 7.5 cm) has become an important tool widely used for forest monitoring (REICHE et al., 2018; ESA, 2019). Given this, it is important to

develop methodologies that can exploit the potential of this free distribution data to contribute to forest monitoring systems.


Therefore, this study aims to evaluate the potential of attributes derived from polarimetric decomposition and backscatter coefficients of Sentinel-1 double polarization (VV and VH) SAR data in relation to texture and backscatter coefficient attributes of single polarization data from the CSM sensor (HH) to discriminate secondary forest (SF) areas. The research area will be the municipality of Colniza, located in Mato Grosso state.

3.2 METHODOLOGIES

3.2.1 Study area

The study area comprises the eastern portion of Colniza, located in the north of Mato Grosso state, between 9° 56' 26.47 and 9° 12' 23.69 south latitudes and between 59° 16' 57" and 59° 00' 52 west longitudes, in an area of approximately 1.600 km² (Figure 3.1). The study area comprises a region with large deforestation area, imaged by the CSM and Sentinel-1 sensors. The Colniza presented areas that were abandoned after deforestation and are in natural regeneration process now, in different ecological successional stages ([IBGE, 2012](#); [MAPBIOMAS, 2022](#)). The vegetation consists of dense and high forests typical of the Amazon, and Cerrado areas, presenting small trees, tortuous, isolated or grouped on a grass-covered soil. The climate, according to Köppen's classification, is Aw, humid tropical, with a mean temperature of 30°C. The average annual rainfall is 2.000 mm ([SANTOS et al., 2000](#)).

Figure 3.1. Localization of the study area. The color composite (July 12, 2017) includes the Sentinel 2 bands 11, 8 and 4 in red, green and blue, respectively.




Source: Authors (2022).

3.2.2 Radar image processing

The methodological procedures adopted in this study are shown in Figure 3.1. The Sentinel-1 image used in this study was acquired on September 3, 2017, in IW (Interferometric Wide swath) mode, which has a spatial resolution of 5x20 m, with processing level L1 - Single Look Complex (SLC), being complex images composed by amplitude and phase information, with double polarization: VV and VH. The image was processed in the Sentinel Application Platform 7.0 (SNAP) software. Firstly, the image went through the Terrain Observation with Progressive Scans (TOPSAR) *split* and *orbit* correction process, selecting a smaller subarea to minimize the computational effort. Then, the procedure of TOPSAR *deburst* and radiometric calibration was applied. The Covariance matrix [C2] was generated and resampled by a spatial average (Multilook process), a 3x3 pixel window size was performed, with the pixel spacing being converted to 14.05 m in range and azimuth directions.

Figure 3.2. Flow diagram of SAR images processing and classification procedures.



Source: Authors (2022).

To reduce speckle noise and preserve the details, the Sentinel-1 image was filtered with the Refined Lee filter (LEE et al., 1999) with a 5×5 pixel window size. This filter was chosen because it presents good results according to the studies of Pôssa et al. (2018) and Wiederkehr et al. (2020) with polarimetric attributes. After filtering, the backscattering coefficients were obtained in the VV (σ_{VV}), VH (σ_{VH}), and cross-polarization ratio (VV/VH) (CPRA). The H-Alpha polarimetric decomposition (CLOUDE and POTTIER, 1997) was performed to extract the attributes of entropy (H) and alpha-angle (α). Finally, the geometric correction of the attributes through geocoding was applied. The last procedure consisted of the attributes geometric correction through geocoding, using the digital elevation model (DEM) Shuttle Radar Topography Mission (SRTM).

The CSM image used in the study was sensed on 28 October 2017, in StripMap mode, sub-mode HIMAGE, in SLC format. The same preprocessing steps were performed to better compare the results of both sensors images. First, the image was calibrated at HH (σ_{HH}) polarization, followed by a multilook process with a 3×3 pixel window size, converting to 3 m spatial resolution in the range and azimuth directions, respectively. Then an image was filtered with the Refined Lee filter, 5×5 pixel window. GLCM was obtained to retrieve various texture metrics from the HH image, with a 3×3 pixel window size (HARALICK et al., 1973). Four texture metrics were computed: dissimilarity, homogeneity, second moment, and contrast. Previous studies conducted by Kuplich et al. (2005) and Sothe et al. (2017) showed that

homogeneity, contrast, second moment (energy) and dissimilarity were considered the most important ones for identifying vegetation successional stages in a patch of forest, which justifies their use in the present work. All processing steps were performed using Envi 5.5 software and your extension SARscape.

3.2.3 Attribute selection

The SF samples used in this study were extracted from crossing PRODES deforestation data and areas classified as secondary vegetation of the 2014 TerraClass Amazônia, a project of the National Institute for Space Research (INPE). As PRODES does not contemplate the revisit and reclassification of the mapped areas as deforested, it was possible to identify and vectorize the areas under the regeneration process. These samples were previously validated in *Google Earth Engine* through temporal analysis of the EVI and NDVI indices of the Landsat satellite image catalog.

The selection of the other reference samples representative of the thematic classes was based on the stratified random sampling method using an R11G8B4 color composition of a 10 m resolution Sentinel-2 image dated 12 July 2017, Level 1C geocoded. This composition was chosen because it better identifies the vegetation areas, due the high reflection of vegetation in the near infrared (NIR) region in relation to the marked absorption of chlorophyll in the red region of the electromagnetic spectrum ([PONZONI and REZENDE, 2004](#)).

To obtain samples set with the best representation of each class thematic, the selected samples were well distributed throughout the study area, where 180 polygons were vectorized. We sought to follow a proportion of 75% training samples and 25 % validation samples, respecting the size of each identified class (Table 3.1) ([CONGALTON and GREEN, 2009](#)).


Thus, 9 different land cover types were considered for the classification: Primary Forest (PFO) – Unchanged forests, Advanced Secondary Forest (SF3) - Natural regeneration with over 15 years, Intermediate Secondary Forest (SF2) - Natural regeneration from 5 to 15 years, Initial Secondary Forest (SF1) - Natural regeneration with less than 5 years, Croplands (CRO) - Areas with agriculture cover, Degraded Forest (DEG) – Forest areas with deforestation, Bare Soil (BSO) – Prepared areas to receive the cropland, Pasture (PAS) - Managed pasture areas, with grass cover and Water Bodies (WAT) – Rivers and lakes (Figure 3.3).

Table 3.1. Number of pixel for each class.

LULC	Training samples (pixel)	Validation samples (pixel)
PFO	14687	4896
SF1	2083	694
SF2	3796	1265
SF3	4030	1343
CRO	9089	3030
DEG	2026	675
BSO	6785	2262
PAS	5342	1781
WAT	234	78

Source: Authors (2022)

Figure 3.3. Samples set of study area. The color composite (July 12, 2017) includes the Sentinel 2 bands 4, 3 and 2 in red, green and blue, respectively.



Source: Authors (2022)

An exploratory analysis of attributes derived from polarimetric decomposition, texture, and backscatter metrics was performed to assess the potential for discrimination of SF

samples about other thematic classes. Boxplots were made for each attribute from the training samples, considering for the discriminatory understanding of radiometric component information extracted to express the configuration of the different thematic classes. In the attribute selection stage, a Principal Component Analysis (PCA) was performed. The PCA objective is to promote a linear transformation in the data so that the data resulting from this transformation have its most relevant components in the first dimensions (JAFARPOUR *et al.*, 2012).


From the selection of attributes for the secondary vegetation samples, the Land Use and Land Cover (LULC) classification was performed by applying the Support Vector Machine (SVM) classifier. In this work, the radial basis function kernel was chosen, for its superiority in relation to the other functions has been demonstrated in several studies (DURO *et al.*, 2012; SOTHE *et al.*, 2017). With the classification results and the test samples set, the confusion matrix was generated, to determine the accuracy of the classification that was based on Kappa index and overall accuracy (CONGALTON and GREEN, 2009).

3.3 RESULTS

3.3.1 Exploratory analysis of the attributes

The exploratory analysis of the Sentinel-1 H-alpha polarimetric decomposition attributes (Figure 3.4) showed similar values between the different typologies, and some sensitivities could be observed in certain typologies. However, both H and α showed a good ability to discriminate the PFO areas from SF areas in their different stages.

Figure 3.4. Boxplots representing the thematic classes distribution over the attributes derived from the H-alpha decomposition: entropy H (a) and alpha angle α (b). Attributes representing the thematic classes distribution over VV polarization (σ_{VV}) (c), VH polarization (σ_{VH}) (d) and the cross-polarization ratio (CPRA) (e) attributes derived from backscatter.



Source: Authors (2022).

The average values of H were relatively lower for the PFO class ($H = 0.74$), allowing to differentiate it from SF3 ($H = 0.79$), SF2 ($H = 0.77$) and SF1 ($H = 0.76$). Moreover, it is possible to observe that among the different stages of secondary forest, SF3 presented a higher average value of discrimination about SF2 and SF1. The same occurred for the α attribute, but the α scores were relatively higher in the PFO class ($\alpha = 68.5^\circ$), with more biomass and complex plant structure compared to SF3 ($\alpha = 66.2^\circ$), SF2 ($\alpha = 67.1^\circ$), SF1 ($\alpha = 67.7^\circ$). The SF3 class presented higher discrimination sensitivity compared to the SF1 and SF2 classes, indicating radiometric similarity between these stages.

The σ_{VH} attribute showed greater sensitivity to discriminate most thematic classes. The PFO class presented lower average backscatter values in relation to the SF areas ($\sigma_{VH} = -16.5$ dB), SF3 ($\sigma_{VH} = -15.8$ dB), SF2 ($\sigma_{VH} = -16.1$ dB) and SF1 ($\sigma_{VH} = -16.4$ dB).

On the other hand, the σ_{VV} attribute showed very close average values between the PFO ($\sigma_{VV} = -10.5$ dB), SF3 ($\sigma_{VV} = -10.4$ dB), SF2 ($\sigma_{VV} = -10.4$ dB), SF1 ($\sigma_{VV} = -10.5$ dB) classes and CRO ($\sigma_{VV} = -10.5$ dB), indicating high radiometric similarity for this attribute, and it is not possible to discriminate these respective classes from each other. The CPRA attribute also presented a low discrimination capacity between SF3 (5.41), SF2 (5.73), and SF1 (5.9) classes.

The σ_{HH} attribute of the CSM image (Figure 3.5) exhibited very similar mean backscatter values between the PFO ($\sigma_{HH} = -11.7$ dB), SF3 ($\sigma_{HH} = -11.3$ dB), SF2 ($\sigma_{HH} = -11.2$ dB), SF1 ($\sigma_{HH} = -11.2$ dB), and CRO ($\sigma_{HH} = -11.4$ dB) classes.


The dissimilarity attribute obtained by GLCM texture metrics also showed very similar mean values between PFO and SF3, 0.203 and 0.209 respectively. This attribute achieved greater discrimination between SF3 class and SF2 class, with fewer biomass classes that presented lower values.

The second moment GLCM texture attribute proved high capability to discriminate complex vegetation structure areas from more simple vegetation structures, but failed to discriminate the SF stages from each other.

The homogeneity attribute had the lowest average values for the PFO class (0.90). The SF classes presented high radiometric similarity among themselves, SF3 (0.92), SF2 (0.93) and SF1 (0.92), and cannot be discriminated according to the regeneration stage by this attribute.

Finally, the contrast showed very low average values for all thematic classes analyzed, with the median very close to zero. The SF classes presented very high similarity, SF3 (0.007), SF2 (0.005) and SF1 (0.007), and cannot be discriminated by this attribute.

Figure 3.5. Boxplot representing the thematic classes distribution over HH polarization (σ_{HH}) (a) and the GLCM texture metrics: Dissimilarity (b), Second moment (c), Homogeneity (d), and Contrast (e).



Source: Authors (2022).

According to the PCA described in Table 3.2, it is clear that there is a reduction in variance explained by the first 2 components. From the data derived from Sentinel-1, it can be observed that the first two CP present very close values between the secondary vegetation stages, with 71.1% for SF1, 71.7% for SF2, and 72.8% for SF3 of explained variance. Regarding the data derived from the CSM, the values between PC1 and PC2 present a greater difference between the values, of which the sum between the two first components is 70.9%, 69.9%, and 59.9% for SF1, SF2, and SF3 respectively. Therefore, it is observed that a better grouping between PC1 and PC2.

Table 3.2. Percentage of variance explained on each PC [%].


PCA dimension	PC1			PC2			PC3		
SF classes	SF1	SF2	SF3	SF1	SF2	SF3	SF1	SF2	SF3
Sentinel-1	39.5	38.8	38.7	31.6	32.9	34.1	27.0	27.0	25.2
CSM	50.9	49.9	39.9	20.0	20.0	20.0	18.4	18.7	19.2

Source: Authors (2022).

Figure 3.6 shows the polarimetric attributes H and alpha angle from Sentinel-1, which presented the largest information in the main components (PC1 and PC2). For the three SF stages, the accumulated percentage of information variance was 72.79% for SF3, 71.15% for SF2, and 71.09% for SF1. For the attributes extracted from the CSM, the GLCM homogeneity, dissimilarity, and contrast textures presented the highest information in PC1, with a cumulative total variance percentage of 79.18%, 88.58%, and 89.27% for SF3, SF2, and SF1, respectively.

PC1 is simultaneously the direction of the highest variance and the best straight line that minimizes the average distance between values, followed by PC2. Thus, the SVM classification was generated through the combination of the attributes H and alpha angle for the Sentinel-1 and GLCM textures homogeneity, dissimilarity, and contrast for the CSM image.

Figure 3.6. Contribution of each attribute extracted from Sentinel1 and CSM in PC1-2 to SF1 (a), SF2 (b), and SF3 (c) classes. Homo: Homogeneity GLCM; Dissi: Dissimilarity GLCM; Contr: Contrast GLCM; SM: Second moment GLCM.



Source: Authors (2022).

3.3.2 SVM classification results

The best result was obtained by SVM classification in Sentinel-1-derived from polarimetric data, with an overall accuracy of 79.58%, and a Kappa index of 0.70. This result is considered good according to the scale proposed by [Landis and Koch \(1977\)](#). According to the confusion matrix (Table 3.3), the classification demonstrated a high ability to discriminate BSO and PFO classes, with an accuracy of 88.3% and 83.1% respectively. Concerning secondary forest areas, the classifier presented a relative high capacity in classifying SF3 areas, with 78.4% producer's accuracy, however, the SF2 and SF1 classes presented lower classification accuracy of 0.1% and 8.2% respectively.

The main classification errors of SF2 and SF1 classes were commissioned for DEG and SF2 classes respectively. About the other classes, the lower classification performance was found for the CRO and DEG classes. The accuracy of the CRO, DEG, BSO, PAS, and WAT classes was 38.1%, 26.8%, 88.3%, 79.4% and, 53.0% respectively.

Table 3.3. Confusion matrix of the image classification derived from Sentinel.

		Reference [%]									User's accuracy [%]
		PFO	SF3	SF2	SF1	CRO	DEG	BSO	PAS	WAT	
Classification [%]	PFO	83.1	7.8	0.0	0.0	0.2	0.0	0.0	0.0	5.4	96.3
	SF3	4.4	78.4	1.8	0.4	9.4	0.0	0.0	4.4	17.4	80.3
	SF2	0.0	0.5	0.1	74.0	8.7	4.3	0.1	3.9	0.1	0.1
	SF1	2.8	14.6	0.9	8.2	42.2	0.1	0.0	4.7	0.4	0.9
	CRO	8.2	2.8	0.0	0.9	38.1	0.0	0.0	0.1	0.1	53.4
	DEG	0.0	0.0	95.9	1.8	0.0	26.8	0.6	0.0	0.0	16.7
	BSO	0.0	0.1	0.0	0.7	0.0	56.3	88.3	7.3	1.0	78.3
	PAS	0.0	5.0	1.1	14.0	1.2	12.3	10.8	79.4	22.6	88.6
	WAT	1.4	0.7	0.0	0.0	0.0	0.0	0.0	0.0	53.0	26.2
Producer's accuracy [%]		83.1	78.4	0.1	8.2	38.1	26.8	88.3	79.4	53.0	

Overall accuracy: 79.58% - Kappa index: 0.70

Source: Authors (2022).

The combination of GLCM texture attributes presented an overall accuracy of 63.67% and a Kappa index of 0.56, considered as moderate on the scale proposed by [Landis and Koch \(1977\)](#). According to the confusion matrix (Table 3.4), the classification showed a high capacity to classify the PFO class, with 95% accuracy, however the SF3 and SF2 regeneration classes presented low classification accuracies of 55.4% and 29.4% respectively. However, the SF1 class had the lowest percentage of accuracy in relation to the other classes, with about 1.6%. The main classification errors were commissioned for the PFO and SF3 classes. As to the other classes, the classification presented a low capacity to discriminate DEG, WAT and CRO, and high capacity to discriminate PAS and BSO. The accuracy of the CRO, DEG, BSO, PAS, and WAT classes was 60.9%, 6.5%, 78.6%, 79.2%, and 45.3%, respectively.

Table 3.4. Confusion matrix of the image classification derived from CSM.


		Reference [%]									User's accuracy [%]
Classification [%]		PFO	SF3	SF2	SF1	CRO	DEG	BSO	PAS	WAT	
	PFO	95.0	4.7	52.8	26.6	22.1	0.0	0.0	0.0	39.7	68.5
	SF3	4.2	55.4	14.2	37.1	13.9	1.8	0.2	6.8	3.8	41.0
	SF2	0.2	0.4	29.4	0.0	0.0	0.0	0.0	0.0	1.0	96.4
	SF1	0.0	2.7	0.4	1.6	1.5	0.0	0.0	1.8	0.0	12.4
	CRO	0.1	8.9	3.0	32.4	60.9	0.0	0.0	1.4	0.2	51.6
	DEG	0.0	1.1	0.0	0.0	0.0	6.5	7.4	4.1	8.0	14.8
	BSO	0.0	0.3	0.0	0.0	0.0	73.1	78.6	6.3	0.7	61.5
	PAS	0.1	25.8	0.1	2.2	1.5	17.7	13.6	79.2	1.2	78.3
	WAT	0.2	0.7	0.0	0.0	0.0	0.7	0.0	0.1	45.3	49.3
Producer's accuracy [%]		95.0	55.4	29.4	1.6	60.9	6.5	78.6	79.2	45.3	

Overall accuracy: 63.67% - Kappa index: 0.56

Source: Authors (2022).

Figure 3.7 shows the potential of the Sentinel-1 H-alpha decomposition attribute group and CSM-derived GLCM texture attributes to produce LULC maps from the SVM classifier.

Figure 3.7. SVM classification results.



Source: Authors (2022).

We note a predominance of PFO and BSO classes in the study area. The SF classes occupy less than 15% of the study area from Sentinel-1 attributes and are distributed throughout the study area in relatively small areas. However, in the classification derived from the CSM attributes, the SF classes represent 37% of the total area, distributed together with the PFO class. The classes DEG and WAT are the smallest classes in the study area, in both classification maps (Table 3.5).

Table 3.5. LULC areas derived from SVM classification results (km²).

LULC	Sentinel-1	CSM
PFO	294.5	196.1
SF1	29.3	79.2
SF2	31.4	69.5
SF3	66.6	176.7
CRO	166.7	78.9
DEG	27.6	21.1
BSO	182.6	244.3
PAS	96.5	14.2
WAT	5.4	0.6

Source: Authors (2022)

3.4 DISCUSSION

Attributes derived from Sentinel-1 H-alpha polarimetric decomposition technique showed good discrimination potential for the SF3 class. However, the potential to distinguish SF1 and SF2 classes was not as good. The *H* attribute presented high average values for the forest classes in different successional stages, indicating that the different scattering mechanisms contributed similarly to the signal returned to the sensor, only distinguishing the SF3 class from the other SF classes, according to the SVM classification results.

According to exploratory analyzes using boxplot and PCA, the attributes extracted from the Sentinel-1 H-alpha decomposition exhibited the best capacity to discriminate secondary forest classes from other classes than from backscatter coefficients, however, the values are still similar. Entropy measures the degree of random distribution of backscatter

mechanisms and the alpha angle makes it possible to identify and describe the type of target backscatter mechanism (CLOUDE and POTTIER, 1996).

As for the analysis of GLCM texture attributes from CSM, the discrimination between regeneration areas was low. The values of the classes are directly related to the types of canopies structured in the different regeneration stages. The canopy of the early and intermediate succession stages is usually smaller in size and density than those in the more advanced stage of secondary forest. The PFO and SF3 classes presented a higher general discrimination capacity than the other classes with lower vegetation cover. However, despite the pre-processing filtering, the CSM image presented a grainy appearance (speckle effect) that difficult the interpretation and classification. This effect is magnified due to the short wavelength of the X-band (KUCK *et al.*, 2021).

The confusion matrix of Table 3.3 shows the low classification performance of the different successional stage classes derived from the CSM GLCM texture attributes. The X band has more interaction with the top of the canopy than the C-band, without a wide range of target penetration. It detects the still conserved structures, although they may be degraded by burns, for example, thus generating a spectral confusion between the classes (AZEVEDO *et al.*, 2014).

Azevedo *et al.* (2014) in their study on LULC of an area in the Amazon with CSM data concluded that the inclusion of textural information did not indicate significant improvement in thematic performance, being statistically similar to that achieved by the group of attributes formed only by the intensity images. The authors suggest that the use of L-band data associated with X-band data allows the aggregation of information from backscattering of structures located inside the canopy, or even soil information, better characterizing the plant typology present in the study area.

Wiederkehr *et al.* (2020) used polarimetric decomposition techniques in ALOS PALSAR-2 L band images for LULC classification in the Tapajos Forest. In this study, the best attributes for discriminating secondary vegetation classes were anisotropy, derived from the decomposition Cloude-Pottier, and volumetric scattering derived from the Freeman-Durden decomposition. Li *et al.* (2012) analyzed data from the ALOS PALSAR-1 L band and RADARSAT C band for LULC classification in Altamira, Para Brazil, through the combination of radiometric and textural images. The authors claim that L-band data provided a much better classification than C-band data. However, neither L-band nor C-band data can accurately

separate detailed forest. L-band data provided reasonably good classification accuracies for a coarse set of classes such as forest and secondary succession.

In this study, the attributes derived from Sentinel-1 and CSM were not able to discriminate the different stages of secondary forest. According to [Pereira et al. \(2016\)](#), one factor that can contribute to these results is the high complexity of forest cover presented by these classes. Because of this complexity, differences in vegetation structure cannot be evident, mainly regarding classes of sequential stages of regrowth. Future research suggests exploring L-band SAR data with different polarimetric decompositions to discriminate areas of secondary vegetation. Additionally, it is suggested to perform tests with interferometry techniques, as it provides additional information on the three-dimensional structure of the targets in the image. This technique has already been employed in large-scale mapping and forest monitoring, as it increases the classification accuracy (GAMA et al., 2010).

3.5 CONCLUSIONS

This study shows the difficulties presented by working with SAR data and secondary forest different stages. C-band data provided reasonably good classification accuracies for a coarse set of classes such as primary forest, secondary forest advanced, with overall accuracy and Kappa coefficient of 72.2% and 0.64, respectively. The attributes derived from the H-Alpha polarimetric decomposition present better capacity to discriminate secondary forest classes from other classes, however, the values are still similar, it is not possible to discriminate the classes of secondary vegetation from each other.

However, X-band provided overall accuracy and Kkappa coefficient of only 63.67% and 0.56 for the SVM classification. According to the analysis of boxplots and PCA, the attributes extracted by the backscattering coefficients in the VV and VH polarizations of Sentinel-1 and the HH polarization of CSM sensor in the proposed LULC classification did not show good results for the SF classes' discrimination.

PCA was used in this study to reduce the dimensions of the original variables without loss of information by summarizing the data containing many variables by a smaller set of variables. Given the results obtained, the PCA proved to be effective, allowing the removal or disposal of three attributes derived from Sentinel-1 backscattering and two attributes related to GLCM texture and backscattering, attributes that showed low variability or were redundant

because they correlated with one another. Those of major importance were concentrated in main components, namely in the 1st and 2nd dimensions. Thus, fewer attributes were required to explain the overall variation, resulting in time and resource savings.

Preliminary results from this study suggest that Sentinel-1 IW data may be an important source of information for the mapping of land cover in the domain of tropical forests, as they can properly distinguish between those of primary structural and physiognomic configuration. The advanced successional phase of the other typological features of the vegetation cover, as well as exposed soil and cultivated area presented confusion. The results presented in this research aims at contributing to improve LULC mapping with the use of X-band and C-band data. It is suggested the association of SAR interferometry could contribute to the discrimination of forest classes with the use of interferometric coherence and even with altimetric information. Also, as future research it is suggested to explore L-band SAR data with different polarimetric decompositions techniques.

Funding

Bárbara Hass Kiyohara was supported by the *Coordenação de Aperfeiçoamento de Pessoal de Nível Superior* (CAPES, Process # 88887.500593/2020-00) and the *Conselho Nacional de Desenvolvimento Científico e Tecnológico* (CNPq, Process # 380070/2020-0).

Acknowledgements

The authors gratefully acknowledge Telespazio which provided COSMO Sky-Med data and Censipan (*Centro Gestor e Operacional do Sistema de Proteção da Amazônia*) for the support to this project. This research was supported by the *Coordenação de Aperfeiçoamento de Pessoal de Nível Superior* (CAPES, Process # 88887.500593/2020-00) and the *Conselho Nacional de Desenvolvimento Científico e Tecnológico* (CNPq, Process # 380070/2020-0).

3.6 REFERENCES

AZEVEDO, A. R. D. *et al.* Caracterização de uso e cobertura da terra na Amazônia utilizando imagens duais multitemporais do COSMO-SkyMed. **Acta Amazonica**, v. 44(1), p. 87- 98, 2014.

BERNARD, E.; PENNA, L. A.; ARAÚJO, E. Downgrading, downsizing, gazettelement, and reclassification of protected areas in Brazil. **Conservation Biology**, v. 28(4), p. 939-950, 2014.

CARTUS, O. *et al.* A national, detailed map of forest aboveground carbon stocks in Mexico. **Remote Sensing**, v. 6(6), p. 5559-5588, 2014.

CARVALHO, R.; ADAMI, M.; AMARAL, S. *et al.* Changes in secondary vegetation dynamics in a context of decreasing deforestation rates in Pará, Brazilian Amazon. **Applied Geography**, v. 106, p. 40-49, 2019.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 2.ed. New York: Lewis Publishers, 183 pp., 2009.

CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34(2), p. 498-518, 1996.

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(1), p.68-78, 1997.

DING, B.; WEN, G. Exploiting multi-view SAR images for robust target recognition. **Remote Sensing**, v. 9(11), p.1150, 2017.

DURO, D. C.; FRANKLIN, S. E.; DUBÉ, M. G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. **Remote Sensing of Environment**, v. 118, p. 259-272, 2012.

ESA. European Space Agency 2019. **Copernicus Sentinel-1: The SAR imaging constellation for land and ocean services**. Available at: <https://earth.esa.int/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-1>. Access in: 10 September 2019.

FURTADO, L. F. A.; SILVA, T. S. F.; MORAES, E. M. L. M. Dual-season and full-polarimetric C band SAR assessment for vegetation mapping in the Amazon varzea wetlands. **Remote Sensing of Environment**, v. 174, p. 212-222, 2016.

GAMA, F. F. *et al.* An evaluation of interferometric SAR potential for altimetric mapping of reforested areas by eucalyptus SP. **Boletim de Ciências Geodésicas**, v. 16(4), p. 519-537, 2010.

GARRETT, R. D. *et al.* Forests and sustainable development in the Brazilian Amazon: History, trends, and future prospects. **Annual Review of Environment and Resources**, v. 46, p. 625-652, 2021.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, v. 6, p. 610-621, 1973.

HEINRICH, V. H. *et al.* Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change. **Nature Communications**, v. 12, p. 1-11, 2021.

- IBGE. Amazônia Legal. Available at: <<https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html?=&t=acesso-ao-produto>>. Access in: 12 September 2022.
- IBGE. **Manual Técnico da Vegetação Brasileira. Manuais Técnicos em Geociências**, n. 1, Rio de Janeiro, IBGE, 274 p, 2012.
- JAFARPOUR, S.; SEDGHI, Z.; AMIRANI, M. C. A robust brain MRI classification with GLCM features. **International Journal of Computer Applications**, v. 37(12), p. 1-5, 2012.
- JAKOVAC, C. C. *et al.* Loss of secondary-forest resilience by land-use intensification in the Amazon. **Journal of Ecology**, v. 103(1), 67-77, 2015.
- KUCK, T. N.; GOMEZ, L. D.; SANO, E. E.; BISPO, P. D. C.; HONÓRIO, D. D. Performance of Speckle Filters for COSMO-SkyMed Images from the Brazilian Amazon. **IEEE Geoscience and Remote Sensing Letters**, v. 19, p. 1-5, 2019.
- Kugler, F. *et al.* TanDEM-X Pol-InSAR performance for forest height estimation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52(10), p. 6404-6422, 2014.
- KUPLICH, T. M.; CURRAN, P. J.; ATKINSON, P. M. Relating SAR image texture to the biomass of regenerating tropical forests. **International Journal of Remote Sensing**, v. 26(21), p. 4829-4854, 2005.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, p. 159-174, 1977.
- LEE, R.; DE GRANDI, M. R.; DE GRANDI, G. Polarimetric SAR speckle filtering and its implication for classification. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37(5), p. 2363-2373, 1999.
- 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**, v. 70, p. 26-38, 2012.
- LUCAS, R. M. *et al.* Mapping the regional extent of tropical forest regeneration stages in the Brazilian Legal Amazon using NOAA AVHRR data. **International Journal of Remote Sensing**, v. 21(15), p. 2855-2881, 2000.
- MAPBIOMAS. **MapBiomass v. 6.0**. Available online: <https://mapbiomas.org/en/statistics> (accessed on 25 June 2022).
- NOBRE, C. A. *et al.* Land-use and climate change risks in the Amazon and the need of a novel sustainable development paradigm. **Proceedings of the National Academy of Sciences**, v. 113(39), p. 10759-10768, 2016.

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**, v. 9(12), p. 5413-5423, 2016.

PONZONI, F. J.; REZENDE, A. N. P. Caracterização espectral de estágios sucessionais de vegetação secundária arbórea em Altamira (PA), através de dados orbitais. **Revista Árvore**, v. 28, p. 535–545, 2004.

PÔSSA, E. M. *et al.* Análise de uso e cobertura da terra na região do Tapajós, Amazônia central, a partir de dado polarimétrico PALSAR/ALOS-1 e coerência interferométrica TanDEM-X. **Revista Brasileira de Geografia Física**, v. 11(6), p. 2094-2108, 2018.

REICHE, J. *et al.* Improving near-real time deforestation monitoring in tropical dry forests by combining dense Sentinel-1 time series with Landsat and ALOS-2 PALSAR-2. **Remote Sensing of Environment**, v. 204, p. 147-161, 2018.

SANTOS, M. V. **Zoneamento Sócio-Econômico-Ecológico: diagnóstico sócio-econômico-ecológico do Estado de Mato Grosso e assistência técnica na formulação da 2ª aproximação**. Cuiabá, MT: SEPLAN-MT, 2000.

SIPAM. **Projeto Amazônia SAR: desenvolvimento operacional e primeiros resultados na identificação do desmatamento com radar orbital**. Available at: <http://www.sipam.gov.br/projeto-amazonia-sar>. Access: 21 September 2021.

SOTHE, C. *et al.* Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in Southern Brazil. **Remote Sensing**, v. 9(8), p. 838, 2017.

TERRACLASS. **Amazonia Legal**. Available at: <https://www.terraclass.gov.br/geoportal-aml/>. Access: 3 February 2022.

TREUHART, R. *et al.* Tropical-forest biomass estimation at X-band from the spaceborne TanDEM-X interferometer. **IEEE Geoscience and Remote Sensing Letters**, v. 12(2), p. 239-243, 2015.

WIEDERKEHR, N. C. *et al.* Discriminating forest successional stages, forest degradation, and land use in central Amazon using ALOS/PALSAR-2 full-polarimetric data. **Remote Sensing**, v.12, p. 3512, 2020.

4 ARTIGO 2

Article

Mapping Secondary Vegetation of a Region of Deforestation Hotspot in the Brazilian Amazon: Performance Analysis of C- and L-Band SAR Data Acquired in the Rainy Season

Bárbara Hass Kiyohara ^{1,*} and Edson Eyji Sano ²

¹ Institute of Geosciences, University of Brasília, Brasília 70297-400, Brazil

² Embrapa Cerrados, Planaltina 73310-970, Brazil

* Correspondence: babs.hass@gmail.com



Citation: Kiyohara, B.H.; Sano, E.E. Mapping Secondary Vegetation of a Region of Deforestation Hotspot in the Brazilian Amazon: Performance Analysis of C- and L-Band SAR Data Acquired in the Rainy Season. *Forests* **2022**, *13*, 1457. <https://doi.org/10.3390/f13091457>

Academic Editors: Fabiana Caló, Filiz Bektas Balçık, Fusun Balık Sanlı and Antonio Pepe

Received: 2 August 2022

Accepted: 7 September 2022

Published: 10 September 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: The re-suppression of secondary vegetation (SV) in the Brazilian Amazon for agriculture or land speculation occurs mostly in the rainy season. The use of optical images to monitor such re-suppression during the rainy season is limited because of the persistent cloud cover. This study aimed to evaluate the potential of C- and L-band SAR data acquired in the rainy season to discriminate SV in an area of new hotspot of deforestation in the municipality of Colniza, northwestern of Mato Grosso State, Brazil. This is the first time that the potential of dual-frequency SAR data was analyzed to discriminate SV, with an emphasis on data acquired during the rainy season. The L-band ALOS/PALSAR-2 and the C-band Sentinel-1 data acquired in March 2018 were processed to obtain backscattering coefficients and nine textural attributes were derived from the gray level co-occurrence matrix method (GLCM). Then, we classified the images based on the non-parametric Random Forest (RF) and Support Vector Machine (SVM) algorithms. The use of SAR textural attributes improved the discrimination capability of different LULC classes found in the study area. The results showed the best performance of ALOS/PALSAR-2 data classified by the RF algorithm to discriminate the following representative land use and land cover classes of the study area: primary forest, secondary forest, shrubby pasture, clean pasture, and bare soil, with an overall accuracy and Kappa coefficient of 84% and 0.78, respectively. The RF outperformed the SVM classifier to discriminate these five LULC classes in 14% of overall accuracy for both ALOS-2 and Sentinel-1 data sets. This study also showed that the textural attributes derived from the GLCM method are highly sensitive to the moving window size to be applied to the GLCM method. The results of this study can assist the future development of an operation system based on dual-frequency SAR data to monitor re-suppression of SV in the Brazilian Amazon or in other tropical rainforests.

Keywords: secondary vegetation; rainy season; ALOS-2; sentinel-1; random forest; support vector machine

1. Introduction

Regardless of global importance of tropical forests in terms of biodiversity conservation and carbon and water cycling maintenance, the Brazilian Legal Amazon is losing, on average, about 13.8 thousand km² per year of primary forest by clear-cut deforestation since 1988 [1]. The main purposes of such deforestation are beef production, crop plantation, land speculation, and the installation of hydroelectric plants, among other activities [2–5]. Some authors have pointed out the recent increase of the deforestation rate [6,7], raising from 5000 km² of clear-cut deforestation in 2014 to 13,000 km² in 2021 [1].

Some of the clear-cut deforested areas are abandoned, entering in the process of natural regrowth through secondary succession. This regrowing vegetation is known as secondary vegetation (SV) [8,9]. According to the Global Forest Resources Assessment report of 2020 [10], the world has 3.7 billion ha of SV. The TerraClass project, coordinated by the National Institute for Space Research (INPE) and the Brazilian Agricultural Research

Corporation (Embrapa Agricultura Digital and Embrapa Amazônia Oriental) [11], showed that SV has increased from 10 million ha to 17 million ha in the Brazilian Legal Amazon between 2004 and 2014 [12]. The natural regeneration of forests is an effective low-cost mechanism of carbon sequestration, particularly in tropical regions [13]. Although the net carbon uptake from atmosphere is up to 20 times higher than that from old-growth forests, this tends to be neglected in most of the carbon balance studies in the Brazilian Amazon [14]. Besides its particular interest as source of carbon sink, SV can be seen as having great potential for agriculture and livestock expansion [15] or for biodiversity conservation and ecosystem service [16].

Nunes et al. [17] highlighted different aspects related to the growing pressure to suppress already-deforested SV found in the Brazilian Amazon. For example, landowners face difficulty to find ways to monetize climate change mitigation and other ecosystem services provided by SV. The Brazilian Federal Law No. 12651, known as the Brazilian Forest Code, does not protect or regulate land use in areas occupied by regenerating forests. On the other hand, the same Brazilian Forest Code places severe restrictions for deforesting native forests located in the Brazilian Amazon biome. Landowners must keep 80% of their rural properties preserved by native forests [18], encouraging the use of existing regrowing lands.

The current deforestation monitoring system of the Brazilian Amazon such as the Project of Monitoring Deforestation of the Brazilian Amazon Forest by Satellite (PRODES) [1], Near Real-Time Deforestation Detection System (DETER-B) [19], and Deforestation Alert System (SAD) [20] do not monitor SV since they track only clear-cut deforestation, selective logging, and degradation by fire that occurs in primary forests, masking previously deforested areas as well as non-forest native vegetation formations. The TerraClass Amazon project [11] is the only project aimed at monitoring secondary vegetation every two years. In this project, clear-cut deforested areas detected by the PRODES are inspected by Landsat-like satellite images (i.e., typically, 30 m spatial resolution and 16 day repeat-pass) after two years to determine the corresponding land use and land cover (LULC) class, for example, pasture, cropland, or SV. More recently, Nunes et al. [17] assessed the extent, age, net carbon balance, and annual dynamics of the SV in the Brazilian Amazon by using the LULC maps derived from Landsat time series and produced by the MapBiomass project [21] from 1985 to 2017. The SV area has increased over time, reaching 12 million ha in 2017, 44% of which was under 5 years old. Indeed, most of the estimations of the extent of the SV is often conducted based on remote sensing data derived from optical sensors e.g., [22,23].

Long time series of optical satellite data such as the Landsat historical data provide important information on the spatial and temporal patterns of deforested areas in the process of regeneration in the Brazilian Amazon. However, because of the constraints related to the persistent cloud coverage in tropical regions, optical remote-sensing-derived information of SV will be mostly related to the peak of the dry season, which is from July to September in the Brazilian Amazon. Thus, studies involving the seasonal variations of SV, similar to the one conducted by [24] in an Amazon tropical evergreen forest, or re-suppression monitoring of SV, which typically occurs during the end of the wet season, will be limited. Although the Brazilian Forest Code does not provide any governance regarding SV, the Pará State, which hosts most areas with regrowing vegetation in the Brazilian Amazon (~64,000 km² in 2014), has approved administrative procedures for suppressing SV in the initial state of regeneration (Normative Instruction No. 8, 28 October 2015) [25].

Synthetic aperture radar (SAR) observations are available regardless of cloud conditions, enabling the monitoring of the dynamics of the SV throughout the year. The SAR data acquired by the Advanced Land Observing Satellite (ALOS)/Phased Array Type L-band Synthetic Aperture Radar (PALSAR) satellite launched by the Japan Aerospace Exploration Agency (JAXA) [26] have been used by several authors to detect deforestation over the Brazilian Amazon e.g., [27,28], or to estimate the above-ground biomass of SV over the Central Amazon [29]. The common sense is that the differences in the backscattering coeffi-

cients between forest and non-forest lands are much more enhanced in the L-band than in shorter wavelengths (X- and C-bands) [30]. However, the constellation of two C-band, 5 m spatial resolution Sentinel-1A and Sentinel-1B satellites launched by the European Space Agency (ESA) is unique because they comprise the only updated SAR data that are freely available on the internet [31], allowing for low-cost studies of near real-time deforestation and degradation detections [32–34]. Some authors have combined L-band ALOS data with the Landsat data to obtain better classification results of different stages of SV in the Brazilian Amazon [35,36]. Despite their promising results, such combinations are always dependent on the availability of cloud-free optical images.

Monitoring the near real-time re-suppression of SV in the Brazilian Amazon using SAR data, especially in those areas with an advanced stage of regeneration, is crucial for environmental law enforcement procedures by the Brazilian Institute of Environment and Renewable Natural Resources (IBAMA) and by the state environmental agencies. The only L-band, SAR-based, early deforestation monitoring system available for the Brazilian Amazon is the JICA-JAXA Forest Early Warning System in the Tropics (JJ-FAST), which started in November 2016. This system is based on the ALOS/PALSAR-2 ScanSAR images, which operate with a 60 m pixel size, every 42 days, and a minimum mapping unit (MMU) of 2 ha [27,28]. More recently, Doblas et al. [37] proposed the DETER-R system, a fully automated forest disturbance detection system for the Brazilian Amazon based on times series of C-band, Sentinel-1 data processed in the Google Earth Engine platform, with a MMU of 1 ha. Both JJ-FAST and DETER-R were developed with the aim of monitoring clear-cut deforestation. In other words, approximately 25% of the total clear-cut areas in the Brazilian Amazon that have been converted into SV [38] are not taken into consideration. The objective of this study was to evaluate the potential of combined C- and L-band SAR data to discriminate SV in the Brazilian Amazon. To our best knowledge, this is the first time that the potential of dual-frequency SAR data is analyzed to discriminate SV, with an emphasis on data acquired during the rainy season. The results of this study can assist the future development of a dual-frequency SAR system to monitor the re-suppression of SV in the Brazilian Amazon. Besides the L-band ALOS/PALSAR-2, currently in operation, we will have the launch of ALOS-4, the NASA-ISRO SAR (NISAR) mission, and TanDEM-L in the next few years [39], ensuring the availability of L-band SAR data for the next years.

2. Materials and Methods

2.1. Study Area

The study area comprises a region of approximately 24,000 ha in the eastern portion of the municipality of Colniza (Figure 1), in the northwestern part of the Mato Grosso State, between 9° 36' 23.7" and 9° 45' 26.5" south latitude and between 59° 10' 52" and 59° 19' 57" west longitude. The vegetation consists of dense ombrophilous forests [40]. The climate, according to the Köppen's climate classification system, is Am, that is, tropical (hot and humid) with a short dry season. The rainy season corresponds to the months of October to May, with the mean annual rainfall varying from 2100 to 2500 mm [41].

The municipality of Colniza presents approximately 80% of its territory still covered by primary forest [42]. About 25% of its land is covered by three indigenous lands. However, together with the neighboring municipality of Aripuanã, it is the current deforestation hotspot of the Brazilian Amazon, especially along the BR-174 highway, in the eastern part of the municipality, and where our study area is located nearby. Colniza is already facing intense landscape fragmentation [43].




Figure 1. Location of the study area in the Brazilian Legal Amazon (a) and in the municipality of Colniza, Mato Grosso State (b). Study area over a Sentinel-2 true color composition image from 27 July 2018 (c).

2.2. Satellite Images

We selected Single Look Complex (SLC) Level 1.1, L-band ALOS/PALSAR-2 satellite images acquired on 24 March 2018 at the StripMap mode, with a spatial resolution of 6.25 m, HH and HV polarizations (hereafter referred to L-HH and L-HV polarizations, respectively), and an incidence angle of 36.6° . Another SLC SAR image selected for this study was the one acquired by the C-band Sentinel-1A satellite on 2 March 2018, with the Interferometric Wide (IW) acquisition mode, a spatial resolution of 14.05 m, VV and VH polarizations (hereafter referred to as C-VV and C-VH polarizations, respectively), and an incidence angle of 40.8° .

Two dry-season optical images, acquired by the Sentinel-2 Multispectral Instrument Image (MSI) and the China-Brazil Earth Resources Satellite (CBERS-4) data were also selected. The Sentinel-2 image was acquired on 27 July 2018, with the spatial resolution of 10 m. In this study, we selected the spectral bands 2, 3, and 4 (blue, green, and red bands, respectively). The CBERS-4 data were acquired by the wide-scan multispectral and panchromatic camera (WPM) on 9 July 2018, with the spatial resolutions of 10 m and 5 m, respectively. Drusch et al. [44] and INPE [45] provide technical details of Sentinel-2 and CBERS-4 satellites, respectively.

2.3. Methods

Figure 2 shows the main steps of the methodological approach considered in this study. The ground truth data were obtained from the data provided by the TerraClass and PRODES projects with the support of visual interpretation of the CBERS-4 image. The SAR images acquired by the ALOS-2 and Sentinel-1 satellites were pre-processed using the ESA's Sentinel Application Platform (SNAP) 7.0 software and classified by the Random Forest (RF) and Support Vector Machine (SVM) classifiers, after we performed texture attribute selection based on the Principal Component Analysis (PCA). The accuracies of the classifications were analyzed through the confusion matrix.




Figure 2. Flowchart showing the main steps of the methodological approach considered in this study.

2.3.1. Pre-Processing

The radiometric calibration of each L-HH- and L-HV-polarized image was carried out to obtain the backscattering coefficients (σ^0) in the ground range (Equation (1)):

$$\sigma^0 = 10 \log_{10}(I^2 + Q^2) + CF_1 - A \quad (1)$$

where I and Q are the real and imaginary parts of the complex images; CF is the radiometric calibration factor (−83 dB); A is the conversion factor (32 dB) [46].

The ALOS-2 images were also filtered with the GammaMap filter to reduce speckle [47,48] using a 5×5 window size. The geometric correction was performed through geocoding, using the digital elevation model (DEM) produced by the Shuttle Radar Topography Mission (SRTM) and made available at the 90 m spatial resolution.

The C-VV- and C-VH-polarized images were pre-processed through the Terrain Observation with Progressive Scans (TOPSAR) split and orbit correction algorithm and selecting a smaller subarea to minimize the computational effort. Then, the procedures of deburst and radiometric calibration were applied in this software. Subsequent speckle filtering by the GammaMap filter was applied also using a 5×5 window size. The last procedure consisted of geometric correction through geocoding, using the same process performed for the ALOS-2 image.

2.3.2. Feature Selection

The identification of SV in the study area was based on the Gray Level Co-occurrence Matrix (GLCM), which provides textural information based on second-order statistics. The GLCM is a matrix of relative frequency $P(i, j, d, \theta)$ that considers two neighboring pixels separated by the distance d and with orientation θ from each other in a sub-region of the image, one being gray scale pixel i and the other the gray scale pixel j . Four adjacencies are defined: horizontal (0°), vertical (90°), and two diagonals (45° and 135°) [49,50]. From each matrix, it is possible to extract the following textural features, which are widely used in the literature [51]:

$$\text{Entropy (Entr)} = \sum_{i,j} p(i,j) \log\{p(i,j)\} \quad (2)$$

$$\text{Homogeneity (Homo)} = \sum_{i,j} \frac{1}{1 + (i - j)^2} p(i,j) \quad (3)$$

$$\text{Variance (Vari)} = \sum_{i,j} (i - \mu)^2 p(i,j) \quad (4)$$

$$\text{Correlation (Corr)} = \sum_{n=0}^{N_g-1} n^2 \left\{ \frac{\sum_i \sum_j p_{(ij)}}{|i-j|=n} \right\} \quad (5)$$

$$\text{Mean} = \sum_{i,j} i(p_{(i,j)}) \quad (6)$$

$$\text{Energy (Ener)} = \sum_{i,j} p_{(i,j)}^2 \quad (7)$$

$$\text{Contrast (Cont)} = \sum_{i,j} p_{(i,j)}(i-j)^2 \quad (8)$$

$$\text{Angular Second Moment (ASMO)} = \sum_{i,j} \{p_{(i,j)}\}^2 \quad (9)$$

$$\text{Dissimilarity (Diss)} = \sum_{i,j} p_{(i,j)} |i-j| \quad (10)$$

where p_{ij} is the input value in the normalized GLCM; N_g represents the different gray levels of the image.

These textural analyses were applied to the both ALOS/PALSAR-2 and Sentinel-1 data. According to the previous studies [52–54], the selected window size in the GLCM textural analysis can impact the results of LULC classifications. Small windows can amplify the amount of noise in the texture image, while larger windows can smooth the texture variation, degrading the quality of texture attributes [53,55]. Thus, four different window sizes were tested for each set of texture attributes at the 64-bit quantization level (5×5 , 7×7 , 9×9 , and 11×11).

2.3.3. Principal Component Analysis

PCA is a technique that reduces data dimensionality by concentrating as much variance as possible in the first components based on a linear transformation [56]. In this study, in order to reduce the number of variables to be considered in the machine learning classification, we applied the PCA technique for the GLCM texture attributes. Then, we selected the first principal component (PC1) and the second principal component (PC2) to run the RF and SVM algorithms, which corresponds to same methodology applied by Wiederkehr et al. [57]. A total of 10 experiments were carried out with the SAR images (Table 1).

Table 1. Parameters of the classification experiments with SAR data.

Sensor	Experiment	Data Composition	GLCM Window Size
ALOS/PALSAR-2	A1	HH + HV	-
	A2	HH + HV + GLCM _{PC1} + GLCM _{PC2}	5×5
	A3	HH + HV + GLCM _{PC1} + GLCM _{PC2}	7×7
	A4	HH + HV + GLCM _{PC1} + GLCM _{PC2}	9×9
	A5	HH + HV + GLCM _{PC1} + GLCM _{PC2}	11×11
Sentinel-1	S1	VV + VH	-
	S2	VV + VH + GLCM _{PC1} + GLCM _{PC2}	5×5
	S3	VV + VH + GLCM _{PC1} + GLCM _{PC2}	7×7
	S4	VV + VH + GLCM _{PC1} + GLCM _{PC2}	9×9
	S5	VV + VH + GLCM _{PC1} + GLCM _{PC2}	11×11

The texture attributes have different ranges of values among themselves. To avoid overvaluing the attributes presenting higher values, we normalized all attributes in the [0–1] interval, according to the approach described by Soares et al. [58] and Azevedo et al. [55].

2.3.4. Reference Data and Sample Selection

Initially, a set of 122 irregular polygons were manually delimited based on the LULC classes mapped by the TerraClass project (year: 2014) and the deforestation data produced by the PRODES project (period: 2015–2018), in order to perform the image classification.

The TerraClass project is composed of 17 classes; however, only the following classes that are found in the study area were considered:

- Primary Forest (PF): areas of upland, broadleaf rainfall forests and gallery forests along drainages with no evidence of human activities;
- Secondary Vegetation (SV): clear-cut forests that are regrowing as consequence of abandonment (see more details in the Introduction section);
- Clean Pasture (CP): well-managed pastures for beef production;
- Shrubby Pasture (SP): poorly managed pastures for beef production, with the presence of weeds; and
- Bare Soil (BS): relatively small areas without vegetation cover, mostly along the roads.

The number of samples for each LULC classes was defined taking into consideration the proportion of size of each class, following the recommendations of Stehman [59] and Olofsson et al. [60], who indicated four different approaches for sample allocation: proportional, equal, optimal and power allocation. Thus, a set of 122 polygons was manually drawn in the ArcGIS™ software by overlaying the TerraClass and PRODES maps in the RGB color composite of bands 6, 7, and 8 of the CBERS-4A satellite fused with the 5 m panchromatic band by the Gram–Schmidt technique available in the ENVI 5.0™ image processing software. In terms of the number of Sentinel-1 pixels, 2844 pixels were selected in the PF class; 1782 pixels in the SV; 2296 pixels in the CP; 834 pixels in the SP; 168 pixels in the BS (Figure 3). In terms of ALOS/PALSAR-2 pixels, 5771 pixels were selected in the PF class; 3454 pixels in the SV; 4633 pixels in the CP; 1588 pixels in the SP; 298 pixels in the BS. These different sets of pixels correspond to the approximate proportion of LULC classes mapped in the study area by the TerraClass project: SV = 18%; CP = 31%; SP = 11%; BS = 2%.




Figure 3. Set of 122 samples based on the LULC classes mapped by the TerraClass project and the deforestation data produced by the PRODES project. The RGB color composite corresponds to the ALOS/PALSAR-2 data (R: HH/HV; G: HH; B: HV).

Images from the panchromatic band onboard the CBERS-4 satellite were used as a reference. A true composite was performed with the multispectral bands (10 m resolution) that were later merged through the Gram–Schmidt fusion technique with the panchromatic band with a 5 m spatial resolution.

2.3.5. Machine Learning Classifications

In this study, the image classifications were performed using the RF and SVM classifiers available in the EnMAP-Box software [61]. They were less sensitive to the speckle-affected SAR data, showing good classification results involving LULC dynamics in forests [62]. The RF algorithm uses decision trees to increase classification accuracy through many combinations of random subsets of trees [63]. It constitutes an ensemble and bagging algorithm, ensemble because it gathers and employs a set of regression trees classifiers and bagging because decision trees are created from subsets of the same sample set, with replacement [64]. In this study, we carried out preliminary tests with 100, 500, and 1000 trees. Although the classification accuracy increased with the increasing number of trees, we opted to use 500 trees in all classifications because of the best compromise between computational effort and model accuracy. Previous studies also have recommended 500 trees [64,65].

We evaluated the accuracy of the RF classification using an approach in which the RF algorithm collects approximately 75% of data as a training set while the remaining is left out, a procedure known as out-of-bag (OOB). The OOB samples are then directed to trees that have not been used by the classifier yet. The difference between the expected and the real class is used to estimate the classification error [63]. This method is considered unbiased because, as the number of trees increases, the error tends to decrease to a certain threshold. The importance of each variable in the classification process, in raw and normalized values, is calculated from the OOB samples. We considered the number of variables as the default value, which corresponded to the square root of the total number of input variables [64].

The SVM algorithm is a nonlinear classifier that is trained to find an optimal classification hyperplane. It minimizes the upper bound of the classification error and maximizes the distance of the data points of each class to the ideal separation linear hyperplane of the axes created from each variable [66]. The SVM model is optimized to look for a non-linear hyperplane in a multidimensional feature space using a kernel function [67]. The most used kernel functions are the linear, polynomial, radial basis function (RBF), and sigmoid functions [68]. In this study, we selected the RBF function, which has two predefined parameters, the cost (C) and the gamma (γ). Both parameters depend on the data range and distribution and differ from one classification to the other. In order to find the optimum C and γ parameters, a two-dimensional grid search with internal validation was performed within the EnMAP-Box software, for each classification [69].

2.3.6. Accuracy Analysis

The classification results from the experiments were analyzed through the confusion matrices (user's and producer's accuracies), Kappa coefficient, and overall accuracy (OA), with a level of significance of 5%. For the best classification result with the RF algorithm, the ranking of predicted variables showing the most important features was calculated.

3. Results

3.1. C- and L-Band Backscatter Coefficients

Figure 4 shows the average values and corresponding standard deviations of the backscattering coefficients of C-VV, C-VH, L-HH, and L-HV data sets obtained from the calibration sites. Co-polarized signals (L-HH and C-VV) were higher than those from the cross-polarized signals (L-HV and C-VH). This was somewhat expected since the backscattering process, involving cross-polarized energy, is mainly related to the volumetric scattering from the canopy, attenuating the SAR signal returned to the antenna [70]. In the case of co-polarized energy, most of the backscattering process is related to the stronger signal returns from trunks, branches, and leaves located in the upper part of the canopy.




Figure 4. Backscattering coefficients of primary forest (PF), shrubby pasture (SP), secondary vegetation (SV), bare soil (BS), and clean pasture (CP), derived from L-HH (A), L-HV (B), C-VV (C), AND C-VH (D) polarizations.

3.2. Most Relevant Texture Attributes of SAR Images

Figure 5 presents the ranking of the percentage of contribution of most important texture attributes of each SAR images considered in this study. The total contribution of first two principal components varied from 74.2% (L-HH polarization) to 98.4% (C-VV polarization). For the L-HH polarization, the variations explained by the first two principal components were 48.9% and 25.3%, respectively. For the L-HV polarization, the variations in PC1 and PC2 were 71.4% and 17.6%, respectively. For the C-VV polarization, the variations explained by PC1 and PC2 were 87.6% and 10.8%, respectively while for the C-VH polarization, the variations in PC1 and PC2 were 63.7% and 20.5%, respectively. The order of the importance of textural attributes varied according to the polarization. These texture features are considered the most important among all texture attributes analyzed for the SV samples and were grouped according to the results of each polarization. Table 2 shows how each set of texture features that was used in the experiments was organized. The ALOS/PALSAR-2 images had more texture attributes included in relation to the Sentinel-1 images, mainly regarding the HV cross-polarization.

Table 2. Organization of texture features used in each experiment, after PCA analysis.

Satellite	Experiments	Data Composition	No. Images
ALOS/ PALSAR-2	A1	L-HH + L-HV	2
	A2, A3, A4, and A5	L-HH + L-HH(mean) + L-HH(vari) + L-HH(ener) + L-HH(entri) + L-HH(homo) + L-HV + L-HV(corr) + L-HV(ener) + L-HV(entri) + L-HV(diss) + L-HV(homo) + L-HV(contr) + L-HV(ASMO) + L-HV(vari)	15
Sentinel-1	S1	C-VV + C-VH	2
	S2, S3, S4, and S5	C-VV + C-VV(homo) + C-VV(vari) + C-VV(ener) + C-VV(ASMO) + C-VV(corr) + C-VH + C-VH(ener) + C-VH(entri) + C-VH(corr) + C-VH(ASMO)	11




Figure 5. Contributions of the texture variables to the PC1 and PC2 components for ALOS/PALSAR-2 HH polarization (a), ALOS/PALSAR-2 HV polarization (b), Sentinel-1 VV polarization (c), and Sentinel-1 VH polarization (d). The red dashed line indicates the mean value at which the contributions were uniform.

3.3. Random Forest and Support Vector Machine Classification Results for the SAR Data

Table 3 shows the user's accuracy, producer's accuracy, OA, and Kappa coefficient for each experiment performed with the RF algorithm. In general, the performance of the ALOS/PALSAR-2 data was higher than that from Sentinel-1 data. The best result of the RF classification involving ALOS/PALSAR-2 data was achieved by the Experiment A5 (overall accuracy of 84.20%; Kappa coefficient of 0.78), while for the Sentinel-1 data, the best result was obtained by the Experiment S5 (overall accuracy of 81.07%; Kappa coefficient of 0.73). We can note an improvement when texture attributes were added to the backscatter values in both the ALOS-2 and Sentinel-1 data.

Table 3. Overall accuracy (OA) and Kappa coefficient for the Random Forest classification experiments involving ALOS/PALSAR-2 and Sentinel-1 data sets. PF = primary forest; SV = secondary vegetation; CP = clean pasture; SP = shrubby pasture; BS = bare soil. See details of the experiments in Table 1.

Experiment	User's Accuracy (%)					Producer's Accuracy (%)					OA %	Kappa
	PF	SV	CP	SP	BS	PF	SV	CP	SP	BS		
A1	67.52	59.87	75.52	52.99	40.00	81.00	44.29	86.55	32.05	8.60	67.75	0.54
A2	70.79	72.44	74.72	63.70	75.00	90.50	43.59	94.59	20.99	3.23	72.16	0.60
A3	74.58	73.43	80.74	74.68	60.00	91.58	53.53	92.53	39.95	9.68	76.29	0.66
A4	77.50	77.87	84.60	76.31	70.59	91.94	58.69	93.77	55.98	12.90	79.62	0.71
A5	82.60	84.52	86.63	82.64	91.67	95.15	68.32	95.16	67.72	11.83	84.20	0.78
S1	59.11	62.18	65.74	57.69	28.57	72.28	53.33	72.52	27.03	8.00	61.35	0.45
S2	57.45	66.22	58.36	72.41	80.00	72.28	43.56	75.95	18.92	32.00	59.74	0.42
S3	64.62	80.72	67.35	75.56	71.43	82.88	59.56	75.57	30.63	40.00	68.72	0.55
S4	66.60	78.28	79.07	73.58	91.67	85.05	68.89	77.86	35.14	44.00	72.86	0.61
S5	75.82	81.16	88.89	84.31	90.00	92.99	76.02	85.41	42.57	47.37	81.07	0.73

Table 4 shows the user's accuracy, producer's accuracy, OA, and Kappa coefficient for each experiment performed with the SVM algorithm. Again, the performance of the ALOS/PALSAR-2 data was higher than that from Sentinel-1 data in terms of the OA and Kappa coefficient. For the SV discrimination, the ALOS/PALSAR-2 presented a better performance in terms of user's accuracy (75.66%) and producer's accuracy (66.97%) than that from the Sentinel-1 data (user's accuracy and producer's accuracy of 60.80% and 53.06%, respectively). Figure 5 shows the overall accuracy (OA) and Kappa coefficient for each experiment performed with the RF algorithm and for the SVM algorithm, respectively.

Table 4. Overall accuracy (OA) and Kappa coefficient for the Support Vector Machine classification experiments involving ALOS/PALSAR-2 and Sentinel-1 data sets. PF = primary forest; SV = secondary vegetation; CP = clean pasture; SP = shrubby pasture; BS = bare soil. See details of the experiments in Table 1.

Experiment	User's Accuracy (%)					Producer's Accuracy (%)					OA %	Kappa
	PF	SV	CP	SP	BS	PF	SV	CP	SP	BS		
A1	47.40	65.33	53.24	0.00	0.00	74.18	21.78	69.08	2.26	0.00	50.76	0.27
A2	50.17	66.33	58.42	50.00	83.33	78.53	28.89	67.56	0.90	40.00	54.69	0.33
A3	55.41	70.59	66.42	69.57	84.62	82.07	42.67	69.47	14.41	44.00	61.25	0.44
A4	65.50	75.66	71.89	63.46	81.82	81.52	63.56	77.10	29.73	36.00	69.32	0.56
A5	70.32	72.20	86.33	65.57	100.00	83.02	66.97	85.41	39.60	57.89	75.23	0.65
S1	45.92	53.12	53.25	0.00	100.00	60.16	35.06	75.08	0.00	1.04	49.89	0.28
S2	48.82	56.80	54.79	0.00	57.14	66.45	38.82	71.52	0.00	12.50	52.31	0.32
S3	50.03	60.80	57.00	0.00	42.50	69.58	42.71	69.58	0.00	17.71	54.04	0.34
S4	52.47	57.66	60.02	0.00	38.89	72.03	46.47	70.09	0.00	14.58	55.73	0.37
S5	56.79	59.89	64.83	10.00	36.54	70.60	53.06	80.26	0.25	19.79	59.74	0.43

Figure 6 presents the ranking of importance of each feature in the classification process based on the RF algorithm performed, considering the A5 and S5 experiments, which showed the highest overall accuracy in the previous test. In both classifications, the GLCM correlation related to the cross-polarizations (HV and VH, respectively) contributed more to the RF classification.




Figure 6. Ranking showing the most important features for the RF classification for the A5 (a) and S5 (b) experiments.

Figure 7 illustrates the result of the best accuracies found with the ALOS/PALSAR-2 (Experiment A5, RF) and Sentinel-1 (Experiment S5, RF) data. We note a predominance of PF in the western part of the study area and the CP in the rest of the study area. The SV and SP occupy less than 25% of the study area (Figure 8) and are distributed throughout the study area in relatively small areas. The small extension of BS occurs in the western part of the study area.




Figure 7. Best classification results obtained by the Random Forest classifier considering the ALOS/PALSAR-2 (a) and Sentinel-1 (c) data sets. (b,d) correspond to the ALOS/PALSAR-2 and Sentinel-1 images acquired at HV and VV polarizations, respectively, for illustration purposes.




Figure 8. Area (%) occupied by each land use and land cover class considered in this study, estimated by the Random Forest algorithm based on the ALOS-2 and Sentinel-1 images. PF = primary forest; CP = clean pasture; SV = secondary vegetation; SP = shrubby pasture; and BS = bare soil.

4. Discussion

Overall, the backscattering coefficients obtained in this study are in agreement with previous values reported by other studies conducted in different sites of the Brazilian Amazon: -7.53 dB and -12.59 dB for primary forest and ALOS-2 L-HH and L-HV images, respectively [71]; -7.53 dB and -12.45 dB for secondary forest and ALOS-2 L-HH and L-HV images, respectively [72]; -14.81 dB and -22 dB for cultivated pastures and ALOS-2 L-HH and L-HV images, respectively [71]. The lower values of the backscattering coefficients for bare soils and clean pastures are related to the lack or low levels of biomass. None of the SAR configurations showed a clear possibility of discriminating the SV from other LULC classes based solely on SAR amplitude (backscattering coefficients) data. This indicates the need of additional data such as the use of textural information for classifying SV.

The experiments with the ALOS/PALSAR-2 image presented a better performance than those involving Sentinel-1 data, reaching a maximum performance (OA of 84.2%; Kappa coefficient of 0.78) when texture attributes with 11×11 window size were added to the radiometric information (backscattering coefficient). These findings agree with the results found by Li et al. [73] who analyzed radiometric images and their textures obtained by the L-band ALOS/PALSAR-1 and C-band RADARSAT (C-band SAR) satellites for LULC classification in Altamira, Pará, Brazil. They concluded that the L-band data provided better LULC classification than the C-band data, regardless of the classification algorithm. Mercier et al. [74] and Nicolau et al. [75] also found significant confusion in discriminating secondary vegetation and forest based on Sentinel-1 data sets acquired over the study areas located in the municipality of Paragominas, Pará State, Brazil, and Madre de Dios region, Peru, respectively.

In this study, we noted that the largest window size presented the best classification results. According to Zhou et al. [76], textural attributes derived from the GLCM method are highly sensitive to the moving window size and the best criterion to set the value of the moving window size is still not fully understood. Coburn and Roberts [77] reported that large window sizes are more suitable when landscape is heterogeneous, and vice-versa. This last statement may explain our best results for the largest window size.

The use of SAR textural attributes improved the discrimination capability of different LULC classes found in the study area. Zhu et al. [78] reported an improvement from 31% to 72% in classification accuracy when texture metrics were added to the ALOS/PALSAR data in an urban and peri-urban environment (Boston, Massachusetts, USA). In the study conducted by Pavanelli et al. [79], the addition of these metrics to the ALOS/PALSAR-2

data sets increased the classification from 30.0% to 44.6%. According to these authors, this relatively low accuracy was due to the much higher number of classes selected for classification (17) than in the other studies. Here, it is important to note that textural images do not assure improvements in all LULC classes because it varies with the landscape characteristics and image acquisition modes [73]. Another important aspect pointed out by these authors is the selection of a suitable size of the moving window. As the sizes of LULC patches vary greatly, typically less than 1 ha for bare soil to hundreds of hectares of pastures and PF in our study area, no window size will be perfect to discriminate all LULC classes at once.

In this study, the RF outperformed the SVM classifier to discriminate the five LULC classes by 14% of overall accuracy for both ALOS-2 and Sentinel-1 data sets, considering the five experiments. The performance of discriminating SV was also higher for the RF algorithm: 3.6% and 16% higher in terms of OA for ALOS-2 and Sentinel-1 data sets, respectively. Previous studies highlight the low sensitivity to feature selection, simple parameterization, and short calculation time as being the main advantages of the RF classifier method [64,74,80].

One of the most difficult aspects of this study was the gathering of reliable ground truth data for training and validation of two selected non-parametric, machine learning algorithms. The field campaign was very complicated to be conducted due to the poor road accessibility during the rainy season. Besides, there was no forest inventory available in the study area. We tried to use the best ancillary data, available from the TerraClass project, however, there was a four-year delay between the last LULC map produced by this project (2014) and the satellite overpasses (2018). This may contribute to reducing the accuracy of our final classifications.

5. Conclusions

This study evaluated the potential of C- and L-band SAR data acquired in the rainy season to discriminate SV in a region considered to be the new hotspot of clear-cut deforestation in the Brazilian Amazon. The approach used in this research brings some important contributions to the development of a SAR-based system to monitor the near-real time re-suppression of SV in the Brazilian Amazon. First, we demonstrated the better potential of L-band ALOS/PALSAR-2 data in comparison with the C-band Sentinel-1 data for discriminating different LULC representative classes of the Brazilian Amazon. Second, the ability of the RF classifier to discriminate SV was higher when compared to the SVM classifier. Third, the use of both amplitude and texture attributes is highly recommended to improve the accuracy of the classification. Further research is needed to test the performances of other classification methods such as the U-NET that is based on semantic segmentation, the deep learning-based Convolutional Support Vector Machine (CSVM) or the Convolutional Neural Network-Multilayer Perceptron (CNN-MLP) data augmentation technique. Future research is also demanded to test the different polarimetric decompositions and interferometric techniques to discriminate between areas of secondary vegetation.

Author Contributions: B.H.K. was responsible for writing the article and conducting the study. E.E.S. supervised the work and contributed to the writing process. All authors have read and agreed to the published version of the manuscript.

Funding: B.H.K. was supported by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES, Process # 88887.500593/2020-00) and the Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq, Process # 380070/2020-0).

Data Availability Statement: Not applicable.

Acknowledgments: The authors acknowledge the Japan Aerospace Exploration Agency (JAXA), under the 6th Research Announcement (RA-6) for the Advanced Land Observing Satellite-2 (ALOS-2), which provided ALOS/PALSAR-2 data for this study and the Centro Gestor e Operacional do Sistema de Proteção da Amazônia (Censipam), under the Ministry of Defense, Brazil for the structure and support to develop this project. We also thank two anonymous reviewers for their valuable comments.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. INPE. TerraBrasilis. *PRODES (Deforestation)*. 2022. Available online: http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal_amazon/rates (accessed on 24 June 2022).
2. Sauer, S. Soy expansion into the agricultural frontiers of the Brazilian Amazon: The agribusiness economy and its social and environmental conflicts. *Land Use Policy* **2018**, *79*, 326–338. [CrossRef]
3. Miranda, J.; Börner, J.; Kalkuhl, M.; Soares-Filho, B. Land speculation and conservation policy leakage in Brazil. *Environ. Res. Lett.* **2019**, *14*, 045006. [CrossRef]
4. Arias, M.E.; Farinosi, F.; Lee, E.; Livino, A.; Briscoe, J.; Moorcroft, P.R. Impacts of climate change and deforestation on hydropower planning in the Brazilian Amazon. *Nat. Sustain.* **2020**, *3*, 430–436. [CrossRef]
5. Skidmore, M.E.; Moffette, F.; Rausch, L.; Christie, M.; Munger, J.; Gibbs, H.K. Cattle ranchers and deforestation in the Brazilian Amazon: Production, location, and policies. *Global Environ. Chang.* **2021**, *68*, 102280. [CrossRef]
6. Pereira, E.J.A.L.; Ferreira, P.J.S.; Ribeiro, L.C.S.; Carvalho, T.S.; Pereira, H.B.B. Policy in Brazil (2016–2019) threaten conservation of the Amazon rainforest. *Environ. Sci. Policy* **2019**, *100*, 8–12. [CrossRef]
7. Trancoso, R. Changing Amazon deforestation patterns: Urgent need to restore command and control policies and market interventions. *Environ. Res. Lett.* **2021**, *16*, 041004. [CrossRef]
8. Corlett, R.T. What is secondary forest? *J. Trop. Ecol.* **1994**, *10*, 445–447. [CrossRef]
9. CDB. Definitions: Indicative Definitions Taken from the Report of the Ad Hoc Technical Expert Group on Forest Biological Diversity. 2006. Available online: <https://www.cbd.int/forest/definitions.shtml> (accessed on 24 June 2022).
10. FAO. *Global Forest Resources Assessment 2020*; Main Report; FAO: Rome, Italy, 2020; 186p.
11. Almeida, C.A.; Coutinho, A.C.; Esquerdo, J.C.D.M.; Adami, M.; Venturieri, A.; Diniz, C.G.; Dessay, N.; Durieux, L.; Gomes, A.R. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. *Acta Amazon.* **2016**, *46*, 291–302. [CrossRef]
12. INPE. TerraClass. *Projetos e Pesquisas*. 2019a. Available online: http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php (accessed on 24 June 2022).
13. Chazdon, R.L.; Broadbent, E.N.; Rozendaal, D.M.; Bongers, F.; Zambrano, A.M.A.; Aide, T.M.; Balvanera, P.; Becknell, J.M.; Boukili, V.; Bracalioni, P.H.S.; et al. Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. *Sci. Adv.* **2016**, *2*, e1501639. [CrossRef]
14. Bongers, F.; Chazdon, R.; Poorter, L.; Peña-Claros, M. The potential of secondary forests. *Science* **2015**, *348*, 642–643. [CrossRef]
15. Strassburg, B.B.N.; Latawiec, A.E.; Barioni, L.G.; Nobre, C.A.; Silva, V.P.; Valentim, J.F.; Vianna, M.; Assa, E.D. When enough should be enough: Improving the use of current agricultural lands could meet production demands and spare natural habitats in Brazil. *Glob. Environ. Change* **2014**, *28*, 84–97. [CrossRef]
16. Klemick, H. Shifting cultivation, forest fallow, and externalities in ecosystem services: Evidence from the Eastern Amazon. *J. Environ. Econ. Manag.* **2011**, *61*, 95–106. [CrossRef]
17. Nunes, S.; Oliveira, L., Jr.; Siqueira, J.; Morton, D.C.; Souza, C.M., Jr. Unmasking secondary vegetation dynamics in the Brazilian Amazon. *Environ. Res. Lett.* **2020**, *15*, 034057. [CrossRef]
18. Soares-Filho, B.; Rajão, R.; Macedo, M.; Carneiro, A.; Costa, W.; Coe, M.; Rodrigues, H.; Alencar, A. Cracking Brazil’s forest code. *Science* **2014**, *344*, 363–364. [CrossRef]
19. Diniz, C.G.; Souza, A.A.A.; Santos, D.C.; Dias, M.C.; Luz, N.C.; Moraes, R.V.; Maia, J.S.; Gomes, A.R.; Narvaes, I.S.; Valeriano, D.M.; et al. DETER-B: The new Amazon near real-time deforestation detection system. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2015**, *8*, 3619–3628. [CrossRef]
20. IMAZON. Sistema De Alerta De Desmatamento (Sad)—Maio De 2022. Available online: <https://imazon.org.br/publicacoes/sistema-de-alerta-de-desmatamento-sad-maio-de-2022/> (accessed on 24 June 2022).
21. Souza, C.M., Jr.; Shimbo, J.Z.; Rosa, M.R.; Parente, L.L.; Alencar, A.A.; Ruddorff, B.F.T.; Hasenack, H.; Matsumoto, M.; Ferreira, L.G.; Souza-Filho, P.W.M.; et al. Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. *Remote Sens.* **2020**, *12*, 2735. [CrossRef]
22. Lucas, R.M.; Xiao, X.; Hagen, S.; Froking, S. Evaluating TERRA-1 MODIS data for discrimination of tropical secondary forest regeneration stages in the Brazilian Legal Amazon. *Geophys. Res. Lett.* **2002**, *29*, 1–4. [CrossRef]
23. Asner, G.P.; Rudel, T.K.; Aide, T.M.; Defries, R.; Emerson, R. A Contemporary assessment of change in humid tropical forests. *Conserv. Biol.* **2009**, *23*, 1386–1395. [CrossRef]

24. Wang, J.; Yang, D.; Detto, M.; Nelson, B.W.; Chen, M.; Guan, K.; Wu, S.; Yan, Z.; Wu, J. Multi-scale integration of satellite remote sensing improves characterization of dry-season green-up in an Amazon tropical evergreen forest. *Remote Sens. Environ.* **2020**, *246*, 111865. [CrossRef]
25. Vieira, I.C.G.; Gardner, T.; Ferreira, J.; Lees, A.C.; Barlow, J. Challenges of governing second-growth forests: A case study from the Brazilian Amazonian State of Pará. *Forests* **2014**, *5*, 1737–1752. [CrossRef]
26. Shimada, M.; Isoguchi, O.; Tadono, T.; Isono, K. PALSAR radiometric and geometric calibration. *IEEE Trans. Geosci. Remote Sens.* **2009**, *47*, 3915–3932. [CrossRef]
27. Watanabe, M.; Koyama, C.; Hayashi, M.; Nagatani, I.; Shimada, M. Early-stage deforestation detection in the tropics with L-band SAR. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2018**, *11*, 1–7. [CrossRef]
28. Watanabe, M.; Koyama, C.; Hayashi, M.; Nagatani, I.; Tadono, T.; Shimada, M. Refined algorithm for forest early warning system with ALOS-2/PALSAR-2 ScanSAR data in tropical forest regions. *Remote Sens. Environ.* **2021**, *265*, 112643. [CrossRef]
29. Cassol, H.L.G.; Aragão, L.E.O.C.; Moraes, E.C.; Carriras, J.M.B.; Shimabukuro, Y.E. Quad-pol advanced land observing satellite/phased array L-band synthetic aperture radar-2 (ALOS/PALSAR-2) data for modeling secondary forest above-ground biomass in the central Brazilian Amazon. *Int. J. Remote Sens.* **2021**, *42*, 4985–5009. [CrossRef]
30. Leckie, D.G.; Ranson, K.J. Forestry applications using imaging SAR. In *Principles and Application of Imaging Radar. Manual of Remote Sensing*, 3rd ed.; Henderson, F.M., Lewis, A.J., Eds.; John Wiley & Sons: Hoboken, NJ, USA, 1998.
31. Torres, R.; Snoei, P.; Geudtner, D.; Bibby, D.; Davidson, M.; Attema, E.; Potin, P.; Rommen, B.; Floury, N.; Brown, M.; et al. GMES Sentinel-1 mission. *Remote Sens. Environ.* **2012**, *120*, 9–24. [CrossRef]
32. Doblas, J.; Shimabukuro, Y.; Sant’Anna, S.; Carneiro, A.; Aragão, L.; Almeida, C. Optimizing near real-time detection of deforestation on tropical rainforests using Sentinel-1 data. *Remote Sens.* **2020**, *12*, 3922. [CrossRef]
33. Hoekmann, D.; Kooij, B.; Quiñones, M.; Vellekoop, S.; Carolita, I.; Budhiman, S.; Arief, R.; Roswintarti, O. Wide-area near-real-time monitoring of tropical forest degradation and deforestation using Sentinel-1. *Remote Sens.* **2020**, *12*, 3263. [CrossRef]
34. Silva, C.A.; Guerrisi, G.; Del Frate, F.; Sano, E.E. Near-real time deforestation detection in the Brazilian Amazon with Sentinel-1 and neural networks. *Eur. J. Remote Sens.* **2022**, *55*, 129–149. [CrossRef]
35. Kuplich, T.M. Classifying regenerating forest stages in Amazônia using remotely sensed images and a neural network. *For. Ecol. Manage.* **2006**, *234*, 1–9. [CrossRef]
36. Carreiras, J.M.B.; Jones, J.; Lucas, R.M.; Shimabukuro, Y.E. 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. *Rem. Sens. Environ.* **2017**, *194*, 16–32. [CrossRef]
37. Doblas, J.; Reis, M.S.; Belluzzo, A.P.; Quadros, C.B.; Moraes, D.R.V.; Almeida, C.A.; Maurano, L.E.P.; Carvalho, A.F.A.; Sant’Anna, S.J.S.; Shimabukuro, Y.E. DETER-R: An operational near-real time tropical forest disturbance warning system based on Sentinel-1 time series analysis. *Remote Sens.* **2022**, *14*, 3658. [CrossRef]
38. Assunção, J.J.; Gandour, C. What Does the Surge in Amazon Regeneration Mean for Brazil? Climate Policy Initiative: Rio de Janeiro, Brazil, 2017. Available online: <https://climatepolicyinitiative.org/publication/surge-amazon-regeneration-mean-brazil/> (accessed on 22 August 2018).
39. Aoki, Y.; Furuya, M.; Zan, F.; Doin, M.P.; Eineder, M.; Ohki, M.; Wright, T.J. L-band synthetic aperture radar: Current and future applications to Earth sciences. *Earth Planets Space* **2021**, *73*, 56. [CrossRef]
40. IBGE. *Manual Técnico da Vegetação Brasileira. Manuais Técnicos em Geociências*, n. 1; IBGE: Rio de Janeiro, Brazil, 2012; 274p.
41. Santos, M.V. Zoneamento sócio-econômico-ecológico: Diagnóstico sócio-econômico-ecológico do Estado de Mato Grosso e assistência técnica na formulação da 2ª aproximação; SEPLAN-MT: Cuiabá, MT, Brazil, 2000.
42. MapBiomas. MapBiomas v. 6.0. Available online: <https://mapbiomas.org/en/statistics> (accessed on 25 June 2022).
43. Halbgewachs, M.; Wegmann, M.; Ponte, E. A spectral mixture analysis and landscape metrics based framework for monitoring spatiotemporal forest cover changes: A case study in Mato Grosso, Brazil. *Remote Sens.* **2022**, *14*, 1907. [CrossRef]
44. Drusch, M.; Bello, U.D.; Carlier, S.; Colin, O.; Fernandez, V.; Gascon, F.; Hoersch, B.; Isola, C.; Laberinti, P.; Martimort, P.; et al. Sentinel-2: ESA’s optical high-resolution mission for GMES operational services. *Remote Sens. Environ.* **2012**, *120*, 25–36. [CrossRef]
45. INPE. CBERS 04A. 2019. Available online: http://www.cbers.inpe.br/sobre/cbers04a.php?_ga=2.99883486.151721476.1656282945-118845307.1656282944 (accessed on 26 June 2022).
46. JAXA. Calibration Results of ALOS-2/PALSAR-2 JAXA Standard Products. Available online: https://www.eorc.jaxa.jp/ALOS-2/en/calval/calval_index.htm (accessed on 8 February 2022).
47. Small, D. Flattening Gamma: Radiometric terrain correction for SAR imagery. *IEEE Trans. Geosci. Remote Sens.* **2011**, *49*, 3081–3093. [CrossRef]
48. Hagensieker, R.; Waske, B. Evaluation of multi-frequency SAR images for tropical land cover mapping. *Remote Sens.* **2018**, *10*, 257. [CrossRef]
49. Haralick, R.M.; Shanmugam, K.; Dinstein, I.H. Textural features for image classification. *IEEE Trans. Syst. Man Cybern. Syst.* **1973**, *3*, 610–621. [CrossRef]
50. Kurvonen, L.; Hallikainen, M.T. Textural information of multitemporal ERS-1 and JERS-1 SAR images with applications to land and forest type classification in boreal zone. *IEEE Trans. Geosci. Remote Sens.* **1999**, *37*, 680–689. [CrossRef]

51. Baraldi, A.; Parmiggiani, F. A refined gamma MAP SAR speckle filter with improved geometrical adaptivity. *IEEE Trans. Geosci. Remote Sens.* **1995**, *33*, 1245–1257. [\[CrossRef\]](#)
52. Lu, D.; Batistella, M. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. *Acta Amaz.* **2005**, *35*, 249–257. [\[CrossRef\]](#)
53. Sothe, C.; Almeida, C.M.; Liesenberg, V.; Schimalski, M.B. Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in southern Brazil. *Remote Sens.* **2017**, *9*, 838. [\[CrossRef\]](#)
54. Zakeri, H.; Yamazaki, F.; Liu, W. Texture analysis and land cover classification of Tehran using polarimetric synthetic aperture radar imagery. *Appl. Sci.* **2017**, *7*, 452. [\[CrossRef\]](#)
55. Azevedo, A.R.D.; Santos, J.R.D.; Gama, F.F.; Graça, P.M.L.D.A.; Mura, J.C. Caracterização de uso e cobertura da terra na Amazônia utilizando imagens duais multitemporais do COSMO-SkyMed. *Acta Amaz.* **2014**, *44*, 87–97. [\[CrossRef\]](#)
56. Jolliffe, I.T. *Principal Component Analysis*; Springer: New York, NY, USA, 2002.
57. Wiederkehr, N.C.; Gama, F.F.; Castro, P.B.; Bispo, P.D.C.; Balzter, H.; Sano, E.E.; Mura, J.C. Discriminating Forest successional stages, forest degradation, and land use in central amazon using ALOS/PALSAR-2 full-polarimetric data. *Remote Sens.* **2020**, *12*, 3512. [\[CrossRef\]](#)
58. Soares, J.V.; Rennó, C.D.; Formaggio, A.R.; Yanasse, C.C.F.; Frery, A.C. An investigation of the selection of texture features for crop discrimination using SAR imagery. *Remote Sens. Environ.* **1997**, *59*, 234–247. [\[CrossRef\]](#)
59. Stehman, S.V. Impact of sample size allocation when using stratified random sampling to estimate accuracy and area of land-cover change. *Remote Sens. Lett.* **2012**, *3*, 111–120. [\[CrossRef\]](#)
60. Olofsson, P.; Foody, G.M.; Herold, M.; Stehman, S.V.; Woodcock, C.E.; Wulder, M.A. Good practices for estimating area and assessing accuracy of land change. *Remote Sens. Environ.* **2014**, *148*, 42–57. [\[CrossRef\]](#)
61. Van der Linden, S.; Rabe, A.; Held, M.; Jakimow, B.; Leitão, P.J.; Okujeni, A.; Schwieder, S.S.; Hostert, P. The EnMAP-Box—A toolbox and application programming interface for EnMAP data processing. *Remote Sens.* **2015**, *7*, 11249–11266. [\[CrossRef\]](#)
62. Diniz, J.M.F.S.; Gama, F.F.; Adami, M. Evaluation of polarimetry and interferometry of Sentinel-1A SAR data for land use and land cover of the Brazilian Amazon region. *Geocarto Int.* **2022**, *37*, 1482–1500. [\[CrossRef\]](#)
63. Breiman, L. Random Forests. *Mach. Learn.* **2001**, *45*, 5–32. [\[CrossRef\]](#)
64. Belgiu, M.; Drăguț, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* **2016**, *114*, 24–31. [\[CrossRef\]](#)
65. Sheykhou, M.; Mahdianpari, M.; Ghanbari, H.; Mohammadimanesh, F.; Ghamisi, P.; Homayouni, S. Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2020**, *13*, 6308–6325. [\[CrossRef\]](#)
66. Petropoulos, G.P.; Kontoes, C.; Keramitsoglou, I. Burnt area delineation from a uni-temporal perspective based on Landsat TM imagery classification using Support Vector Machines. *Int. J. Appl. Earth Obs. Geoinf.* **2011**, *13*, 70–80. [\[CrossRef\]](#)
67. Karatzoglou, A.; Meyer, D.; Hornik, K. Support vector machines in R. *J. Stat. Softw.* **2006**, *15*, 1–28. [\[CrossRef\]](#)
68. Huang, C.; Davis, L.S.; Townshend, J.R.G. An assessment of support vector machines for land cover classification. *Int. J. Remote Sens.* **2002**, *23*, 725–749. [\[CrossRef\]](#)
69. Van der Linden, S.; Rabe, A.; Held, M.; Wirth, F.; Suess, S.; Okujeni, A.; Hostert, P. *Image SVM Classification. Manual for Application: Image SVM Version 3.0*; Humboldt-Universität: Berlin, Germany, 2014.
70. Lewis, A.J.; Henderson, F.M. Radar fundamentals: The geosciences perspective. In *Principles and Applications of Imaging Radar. Manual of Remote Sensing*, 3rd ed.; Henderson, F.M., Lewis, A.J., Eds.; John Wiley & Sons: Hoboken, NJ, USA, 1998; pp. 131–181.
71. Silva, V.S.; Sano, E.E.; Almeida, T.; Mesquita Júnior, H.N. Discriminating vegetation cover classes of an Amazon/Cerrado transition region in the Mato Grosso State using ALOS-2/PALSAR-2 satellite images. *Rev. Bras. Cartogr.* **2021**, *73*, 1–16. [\[CrossRef\]](#)
72. Aboud Neta, S.R. Uso De Imagens ALOS/PALSAR Multipolarizadas Para Detecção De Incremento De Desflorestamento Na Amazônia. M.Sc. thesis, National Institute for Space Research, São José, dos Campos, SP, Brazil, 30 September 2009.
73. Li, G.; Lu, D.; Moran, E.; Dutra, L.; Batistella, M. A comparative analysis of ALOS PALSAR L-band and RADARSAT-2 C-band data for land-cover classification in a tropical moist region. *ISPRS J. Photogramm. Remote Sens.* **2012**, *70*, 26–38. [\[CrossRef\]](#)
74. Mercier, A.; Betbeder, J.; Rumiano, F.; Baudry, J.; Gond, V.; Blanc, L.; Bourgoign, C.; Cornu, G.; Ciudad, C.; Marchamalo, M.; et al. Evaluation of Sentinel-1 and 2 time series for land cover classification of forest-agriculture mosaics in temperate and tropical landscapes. *Remote Sens.* **2019**, *11*, 979. [\[CrossRef\]](#)
75. Nicolau, A.P.; Flores-Anderson, A.; Griffin, R.; Herndon, K.; Meyer, F.J. Assessing SAR C-band data to effectively distinguish modified land uses in a heavily disturbed Amazon Forest. *Int. J. Appl. Earth Obs. Geoinf.* **2021**, *94*, 102214. [\[CrossRef\]](#)
76. Zhou, J.; Guo, R.Y.; Sun, M.; Di, T.T.; Wang, S.; Zhai, J.; Zhao, Z. The effects of GLCM parameters on LAI estimation using texture values from Quickbird satellite imagery. *Sci. Rep.* **2017**, *7*, 7366. [\[CrossRef\]](#)
77. Coburn, C.A.; Roberts, A.C.B. A multiscale texture analysis procedure for improved forest stand classification. *Int. J. Remote Sens.* **2004**, *25*, 4287–4308. [\[CrossRef\]](#)
78. Zhu, Z.; Woodcock, C.E.; Rogan, J.; Kelldorfer, J. Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using Landsat and SAR data. *Remote Sens. Environ.* **2012**, *117*, 72–82. [\[CrossRef\]](#)

-
79. Pavanelli, J.A.P.; Santos, J.R.; Galvão, L.S.; Xaud, M.R.; Xaud, H.A.M. PALSAR-2/ ALOS-2 and OLI/Landsat-8 data integration for land use and land cover mapping in northern Brazilian Amazon. *Bull. Geod. Sci.* **2018**, *24*, 250–269. [[CrossRef](#)]
 80. Pelletier, C.; Valero, S.; Inglada, J.; Champion, N.; Marais Sicre, C.; Dedieu, G. Effect of training class label noise on classification performances for land cover mapping with satellite image time series. *Remote Sens.* **2017**, *9*, 173. [[CrossRef](#)]

5 ARTIGO 3

COMBINING ALOS-2/PALSAR-2 FULL-POLARIMETRIC AND COSMO-SKYMED INTERFEROMETRIC COHERENCE DATA TO DISCRIMINATE SECONDARY VEGETATION AND LAND USE CLASSES IN A REGION OF DEFORESTATION HOTSPOT IN THE BRAZILIAN AMAZON

Abstract: This work aimed to evaluate the potential of ALOS-2/PALSAR-2 full-polarimetric images processed by decomposition techniques and polarimetric indexes to discriminate land use and land cover (LULC) classes in an area of deforestation hotspot in the Brazilian Legal Amazon. Interferometric coherence data from COSMO-SkyMed data were also added in the analysis to increase classification accuracy. These polarimetric data were classified using the Random Forest (RF) and Support Vector Machine (SVM) algorithms. The validation of accuracy was performed using the overall accuracy, Kappa index, and confusion matrix. The results showed good potential of interferometric coherence combined with the Yamaguchi decomposition for discriminating representative LULC classes of the study area, presenting a Kappa index of 0.81 and an overall accuracy of 87.8% for the RF algorithm. Even considering the small increment brought by the coherence in the classification performance, this interferometric attribute derived from the COSMO-SkyMed satellite proved to be important, especially in the discrimination of different stages of secondary vegetation (SV). The results of this study can assist the future development of a full-polarimetric SAR system to monitor the re-suppression of SV in the Brazilian Amazon.

Keywords: Synthetic aperture radar; secondary vegetation; Random Forest; Support Vector Machine.

5.1 INTRODUCTION

The Brazilian Legal Amazonia occupies an area of more than 5 million km² (~60%) of the Brazilian territory ([IBGE, 2022](#)). This region presents high levels of deforestation and degradation due to clear-cut, selective logging, and burning activities ([Moran, 1993](#); [Garret et al., 2021](#)). Some of the deforested areas are abandoned, entering in the process of natural regrowth ([Kiyohara and Sano, 2022](#)). There was an increase of 72.000 km² of secondary vegetation (SV) in the Brazilian Amazon between 2004 and 2014 ([TerraClass, 2022](#)). INPE (2022) estimated that 22% of deforested area in this region is in process of natural regeneration. Monitoring forest regeneration after the disturbance is important, for example, for evaluating the magnitude of reduction of environmental impacts on the ecosystem ([Uhl et al., 1988](#); [Kuplich, 2006](#); [Carvalho et al., 2019](#)). Regenerating forests increase carbon sequestration of

atmospheric CO₂ ([Bongers et al., 2015](#); [Chazdon et al., 2016](#); [Nunes et al., 2020](#); [Heinrich et al., 2021](#)). Secondary vegetation, compared to clear-cut areas, improves soil fertility, increases landscape biodiversity, and reduces surface runoff and the impacts of forest fragmentation on the natural habitat ([Feldspausch et al., 2004](#); [Nunes et al., 2020](#); [Heinrich et al., 2021](#)).

Previous studies have used optical remote sensing data for assessing secondary vegetation succession in the Brazilian Amazon ([Nelson et al., 2000](#); [Vieira et al., 2003](#); [Ponzoni and Rezende, 2004](#); [Sothe et al., 2017](#)), though frequent cloud cover in this region makes difficult to obtain images based on these sensors ([Asner, 2001](#)). An alternative is the use of synthetic aperture radar (SAR) data. The use of SAR data in tropical forests includes different frequencies, polarizations, and processing techniques ([Hagensieker and Waske, 2018](#)). One of the most commonly used techniques is the polarimetric decomposition. This technique facilitates the interpretation of polarimetric SAR images in the classification process, as it separates scattering mechanisms in covariance and coherence matrices ([Lee and Pottier, 2009](#); [Pôssa et al., 2018](#); [Wiederkehr et al., 2020](#)). Another technique is the interferometry, which is based on the combination of two SAR images acquired over the same area with slightly different geometry of acquisition to ensure differences in phase ([Temporim et al., 2017](#)). It is possible to maximize interferometric coherence by combining interferometry and polarimetry processes, which corresponds to the measure of the correlation between the two images used in the interferometric processing. This product can contribute to the thematic stratification of the landscape, considering that forested regions have low interferometric coherence due to the instability of forest components when compared to other land use and land cover (LULC) classes such as pasture, bare soils, and sparse vegetation ([Wegmüller et al., 2015](#); [Olesk et al., 2016](#); [Mohammadimanesh et al., 2018](#)).

Several studies have used SAR data to discriminate SV in the Brazilian Amazon. For example, [Wiederkehr et al. \(2020\)](#) used ALOS/PALSAR-2 polarimetric images classified by the Random Forest (RF) and Support Vector Machine (SVM) algorithms to discriminate different forest successional stages, forest degradation, and land use in the Tapajós National Forest, Pará State. The RF classification presented superior performance in relation to the SVM algorithm. Indeed, the choice of a suitable classification method is fundamental for the success of LULC maps ([Lu et al., 2007](#); [Sothe et al., 2017](#); [Than Noi and Kappas, 2017](#)). Non-parametric techniques known as machine learning that include RF and SVM classifiers are among the most used methods due to their promising performance in image classification

(Breiman, 2001). These algorithms have great capacity for synthesizing data functions based on discrete or continuous data (Sothe et al., 2017). These ML methods are robust, can accept several input variables, and are relatively insensitive to noise (Paneque-Galvez et al., 2013; Furtado et al., 2016; Yu et al., 2017).

The objective of this research is to discriminate secondary vegetation and land uses classes in a region of deforestation hotspot in the Brazilian Amazon by combining L-band, polarimetric ALOS-2/PALSAR-2 data, X-band and interferometric coherence data acquired by the COSMO-SkyMed satellite. The RF and SVM algorithms were applied to these data. We expect the results to support the understanding of the different SAR frequencies and techniques applied in forest tropical mapping, contributing to recommendations for future applications.

5.2 MATERIAL AND METHODS

5.2.1 Study area

The study area comprises an area of approximately 600 km² in the eastern portion of the municipality of Colniza, located in northwestern of Mato Grosso State (Figure 5.1). It comprises a region with large areas of deforestation that were abandoned after deforestation and is currently undergoing a natural regeneration process (Halbgewachs et al., 2022). The vegetation consists of typical dense rainfall forest found in the Brazilian Amazon (IBGE, 2012). The climate, according to the Köppen's climate classification system, is Am, that is, tropical (hot and humid), with short dry season. The rainy season corresponds to the months of October to May, where the annual rainfall varies from 2100 mm to 2500 mm (Santos, 2000).




Figure 5.1. Location of the study area in the Brazilian Legal Amazon (A) and in the municipality of Colniza, Mato Grosso State (B). The RGB color composite (C) corresponds to the ALOS/PALSAR-2 data (R: HH/HV; G: HH/VV; and B: VV/VH).

5.2.2 SAR Pre-processing

We selected full-polarimetric ALOS-2/PALSAR-2 satellite images from 16 May 2016, acquired in StripMap mode by the Japan Aerospace Exploration Agency (JAXA). The images are made available in Single Look Complex (SLC) processing level (Table 5.1).

Table 5.1. Characteristics of the ALOS-2/PALSAR-2 images selected for this study.

Parameters	Characteristics
Acquisition mode	StripMap
Orbit	Ascendent
Pixel size	6.25 m
Overpass	16 May 2016
Polarization	HH, HV, VV, and VH
Incidence angle	25.5°

We also selected two scenes acquired by the COSMO-SkyMed (CSK) satellite (Telespazio, 2022). CSK is a constellation of four medium-size satellites that operate with X-

band SAR sensor. The scenes were acquired in StripMap mode, HIMAGE submode, and SLC processing level (Table 5.2).

Table 5.2. Characteristics of the COSMO-SkyMed images selected for this study.

Parameters	Characteristics
Acquisition mode	StripMap/HIMAGE
Orbit	Descendent
Pixel size	3 m
Overpasses	11 May 2016 and 3 June 2016
Polarization	HH
Incidence angle	40.0°

The optical data used in this research was acquired by the Sentinel-2 Multispectral Instrument (MSI) sensor, which is operated by the European Space Agency (ESA). The cloud-free Sentinel-2 image was acquired on 27 July 2016, downloaded from the United States Geological Survey (USGS) website (earth explorer platform).

5.2.3 Methods

Figure 5.2 shows the main steps of the methodological approach considered in this study. The ground truth data were obtained from the data provided by the TerraClass project, coordinated by the National Institute for Space Research (INPE, 2019) and the Brazilian Agricultural Research Corporation (Embrapa Agricultura Digital and Embrapa Amazônia Oriental) (Almeida et al., 2016) and MapBiomass (Brazilian Annual Land Use and Land Cover Mapping Project) (Neves et al., 2020; MapBiomass, 2022) with the support of visual interpretation of the Sentinel-2 image and high spatial resolution images available in the Google Earth platform.




Figure 5.2. Flowchart showing the main steps of the methodological approach considered in this study.

5.2.3.1 Pre-processing

The radiometric calibration of each full-polarimetric ALOS-2 intensity images was carried out to obtain the backscattering coefficients (σ^0) in the ground range (Eq. 5.1):

$$\sigma^0 = 10 \log_{10}(I^2 + Q^2) + CF_1 - A \quad (5.1)$$

where:

I and Q = real and imaginary parts of the complex images;

C = radiometric calibration factor (-83 dB); and

A = conversion factor (32 dB) (JAXA, 2022).

The multilooking process was applied to the ALOS-2 and the CSK images to improve the spatial resolution of the images (Goldstein et al., 1988). The images were also filtered with the GammaMap filter to reduce speckle noise (Kiyohara and Sano, 2022; Hagensieker and Waske, 2018) using a 5×5 window size. The geometric correction was performed through geocoding, using the digital elevation model produced by the Shuttle Radar Topography Mission (SRTM) and made available at the 30 m spatial resolution.

The interferometry coherence (γ) of two complex SAR images is defined according to Eq. 5.2:

$$\gamma = \frac{E\{uv^*\}}{\sqrt{E\{|u|^2\}E\{|v|^2\}}}$$
 (5.2)

where:

E = expected value;

u and v = two co-registered complex images; and

v^* = complex conjugate of v (Wegmüller et al., 2015). The coherence range window size was set to 10 and the coherence azimuth window size was set to 1.

SAR interferometry technique requires pixel-to-pixel match between common features in the pairs of images. Thus, we added the co-registration step between the two SAR images for the accurate determination of phase difference and for noise reduction. All ALOS-2 and CSK pre-processing steps were performed in the ESA's Sentinel Application Platform (SNAP) 7.0 software.

5.2.3.2 Polarimetric decomposition processing

The polarimetric decompositions were generated from the filtered coherence [T] and covariance [C] matrices, using a 5×5 window size, resulting in four groups of attributes (Table 5.3).

Table 5.3. Characteristics of the attributes extracted from the ALOS/PALSAR-2 full-polarimetric data.

Attributes	Description	Citation
Entropy (H)	Indicates the number of active scattering mechanisms.	Cloude and Pottier (1996)
Alpha angle (α)	Indicates the importance of secondary scattering mechanisms.	
Anisotropy (A)	Dominant scattering mechanism.	
Surface scattering	Modeled surface scattering using <i>bragg</i> scatterers, which occur on slightly rough/wavy surfaces.	Yamaguchi et al., (2005)
Double-bounce	Modeled double-bounce scattering using two orthogonal surfaces.	
Volumetric scattering	Modeled volumetric scattering using a cloud of cylindrical and thin scatterers with random distribution.	
Helix scattering	Modeled helix-type reflector, which generates left and right circular polarizations. Best suited for describing artificial targets.	
Surface scattering	Modeled surface scattering using <i>bragg</i> scatterers, which occur on slightly rough/wavy surfaces.	

Double-bounce	Modeled double-bounce scattering using two orthogonal surfaces.	Freeman and Durden (1998)
Volumetric scattering	Models volumetric scattering using a cloud of cylindrical and thin scatterers with random distribution.	
Surface scattering	Portion of surface scattering.	van Zyl (1989)
Double-bounce	Portion of double-bounce scattering.	
Volumetric scattering	Portion of volumetric scattering.	

In addition to the polarimetric decompositions, we extracted the backscatter-derived indices known as the backscatter coefficient (σ°) (van der Sanden, 1997). The attributes extracted from the backscattering coefficient present only the information of the real part (amplitude) of the complex scattering matrix (Table 5.4).

Table 5.4. Characteristics of the indices extracted from the ALOS/PALSAR-2 full-polarimetric data.

Indexes	Description	Equation	Citation
Radar Vegetation Index (RVI)	Sensitive index to the volume of biomass.	$RVI = \frac{8\sigma_{HV}^0}{\sigma_{HH}^0 + \sigma_{VV}^0 + 2\sigma_{HV}^0}$	Kim and Van Zyl (2009)
Canopy Structure Index (CSI)	Relative measure of the importance of vertical plant structures.	$CSI = \frac{\sigma_{VV}^0}{\sigma_{VV}^0 + \sigma_{HH}^0}$	
Volume Scattering Index (VSI)	Measure of the degree of depolarization of the backscattered signal, being used as an indicator of the density and thickness of canopies.	$VSI = \frac{\sigma_{HV}^0}{\sigma_{HV}^0 + BMI}$	Pope et al. (1994)
Biomass Index (BMI)	Indicator related to the amount and presence of woody material in relation to the leaf material of the vegetation cover.	$BMI = \frac{\sigma_{HH}^0 + \sigma_{VV}^0}{2}$	

5.2.3.3 RF and SVM classifications

In this study, the images were classified using the RF and SVM algorithms available in the EnMAP-Box software (van der Linden et al., 2015). RF algorithm uses decision tree to increase classification accuracy through many combinations of random subsets of tree. In this study, 500 trees were used in all classifications, based on results obtained by Sothe et al. (2017), Wiederkehr et al. (2020) and Kiyohara and Sano (2022) and on the best compromise between computational effort and model accuracy (Belgiu and Drăgu, 2016; Sheykhmousa et al., 2020).

The accuracy of the RF classification was evaluated based on a split of data consisting in 75% of training samples and 25% of validation samples, known as out-of-bag (OOB)

samples. The OOB samples are then directed to trees that have not been used by the classifier yet. The RF model is considered unbiased because, as the number of trees increases, the error tends to decrease to a certain threshold (Breiman, 2001). The importance of each variable in the classification process in normalized values, is calculated from the OOB samples (Kiyohara and Sano, 2022).

The SVM algorithm is a nonlinear classifier that is trained to find an optimal classification hyperplane and is optimized using a kernel function (Karatzoglou et al., 2006; Petropoulos et al., 2011). In this study, we selected the radial basis function, which has two predefined parameters, the cost (C) and the gamma (g). Both parameters depend on the data range and distribution and differ from one classification to the other. In order to find the optimum C and g parameters, a two-dimensional grid search with internal validation was performed within the EnMAP-Box software, for each classification (Huang et al., 2002; van der Linden et al., 2014).

5.2.3.4 Feature and samples selection

A set of samples were gathered based on the LULC classes mapped by the TerraClass Amazonia project (year: 2014) (TerraClass 2022) and the secondary vegetation stages data produced by the MapBiomass project (MapBiomass 2022) to perform the image classification. Seventy-five percent of the sampling points were used to train the image classifiers, while the remaining points were used to validate the results of the classification (Table 5.5). Although the legend of the TerraClass project is composed of 17 classes, in this study, only the following classes found in the study area were considered:

- Primary Forest (PFO): areas with no evidence of human activities;
- Secondary Vegetation (SV1, SV2, and SV3): clear-cut forests that are regrowing as a consequence of abandonment in stage 1 (initial, ~5 years); 2 (intermediate, ~5-15 years); and 3 (advanced, + 15 years);
- Clean Pasture (CPA): well-managed pastures for cattle beef production;
- Shrubby Pasture (SPA): poorly managed pastures with the presence of weeds, shrubs, and trees;
- Degradation forest (DEG): degraded forest;
- Water Bodies (WAT): Aripuanã river.

Table 5.5. Distribution of training and validation samples for each LULC class.

LULC class	Training samples (pixel)	Validation samples (pixel)
PFO	10.167	3.389
SV3	1.240	413
SV2	654	218
SV1	1.484	495
CPA	5.531	1.844
SPA	1.316	439
DEG	439	146
WAT	599	200

The number of samples for each LULC class was defined according to the size of each class (Congalton and Green, 1999) and based on visual analysis of the samples spatial distribution in study area (Figure 5.3). Images from the Sentinel-2 MSI satellite were used as reference. A true composite was performed with the 10-m resolution multispectral bands (R4G3B2). We also used high spatial resolution images from Google Earth platform to support the inspection of each sample in the Sentinel-2 image.




Figure 5.3. Set of samples based LULC classes. The RGB color composite corresponds to the Sentinel-2 MSI data (R: band 4; G: band 3; B: band 2) acquired on 27 July 2016.

5.2.3.5 Accuracy assessment

The classification results from the experiments were analyzed through the user's accuracy (UA), producer's accuracy (PA), overall accuracy (OA) and Kappa index, with a level of significance of 5%. For the best classification result, we calculated the ranking of predicted variables showing the most important features.

5.3 RESULTS

5.3.1 SAR Data Analysis

Figure 5.4 shows the average values and corresponding standard deviations of the backscattering coefficients of Alos-2 full-polarimetric data (L-HH, L-HV, L-VH, and L-VV) obtained from the calibration sites. Co-polarized signals (L-HH and L-VV) were higher than those from the cross-polarized signals (L-HV and C-VH) ([Kiyohara and Sano, 2022](#)).

In the case of co-polarized signal, most of the backscattering process is related to the stronger signal returns from the vegetation classes derived from trunks, branches, and leaves located in the upper part of the canopy. Thus, the cross polarizations HV and VH present better contrast with the vegetation classes, due to the random orientation of parts of the canopy and because the volumetric scattering acts by attenuating the SAR signal returned to the antenna ([Lewis and Henderson 1998](#)).




Figure 5.4. Backscattering coefficients of clean pasture (CPA), degradation forest (DEG), primary forest (PFO), shrubby pasture (SPA), initial secondary vegetation (SV1), intermediate secondary vegetation (SV2), advanced secondary vegetation (SV3) and water bodies (WAT), derived from L-HH (a), L-HV (b), L-VV (c), and L-VH (d) polarizations.

Figure 5.5 presents the boxplot with the interferometric coherence distribution from CSK data pattern for the different LULC classes in the study area. The coherence values for the PFO and SV3 classes were low compared to the other classes. This result was expected because one of the common sources of decorrelation in forests is the volumetric scattering. Thus, a decrease in coherence values is expected with the increase in the amount of vegetation, while for other spectral classes with higher stability, such as the shrubby pasture and water, coherence is higher (Pôssa et al., 2018).




Figure 5.5. Interferometric coherence distribution from CSK data of LULC classes.

5.3.2 Classification Results

Table 5.6 shows the classification results obtained for different decompositions and polarimetric indices, with or without addition of interferometric coherence, from the RF and SVM classifiers. The best performances were obtained with the Yamaguchi decomposition, combined with CSK interferometric coherence, using the RF classifier (OA of 87.81% and Kappa index of 0.81). All classifications from the decompositions and polarimetric indices of ALOS-2/PALSAR-2 showed an increase in OA and Kappa index when associated with coherence. However, the Yamaguchi decomposition presented the highest improvement, using the RF algorithm. It is worth mentioning that this technique has one more component than other techniques, such as Cloude-Pottier, Freeman-Durden, and van Zyl techniques.

Table 5.6. Performance of the RF and SVM classifiers.

Polarimetric Attributes	Classifier	OA%	OA CL 95%	Kappa	Kappa CL 95%
Cloude–Pottier	RF	85.38	84.94 – 85.81	0.77	0.76 – 0.78
	SVM	84.20	83.75 – 84.65	0.75	0.74 – 0.76
Cloude–Pottier + γ	RF	86.07	85.65 – 86.50	0.78	0.78 – 0.79
	SVM	85.13	84.69 – 85.57	0.77	0.76 – 0.77
Yamaguchi	RF	87.81	87.08 – 88.54	0.81	0.80 – 0.82
	SVM	84.98	84.54 – 85.41	0.76	0.76 – 0.77
Yamaguchi + γ	RF	90.59	89.94 – 91.24	0.86	0.85 – 0.87
	SVM	86.23	85.80 – 86.65	0.79	0.78 – 0.79
Freeman–Durden	RF	84.51	84.07 – 94.96	0.76	0.75 – 0.77
	SVM	82.40	81.93 – 82.86	0.72	0.71 – 0.73
Freeman–Durden + γ	RF	86.03	85.60 – 86.46	0.78	0.77 – 0.79
	SVM	85.24	84.81 – 85.68	0.77	0.76 – 0.78
van Zyl	RF	85.49	85.06 – 85.93	0.77	0.77 – 0.78

van Zyl + γ	SVM	83.62	83.16 – 84.07	0.74	0.73 – 0.75
	RF	86.11	85.68 – 86.53	0.78	0.78 – 0.79
	SVM	86.05	85.63 – 86.48	0.78	0.77 – 0.79
Pope and RVI indexes	RF	81.08	80.60 – 81.57	0.69	0.69 – 0.70
	SVM	81.29	80.81 – 81.77	0.70	0.69 – 0.71
Pope and RVI indexes + γ	RF	82.91	82.45 – 83.37	0.72	0.72 – 0.74
	SVM	82.84	82.37 – 83.30	0.73	0.72 – 0.73

As for the classifications related to polarimetric indices, the best classification performance was obtained with the SVM classifier, obtaining a Kappa index of 0.70. This group of attributes integrated to the interferometric coherence data resulted in a Kappa index of 0.73, with no statistically significant difference. However, the classifications containing the polarimetric indices were the ones with the lowest accuracy, in relation to the entire set of decompositions.

Figure 5.6 presents the values related to UA and PA for the RF classification. It is possible to observe that the UA values in all analyzed groups were above 75% for most LULC classes. Only the SV2 and SV3 classes showed lower values of 48% and 45%, respectively, for the Yamaguchi decomposition, with an increase of approximately 10% when coherence was added.

Regarding the PA values, we can see different patterns in the analyzed groups. The contribution of interferometric coherence was statistically significant mainly for the SV classes in the classifications related to the Yamaguchi and Freeman-Durden components, and the polarimetric indices. This metric is related to the sensitivity of the classifier, that is, the ability to correctly distinguish a given class, which shows that the coherence reduced the omission error for SV areas. The PFO, CPA, and WAT classes presented high UA and PA values (above 80%) for all analyzed groups, showing that these classes presented greater reliability and less confusion among the other classes.




Figure 5.6. User's and producer's accuracy based on Random Forest algorithm.

Figure 5.7 presents the values related to UA and PA for the SVM classification. There is high similarity between the graphs in relation to the classification with the RF algorithm. There was a contribution of interferometric coherence to the SV classes in almost all groups of attributes analyzed, being statistically significant for the Yamaguchi decomposition, mainly for SV2 and SV3, which showed an increase of more than 15% when associated with coherence. Only the van Zyl technique did not obtain similar performance, with a decrease in the SV1 class.

Among all attribute groups, the group of polarimetric indices that presented the lowest PA was the DEG, SPA, SV1, SV2, SV2, and SV3 classes, indicating that there may have been confusion among these classes by the SVM classifier. DEG presented approximately 50% lower

values of accuracy from the Yamaguchi attributes in relation to the RF classification. This difference indicates that the RF classifier presented better performance to identify this class.




Figure 5.7. User's and producer's accuracy based on the Support Vector Machine algorithm.

Comparing Figures 5.6 and 5.7, there is a positive impact of interferometric coherence in the discrimination of classes containing vegetation cover in both classifications. The increase in PA in almost all groups of polarimetric attributes of the SV classes is noted. This result indicates that interferometric coherence contributed to an improvement in the discrimination of vegetation typologies, considering different stages of SV.

Figure 5.8 illustrates the result of the best accuracies experiment using the Yamaguchi decomposition technique on ALOS-2/PALSAR-2 data, with interferometric coherence

integration. Note the predominance of PFO and CPA classes in the study area (Figure 8), attributing to these classes 46.2% and 25.4% of the total area, respectively. The smallest areas correspond to DEG, SV2, SV3, and WAT. If added together, they represent 6% of the total study area.




Figure 5.8. Best classification results obtained by the Random Forest algorithm, considering the Yamaguchi technique from full-polarimetric ALOS-2 data with COSMO-SkyMed coherence interferometric addition.

When comparing the integration of coherence with the components of the Yamaguchi technique (Figure 5.9), we can observe that there was a decrease of approximately 3% of the total area of PFO (from 49.2% to 46.2%). The SPA class also showed a decrease in its area with the coherence (11.0% to 9.4%) while the SV showed an increase in their territorial extension, mainly for the SV3 class, which increased from 0.3% to 2.1% with the integration of coherence. This result leads to the conclusion that previously classified PFO and SPA areas were integrated

to SV areas when interferometric coherence was added, contributing to the improvement of the discrimination of these classes.




Figure 5.9. Area (%) occupied by each land use and land cover class considered in this study, estimated by the Random Forest algorithm based on the Yamaguchi technique with COSMO-SkyMed interferometry coherence.

Figure 5.10 shows the comparison of two fragments of the classifications corresponding to the Yamaguchi technique using the RF classifier, with and without coherence integration. Two random areas were chosen, one containing predominantly the PFO class and the other containing areas of CPA and SPA. We can see by zooming these areas that there was an increase in the SV areas when coherence is added to the polarimetric components.




Figure 5.10. Comparison of two fragments of classifications corresponding to the Yamaguchi technique using the Random Forest classifier, with and without coherence integration.

Figure 5.11 presents the ranking of importance of each feature in the classification process based on the RF algorithm performed for each polarimetric decomposition technique and its respective components. It is possible to observe that interferometric coherence was the second variable that most contributed to the RF classification in all polarimetric decomposition techniques. Regarding the polarimetric indices, coherence was the third variable that contributed most to the classification, after the BMI and CSI indices.




Figure 5.11. Random Forest's predictor variables importance.

5.4 DISCUSSION

The results showed good potential of CSK interferometric coherence for RF classification combined with the Yamaguchi decomposition from ALOS-2/PALSAR-2 polarimetric data, showing a Kappa index of 0.86 and overall accuracy of 90.59%. This result is in agreement with other studies that integrated coherence in thematic mappings based on L-band SAR data. For example, [Luckman et al. \(2000\)](#) evaluated the potential of interferometric coherence imaging, combined with JERS-1 L-band and ERS-1 and ERS-2 C-band SAR data for biomass estimates in an Amazonian Forest site. The results indicated that the interferometric coherence facilitated the identification of areas of deforestation. They also highlighted that

some surfaces were identifiable in the coherence image, however, they were not visible in the SAR intensity data.

[Gaboardi \(2002\)](#) compared the application of interferometric coherence information and amplitude data acquired by the ERS-1 satellite for mapping the LULC classes of a region in the Brazilian Amazon. The author concludes that interferometric coherence increased the accuracy in relation to intensity data, presenting a Kappa index higher than 0.6.

In our study, the polarimetric decomposition techniques proved to be more efficient in distinguishing the different stages of the SV class, when compared to the RVI and Pope's polarimetric indices. However, when integrating CSK coherence data, there was an improvement in the accuracy of these classes in all analyzed groups. [Pôssa et al. \(2018\)](#) used polarimetric attributes derived from ALOS/PALSAR for thematic mapping of an area in the Brazilian Amazon. In their study, the Cloude-Pottier decomposition theorem associated with the interferometric coherence attribute of TanDEM-X presented better classification performance (Kappa = 0.72 and global accuracy = 78.79%). With the integration of interferometric coherence, they also observed that the forest succession classes showed a considerable improvement in accuracy.

The RF algorithm performed better than the SVM algorithm, indicating its superiority, as previous studies have already shown, mainly in forest areas ([Mercier et al. 2019](#); [Sheykhmousa et al. 2020](#); [Wiedekehr et al. 2020](#); [Kiyohara and Sano, 2022](#)). [Jin et al. \(2014\)](#) used interferometric coherence to classify LULC classes of an area in the New York State, U.S. The authors used multitemporal ALOS/PALSAR data acquired in 2010 and classified by the RF algorithm. The results indicated a 7% increase in mapping accuracy when including interferometric coherence combined with intensity data.

5.5 CONCLUSIONS

The results of the present study showed good potential of CSK interferometric coherence combined with the Yamaguchi polarimetric decomposition from ALOS-2/PALSAR-2 polarimetric data for RF classification, presenting a Kappa index of 0.86 and overall accuracy of 90.59%. In this study, the RF algorithm presented overall better performance than the SVM algorithm. The SVM algorithm presented a slight better accuracy only the classification related to the RVI and Pope polarimetric indexes.

In this study, the integration of interferometric coherence contributed in a statistically significant way to the polarimetric information presented by the Yamaguchi group. This group has one more component, and this technique probably was advantageous over the others. However, interferometric coherence also contributed to an improvement in sensitivity using both RF and SVM algorithms and in the other groups as well: Freeman-Durden, Cloude Pottier, van Zyl, and polarimetric indexes, increasing the thematic discrimination of LULC classes.

The integration of the X-band interferometric coherence to the L-band polarimetric attributes had a positive impact mainly on the discrimination of classes referring to primary forest, secondary vegetation, and degradation. Even considering the small increment in the classification performance by the coherence, this interferometric attribute derived from the X-band is promising in LULC mappings in areas with different forest typologies. The results of this study can assist the future development of a full-polarimetric SAR system to monitor the re-suppression of SV in the Brazilian Amazon.

Funding

Bárbara Hass Kiyohara was supported by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES, Process # 88887.500593/2020-00) and the Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq, Process # 380070/2020-0).

Acknowledgements

The authors gratefully acknowledge the Japan Aerospace Exploration Agency (JAXA), under ALOS Research Announcement, which provided ALOS/PALSAR-2 data and Censipan (Centro Gestor e Operacional do Sistema de Proteção da Amazônia - Brazil Ministry of Defense) for the support to this project.

5.6 REFERENCES

Almeida, C. A., A. C. Coutinho, J. C. D. M. Esquerdo, M. Adami, A. Venturieri, C. G. Diniz, N. Dessay, L. Durieux, and A. R. Gomes. 2016. “High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data”. *Acta Amazonica* 46: 291–302. doi: 10.1590/1809-4392201505504.

- Asner, G. P. 2001. "Cloud cover in Landsat observations of the Brazilian Amazon". *International Journal of Remote Sensing* 22(18): 3855-3862. doi: 10.1080/01431160010006926.
- Belgiu, M and L. Drăguț. 2016. "Random Forest in remote sensing: A review of applications and future directions". *ISPRS Journal of Photogrammetry and Remote Sensing* 114: 24–31. doi: 10.1016/j.isprsjprs.2016.01.011.
- Bongers F., R. Chazdon, L. Poorter and M. Peña-Claros. 2015. "The potential of secondary forests". *Science* 348(6235): 642–643. doi: 10.1126/science.348.6235.642-c.
- Breiman, L. 2001. Random Forests. *Machine Learning* 45: 5–32. doi: 10.1023/A:1010933404324.
- Carvalho, R., M. Adami, S. Amaral, F. G. Bezerra and A. P. D. Aguiar. 2019. "Changes in secondary vegetation dynamics in a context of decreasing deforestation rates in Pará, Brazilian Amazon". *Applied Geography* 106: 40-49. doi: 10.1016/j.apgeog.2019.03.001.
- Chazdon, R. L., E. N. Broadbent, D. M. Rozendaal, F. Bongers, A. M. A. Zambrano, T. M. Aide, et al. 2016. "Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics". *Science Advances* 2(5): e1501639. doi: 10.1126/sciadv.1501639.
- Cloude, S. R. and E. Pottier. 1996. "A review of target decomposition theorems in radar polarimetry". *IEEE Transactions on Geoscience and Remote Sensing* 34(2): 498–518. doi: 10.1109/36.485127.
- Congalton, R. G. and K. Green. 1999. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. Lewis Publishers: New York, NY, USA.
- Feldpausch, T. R., M. A. Rondon, E. C. M. Fernandes, S. J. Riha and E. Wandelli. 2004. "Carbon and nutrient accumulation in secondary forests regenerating on pastures in Central Amazonia". *Ecological Applications* 14: 164–176. doi: 10.1890/01-6015.
- Freeman, A. and S. L. Durden 1998. "A three-component scattering model for polarimetric SAR data". *IEEE Transactions on Geoscience and Remote Sensing* 36(3): 963–973. doi: 10.1109/36.673687.
- Furtado, L. F. A., T. S. F. Silva and E. M. L. M. Novo. 2016. "Dual-season and full-polarimetric C band SAR assessment for vegetation mapping in the Amazon várzea wetlands". *Remote Sensing of Environment* 174: 212-222. doi: 10.1016/j.rse.2015.12.013.

- Gaboardi, C. 2002. “*Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional do Tapajós*”. National Institute for Space Research (INPE). PhD Thesis.
- Garrett, R. D., F. Cammelli, J. Ferreira, S. A. Levy, J. Valentim and I. Vieira. 2021. “Forests and sustainable development in the Brazilian Amazon: History, trends, and future prospects”. *Annual Review of Environment and Resources*. 46: 625-652. doi: 10.1146/annurev-environ-012220-010228.
- Goldstein, R. M., H. A. Zebker and C. L. Werner. 1988. “Satellite radar interferometry: Two-dimensional phase unwrapping”. *Radio Science* 23(4): 713-720. doi: 10.1029/RS023i004p00713.
- Hagensieker, R. and B. Waske. 2018. “Evaluation of multi-frequency SAR images for tropical land cover mapping”. *Remote Sensing* 10(2): 257. doi: 10.3390/rs10020257
- Halbgewachs, M., M. Wegmann, and E. Ponte 2022. “A spectral mixture analysis and landscape metrics-based framework for monitoring spatiotemporal forest cover changes: A case study in Mato Grosso, Brazil”. *Remote Sensing* 14(8): 1907. doi: 10.3390/rs14081907.
- Heinrich, V. H., R. Dalagnol, H. L. Cassol, T. M. Rosan, C. T. Almeida, C. H. Silva Junior, et al. 2021. “Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change”. *Nature Communications* 12(1): 1785. doi: 10.1038/s41467-021-22050-1.
- Huang, C., L. S. Davis, and J. R. G. Townshend. 2002. “An assessment of support vector machines for land cover classification”. *International Journal of Remote Sensing* 23(4): 725-749. doi: 10.1080/01431160110040323.
- IBGE. 2022. “Instituto de Geografia Brasileira: Amazônia Legal”. Accessed 28 September 2022. <https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html?=&t=acesso-ao-produto>.
- IBGE. 2012. *Manual Técnico da Vegetação Brasileira. Manuais Técnicos em Geociências, n. 1*. IBGE: Rio de Janeiro, Brazil, 274p.
- INPE. 2019. “TerraClass. Projetos e Pesquisas. 2019”. Accessed 24 June 2022. http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php.
- JAXA. 2022. “Japan Aerospace Exploration Agency. Calibration results of ALOS-2/PALSAR-2 JAXA Standard Products”. Accessed 8 February 2022. https://www.eorc.jaxa.jp/ALOS-2/en/calval/calval_index.htm.

- Jin, H., G. Mountrakis, and S. V. Stehman. 2014. "Assessing integration of intensity, polarimetric scattering, interferometric coherence and spatial texture metrics in PALSAR-derived land cover classification". *ISPRS Journal of Photogrammetry and Remote Sensing* 98: 70-84. doi: 10.1016/j.isprsjprs.2014.09.017.
- Karatzoglou, A., D. Meyer, and K. Hornik. 2006. "Support vector machines in R." *Journal of Statistical Software* 15, 1-28. doi: 10.18637/jss.v015.i09.
- Kim, Y. and J. J. Van Zyl. 2009. "A time-series approach to estimate soil moisture using polarimetric radar data." *IEEE Transactions on Geoscience and Remote Sensing* 47(8): 2519–2527. doi: 10.1109/TGRS.2009.2014944.
- Kiyohara, B. H. and E. E. Sano. 2022. "Mapping secondary vegetation of a region of deforestation hotspot in the Brazilian Amazon: Performance analysis of C-and L-band SAR data acquired in the rainy season." *Forests* 13(9): 1457. doi: 10.3390/f13091457.
- Kuplich, T. M. "Classifying regenerating forest stages in Amazonia using remotely sensed images and a neural network 2006." *Forest Ecology and Management* 234(1-3): 1-9. doi: 10.1016/j.foreco.2006.05.066.
- Lee, J. S. and E. Pottier. 2017. *Polarimetric radar imaging: from basics to applications*. CRC Press, Taylor & Francis Group.
- Lewis, A. J. and F. M. Henderson. 1998. *Radar fundamentals: The geosciences perspective*. In: *Principles and Applications of Imaging Radar. Manual of Remote Sensing*, 3rd ed.; Henderson, F.M., Lewis, A.J., Eds.; John Wiley & Sons: Hoboken, NJ, USA, pp. 131–181.
- Lu, D. and Q. Weng. 2007. "A survey of image classification methods and techniques for improving classification performance." *International. Journal of Remote Sensing* 28(5): 823–870. doi: 10.1080/01431160600746456.
- Luckman, A., J. Baker, and U. Wegmüller. 2000. "Repeat-pass interferometric coherence measurements of disturbed tropical forest from JERS and ERS satellites." *Remote Sensing of Environment* 73(3): 350-360. doi: 10.1016/S0034-4257(00)00110-3.
- MapBiomass. 2022. "MapBiomass v. 6.0". Accessed 25 June 2022. <https://mapbiomas.org/en/statistics>.
- Mercier, A., J. Betbeder, F. Rumiano, J. Baudry, V. Gond, L. Blanc, and L. Hubert-Moy. 2019. "Evaluation of Sentinel-1 and 2 time series for land cover classification of forest–

- agriculture mosaics in temperate and tropical landscapes.” *Remote Sensing* 11(8): 979. doi: 10.3390/rs11080979.
- Miguel, B. H. and E. E. Sano. 2019. “Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica.” *Revista Brasileira de Geografia Física* 12(2): 427-442. doi: 10.26848/rbgf.v12.2.p427-442.
- Mohammadimanesh, F., B. Salehi, M. Mahdianpari, M. Motagh, and B. Brisco. 2018. “An efficient feature optimization for wetland mapping by synergistic use of SAR intensity, interferometry, and polarimetry data.” *International Journal Applied Earth Observation and Geoinformation* 73: 450-462. doi: 10.1016/j.jag.2018.06.005.
- Moran, E. F. 1993. “Deforestation and land use in the Brazilian Amazon.” *Human Ecology* 21(1): 1-21. doi: 10.1093/acrefore/9780199389414.013.102.
- Nelson, R. F., D. S. Kimes, W A. Salas, and M. Routhier. 2000. “Secondary Forest age and tropical forest biomass estimation using Thematic Mapper imagery: Single-year tropical forest age classes, a surrogate for standing biomass, cannot be reliably identified using single-date TM imagery.” *Bioscience* 50(5): 419-431. doi: 10.1641/0006-3568(2000)050[0419:SFAATF]2.0.CO;2.
- Neves, A. K., T. S. Körting, L. M. G. Fonseca, and M. I. S. Escada. 2020. “Assessment of TerraClass and MapBiomas data on legend and map agreement for the Brazilian Amazon biome.” *Acta Amazonica* 50: 170-182. doi: 10.1590/1809-4392201900981.
- Nunes, S., L. Oliveira, J. Siqueira, D. C. Morton, and C. M. Souza. 2020. “Unmasking secondary vegetation dynamics in the Brazilian Amazon.” *Environmental Research Letters* 15(3): 034057. doi: 10.1088/1748-9326/ab76db.
- Olesk, A., J. Praks, O. Antropov, K. Zalite, T. Arumäe, and K. Voormansik. 2016. “Interferometric SAR coherence models for characterization of hemiboreal forests using TanDEM-X data.” *Remote Sensing* 8(9): 700-715. doi: 10.3390/rs8090700.
- Paneque-Gálvez, J., J. F. Mas, G. Moré, J. Cristóbal, M. Orta-Martínez, A. C. Luz, and V. Reyes-García. 2013. “Enhanced land use/cover classification of heterogeneous tropical landscapes using support vector machines and textural homogeneity.” *International Journal of Applied Earth Observation and Geoinformation* 23: 372-383. doi: 10.1016/j.jag.2012.10.007.
- Petropoulos, G. P., C. Kontoes, and I. Keramitsoglou. 2011. “Burnt area delineation from a uni-temporal perspective based on Landsat TM imagery classification using Support Vector

- Machines.” *International Journal of Applied Earth Observation and Geoinformation* 13(1), 70-80. doi: 10.1016/j.jag.2010.06.008.
- Ponzoni, F.J. and A. N. P. Rezende. 2004. “Caracterização espectral de estágios sucessionais de vegetação secundária arbórea em Altamira (PA), através de dados orbitais.” *Revista Árvore* 28: 535–545. doi: 10.1590/S0100-67622004000400007.
- Pope, K. O., J. M. Rey-Benayas, and J. F. Paris. 1994. “Radar remote sensing of forest and wetland ecosystems in the Central American tropics.” *Remote Sensing of Environment* 48(2): 205–219. doi: 10.1016/0034-4257(94)90142-2.
- Pôssa, E. M., F. F. Gama, J. R. Santos, J. C. Mura, and P. C. Bispo. 2018. “Análise de uso da terra e cobertura florestal na Amazônia central, a partir de dado polarimétrico PALSAR/ALOS-1 e coerência interferométrica TanDEM-X.” *Revista Brasileira de Geografia Física* 11(6): 2094–2108. doi: 10.26848/rbgf.v11.6.p2094-2108.
- Santos, M.V. 2000. *Zoneamento sócio-econômico-ecológico: Diagnóstico sócio-econômico-ecológico do Estado de Mato Grosso e assistência técnica na formulação da 2ª aproximação*. SEPLAN-MT: Cuiabá, MT, Brazil.
- Sheykhmousa, M., M. Mahdianpari, H. Ghanbari, F. Mohammadimanesh, P. Ghamisi, and S. Homayouni. 2020. “Support Vector Machine versus Random Forest for remote sensing image classification: A meta-analysis and systematic review.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13: 6308-6325. doi: 10.1109/JSTARS.2020.3026724.
- Sothe, C., C. M. Almeida, V. Liesenberg, and M. B. Schimalski. 2017. “Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in Southern Brazil.” *Remote Sensing* 9(8): 838. doi: 10.3390/rs9080838.
- Telespazio. 2022. “COSMO-SkyMed”. Accessed 4 October 2022. <https://www.telespazio.com/en/programmes/cosmo-skymed>.
- Temporim, F. A., F. F. Gama, J. C. Mura, W. R. Paradella, and G. G. Silva. 2017. “Application of persistent scatterers interferometry for surface displacements monitoring in N5E open pit iron mine using TerraSAR-X data, in Carajás Province, Amazon region.” *Brazilian Journal of Geology* 47: 225-235. doi: 10.1590/2317-4889201720170006.
- TerraClass. 2022. “TerraClass: Amazonia Legal”. Accessed 13 August 2022. <https://www.terraclass.gov.br/geoportal-aml/>.

- Thanh Noi, P. and M. Kappas. 2017. "Comparison of Random Forest, K-Nearest Neighbor, and Support Vector Machine classifiers for land cover classification using Sentinel-2 imagery." *Sensors* 18(1): 18. doi: 10.3390/s18010018.
- Uhl, C., R. Buschbacher, and E. A. S. Serrao. 1988. "Abandoned pastures in Eastern Amazonia: I. Patterns of plant succession." *Journal of Ecology* 76: 663–681. doi: 10.2307/2260566
- Van der Linden, S., A. Rabe, M. Held, B. Jakimow, P. J. Leitão, A. Okujeni, S. S. Schwieder, and P. Hostert. 2015. "The EnMAP-Box—A toolbox and application programming interface for EnMAP data processing." *Remote Sensing* 7(9): 11249–11266. doi: 10.3390/rs70911249.
- Van der Linden, S., A. Rabe, M. Held, F. Wirth, S. Suess, A. Okujeni, and P. Hostert. 2014. *Image SVM Classification, Manual for Application: Image SVM Version 3.0*. Humboldt-Universität: Berlin, Germany.
- Van der Sanden, J. J. 1977. *Radar remote sensing to support tropical forest management*. Wageningen University and Research.
- Van Zyl, J. J. 1992. "Application of Cloude's target decomposition theorem to polarimetric imaging radar data." *SPIE* 27: 184–191. doi: 10.1117/12.140615.
- Vieira, I. C. G., A. S. Almeida, E. A. Davidson, T. A. Stone, C. J. R. Carvalho, and J. B. Guerrero. 2003. "Classifying successional forests using Landsat spectral properties and ecological characteristics in Eastern Amazônia." *Remote Sensing of Environmental* 87(4): 470–481. doi: 10.1016/j.rse.2002.09.002.
- Wegmüller, U., M. Santoro, and C. Werner. 2015. "On the estimation and interpretation of Sentinel-1 TOPS InSAR coherence." In: Proceedings of FRINGE, ESA SP. European Space Agency.
- Wiederkehr, N. C., F. F. Gama, P. B. Castro, P. D. C. Bispo, H. Balzter, E. E. Sano, and J. C. Mura. 2020. "Discriminating Forest successional stages, forest degradation, and land use in Central Amazon using ALOS/PALSAR-2 full-polarimetric data." *Remote Sensing* 12(21): 3512. doi: 10.3390/rs12213512.
- Yamaguchi, Y., T. Moriyama, M. Ishido, and H. Yamada. 2005. "Four-component scattering model for polarimetric SAR image decomposition." *IEEE Transactions on Geoscience and Remote Sensing* 43(8): 1699–1706. doi: 10.1109/TGRS.2005.852084.

- Yu, Y., M. Li, and Y. Fu. 2017. "Forest type identification by random forest classification combined with SPOT and multitemporal SAR data." *Journal of Forestry Research* 29(5): 1407–1414. doi: 10.1007/s11676-017-0530-4.

6 CONSIDERAÇÕES FINAIS

O presente trabalho apresentou três artigos sequenciais, todos com inovações técnicas, que buscaram atender aos respectivos objetivos geral e específicos da tese ao aplicar algoritmos de aprendizado de máquina para a discriminação de áreas de vegetação secundária baseada em dados SAR, a partir da exploração de diferentes técnicas de processamento. A abordagem utilizada nesta pesquisa traz algumas contribuições para o desenvolvimento de um sistema baseado em dados SAR para monitorar a re-supressão da regeneração em tempo quase real na Amazônia brasileira, principalmente na estação chuvosa, devido à cobertura persistente de nuvens na Amazônia que inviabiliza o uso de dados ópticos.

Vale ressaltar que um dos aspectos mais difíceis deste estudo foi a coleta de dados confiáveis de amostras de treinamento e validação. O trabalho de coleta de dados em campo na área de estudo foi inviabilizado devido à falta de recursos e acessibilidade durante a estação chuvosa. Além disso, como já mencionado na Seção 1, não há um inventário florestal disponível para a área de estudo. Dessa forma, tentou-se utilizar os melhores dados auxiliares disponíveis, que foram os produzidos pelos projetos TerraClass, MapBiomas e PRODES. De acordo com os resultados encontrados, podem-se elencar as seguintes conclusões:

- (1) O classificador *Random Forest* apresentou melhor performance em relação ao algoritmo SVM em praticamente todas as classificações realizadas neste estudo, comprovando a sua superioridade em discriminar áreas com tipologias florestais.
- (2) O uso de atributos de textura GLCM é altamente recomendado para melhorar a acurácia da classificação em dados SAR.
- (3) A análise de componentes principais foi utilizada neste estudo para reduzir as dimensões das variáveis originais de textura GLCM, sem perda de informação, ao reduzir a dimensionalidade do conjunto de dados. Diante dos resultados obtidos, a APC mostrou-se eficaz, permitindo a remoção ou descarte de atributos derivados do retroespalhamento dos dados do Sentinel-1 e do ALOS-2, resultando em economia de tempo e de recursos, diminuindo o esforço computacional.

(4) A integração da coerência interferométrica da banda X aos atributos polarimétricos da banda L teve impacto positivo principalmente na discriminação das classes referentes à floresta primária, vegetação secundária e degradação.

Os resultados das classificações por aprendizado de máquina indicaram ainda que:

- i) Imagens do COSMO-SkyMed processados pela técnica de extração de feições GLCM apresentaram resultados muito inferiores (índice Kappa de 0,56 e acurácia global de 63,67%) para a classificação SVM. As classes de vegetação secundária apresentaram baixa acurácia, principalmente no estágio inicial.
- ii) As classificações realizadas com dados do Sentinel-1 apresentaram melhores resultados quando integrados com atributos de textura GLCM (índice Kappa de 0,73 e acurácia global de 81,07%), quando processados pelo algoritmo de classificação RF. No entanto, houve bastante confusão entre as áreas de floresta primária e vegetação secundária.
- iii) As classificações realizadas nos dados do ALOS/PALSAR-2 apresentaram resultados superiores em relação aos demais dados, principalmente quando utilizada a técnica de decomposição de alvos Yamaguchi nos dados polarimétricos (índice Kappa de 0,81 e acurácia global de 87,81%). As áreas de vegetação secundária em estágio inicial apresentaram melhor acurácia em relação aos estágios intermediário e avançado, havendo um aumento na acurácia geral quando as informações interferométricas da banda X foram adicionadas.

Os resultados dos artigos 2 e 3 demonstraram a viabilidade do método de classificação baseado em algoritmos de máquinas empregados a dados SAR nas bandas C e L, reforçando a habilidade desses sensores no monitoramento florestal em épocas de cobertura de nuvens.

Espera-se que os resultados desse estudo apoiem o entendimento das diferentes frequências e técnicas de SAR aplicadas ao mapeamento de florestas tropicais, a partir de algoritmos de aprendizado de máquina, principalmente em áreas de vegetação secundária, contribuindo para futuros projetos de monitoramento florestal na Amazônia. Estudos futuros são sugeridos com aplicações de outros métodos de classificação, como redes neurais convolucionais (CNN) e outras abordagens de *deep learning*.

REFERÊNCIAS

- AMARAL, S.; SOARES, J. V.; ALVES, D. S.; MELLO, E. D.; ALMEIDA, S. A. S.; SILVA, O. D.; SILVEIRA, A. M. Relações entre índice de área foliar (LAI), área basal e índice de vegetação (NDVI) em relação a diferentes estágios de crescimento secundário na Floresta Amazônica em Rondônia. **Anais...** Simpósio Brasileiro de Sensoriamento Remoto, v. 8, p. 485-489, 1996.
- AZEVEDO, A. R. D.; SANTOS, J. R. D.; GAMA, F. F.; GRAÇA, P. M. L. D. A.; MURA, J. C. Caracterização de uso e cobertura da terra na Amazônia utilizando imagens duais multitemporais do COSMO-SkyMed. **Acta Amazonica**, v. 1, n. 44, p. 87-97, 2014.
- BELGIU, M.; DRĂGUȚ, L. Random Forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016.
- BISPO, P. D. C.; PARDINI, M.; PAPATHANASSIOU, K. P.; KUGLER, F.; BALZTER, H.; RAINS, D. et al. Mapping Forest successional stages in the Brazilian Amazon using forest heights derived from TanDEM-X SAR interferometry. **Remote Sensing of Environment**, v. 232, p. 111194, 2019.
- BRASIL, Lei Nº 1.806, de 6 de janeiro de 1953. Dispõe sobre o Plano de Valorização Econômica da Amazônia, cria a superintendência da sua execução e dá outras providências. Rio de Janeiro, RJ: Diário Oficial da União, 1953.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5–32, 2001.
- BROWN, S.; LUGO, A. E. Tropical secondary forests. **Journal of Tropical Ecology**, v. 6, n. 1, p. 1-32, 1990.
- CHANG, N. B.; BAI, K. **Multisensor data fusion and machine learning for environmental remote sensing**. CRC Press, 2018. 529 p.

CLOUDE, S. R.; POTTIER, E. A review of target decomposition theorems in radar polarimetry. **IEEE Transactions on Geoscience and Remote Sensing**, v. 34, n. 2, p. 498–518, 1996.

DPI. Departamento de Processamento de Imagens – INPE. **Componentes Principais. Transformação por componentes principais.** Disponível em: <<http://www.dpi.inpe.br/spring/portugues/tutorial/compon.html>>. Acesso em: 22 jul. 2020.

DUARTE, K. T. N. **Contribuições em Análise de Textura para fins de Segmentação de Imagens Digitais.** Dissertação de mestrado em Tecnologia - Área de Sistemas de Informação e Comunicação, Faculdade de Tecnologia, Universidade Estadual de Campinas, 2017, 83 f.

EMBRAPA. **Satélites de Monitoramento - ALOS - Advanced Land Observing Satellite.** Disponível em: <<https://www.embrapa.br/en/satelites-de-monitoramento/missoes/alos>>. Acesso em: 16 jul. 2020.

E-GEOS. COSMO-SkyMed – **The most advanced SAR constellation.** Disponível em: <<https://www.e-geos.it/#/satellite-hub/general/satellite-detail/csk>> Acesso em: 12 jul. 2020.

ESA. **Missions – Sentinel-2.** Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 12 jul. 2020.

FEARNSIDE, P. M. Global warming and tropical land-use change: greenhouse gas emissions from biomass burning, decomposition and soils in forest conversion, shifting cultivation and secondary vegetation. **Climatic Change**, v. 46, n. 1-2, p. 115-158, 2000.

FLORES-ANDERSON, A. I.; HERNDON, K. E.; THAPA, R. B; CHERRINGTON, E. **The SAR handbook: comprehensive methodologies for forest monitoring and biomass estimation** (No. MSFC-E-DAA-TN67454), 2019.

FREEMAN, A.; DURDEN, S. L. A three-component scattering model for polarimetric SAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 3, p. 963–973, 1998.

FREITAS, F. L.; SPAROVEK, G.; BERNDES, G.; PERSSON, U. M.; ENGLUND, O.; BARRETTO, A.; MÖRTBERG, U. Potential increase of legal deforestation in Brazilian Amazon after Forest Act revision. **Nature Sustainability**, v. 1, n. 11, p. 665-670, 2018.

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 varzea wetlands. **Remote Sensing of Environment**, v. 174, 212-222, 2016.

GARRETT, R. D.; CAMMELLI, F.; FERREIRA, J.; LEVY, S. A.; VALENTIM, J.; VIEIRA, I. Forests and sustainable development in the Brazilian Amazon: history, trends, and future prospects. **Annual Review of Environment and Resources**, v. 46, p. 625-652, 2021.

GREEN, R. M. Relationships between polarimetric SAR backscatter and forest canopy and sub-canopy biophysical properties. **International Journal of Remote Sensing**, v. 19, n. 12, p. 2395-2412, 1998.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, n. 6, p. 610-621, 1973.

HEINRICH, V. H.; DALAGNOL, R.; CASSOL, H. L.; ROSAN, T. M.; ALMEIDA, C. T.; SILVA JUNIOR, C. H.; ARAGÃO, L. E. Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change. **Nature Communications**, v. 12, n. 1, p. 1-11, 2021.

HUANG, C.; DAVIS, L. S.; TOWNSHEND, J. R. G. An assessment of support vector machines for land cover classification. **International Journal of Remote Sensing**, v. 23, n. 4, p. 725-749, 2002.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Amazônia Legal**. Disponível em: <<https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-regionais/15819-amazonia-legal.html?=&t=acesso-ao-produto>>. Acesso em: 12 set. 2022.

INPE. **TerraClass. Projetos e Pesquisas**. Disponível em: <http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php> Acesso em: 24 jun. 2022.

JAKOVAC, C. C.; PEÑA-CLAROS, M.; KUYPER, T. W.; BONGERS, F. Loss of secondary-forest resilience by land-use intensification in the Amazon. **Journal of Ecology**, v. 103, n. 1, p. 67-77, 2015.

JAXA. Japan Aerospace Exploration Agency. **ALOS-2 Project/PALSAR-2**. Disponível em: <<https://www.eorc.jaxa.jp/ALOS-2/en/about/palsar2.htm>>. Acesso em: 15 jul. 2020.

JENSEN, J. R. **Remote Sensing of the Environment: An Earth Resource Perspective**. Second Edition. Pearson Education Limited, 2014. 619 p.

KARATZOGLU, A.; MEYER, D.; HORNIK, K. Support vector machines in R. **Journal of Statistical Software**, v. 15, p. 1-28, 2006.

KIM, Y.; VAN ZYL, J. J. A time-series approach to estimate soil moisture using polarimetric radar data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 8, p. 2519-2527, 2009.

KIYOHARA, B. H.; SANO, E. E. Mapping secondary vegetation of a region of deforestation hotspot in the Brazilian Amazon: Performance analysis of C-and L-band SAR data acquired in the rainy season. **Forests**, v. 13, n. 9, p. 1457, 2022.

KUPLICH, T. M. Classifying regenerating forest stages in Amazonia using remotely sensed images and a neural network. **Forest Ecology and Management**, v. 234, n. 1-3, p. 1-9, 2006.

KUPLICH, T. M. **Sensoriamento remoto por radar para estudos de vegetação**. Disponível em: <<https://www.ofitexto.com.br/wp-content/uploads/2017/10/Talk-Sensoriamento-remoto-por-radar-para-estudos-de-vegeta%C3%A7%C3%A3o.pdf>>. Acesso em: 11 jul. 2020.

KUPLICH, T. M.; CURRAN, P. J.; ATKINSON, P. M. Relating SAR image texture to the biomass of regenerating tropical forests. **International Journal of Remote Sensing**, v. 26, n. 21, p. 4829-4854, 2005.

LEE, J.; POTTIER, E. **Polarimetric radar imaging from basics to applications**. Nova York: CRC Press, 2009. 398 p.

LU, D.; WENG, Q. A Survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**, v. 28, n. 5, p. 823–870, 2007.

MIGUEL, B. H.; SANO, E. E. Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica. **Revista Brasileira de Geografia Física**, v. 12, n. 2, p. 427-442, 2019.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada**. Belo Horizonte. Editora UFMG, 1ª reimpressão, 2007, 295p.

MOREIRA, A. C. Comparação da análise de componentes principais e da CATPCA na avaliação da satisfação do passageiro de uma transportadora aérea. **Investigação Operacional**, v. 27, n. 2, p. 165-178, 2007.

MUNDOGEO. **Deteção de movimentação de terrenos por interferometria de radar de abertura sintética (InSAR) orbital**. Disponível em: <<https://mundogeo.com/2007/12/31/deteccao-de-movimentacao-de-terrenos-por-interferometria-de-radar-de-abertura-sintetica-insar-orbital/>> Acesso em: 11 nov. 2022.

NOBRE, C. A; SAMPAIO, G.; BORMA, L. S.; CASTILLA-RUBIO, J. C.; SILVA, J. S.; CARDOSO, M. Land-use and climate change risks in the Amazon and the need of a novel sustainable development paradigm. **Proceedings of the National Academy of Sciences**, v. 113, n. 39, p. 10759-10768, 2016.

OLESK, A.; PRAKS, J.; ANTROPOV, O.; ZALITE, K.; ARUMÄE, T.; VOORMANSIK, K. Interferometric SAR coherence models for characterization of hemiboreal forests using TanDEM-X data. **Remote Sensing**, v. 8, n. 9, p. 700-715, 2016.

OMAR, H.; MISMAN, M. A.; KASSIM, A. R. Synergetic of PALSAR-2 and Sentinel-1A SAR polarimetry for retrieving aboveground biomass in dipterocarp forest of Malaysia. **Applied Sciences**, v. 7, n. 7, p. 675, 2017.

PANEQUE-GÁLVEZ, J.; MAS, J.F.; MORÉ, G.; CRISTÓBAL, J.; ORTA-MARTÍNEZ, M.; LUZ, A. C.; REYES-GARCÍA, V. Enhanced land use/cover classification of heterogeneous tropical landscapes using support vector machines and textural homogeneity. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 372-383, 2013.

PAVANELLI, J. A. P.; SANTOS, J. R. D.; GALVÃO, L. S.; XAUD, M.; XAUD, H. A. M. PALSAR-2/ALOS-2 and OLI/LANDSAT-8 data integration for land use and land cover mapping in northern Brazilian Amazon. **Boletim de Ciências Geodésicas**, v. 24, n. 2, 250- 269, 2018.

PEREIRA, L. O.; FURTADO, L. F.; NOVO, E. M.; SANT'ANNA, S. J.; LIESENBERG, V.; SILVA, T. S. Multifrequency and full-polarimetric SAR assessment for estimating above ground biomass and leaf area index in the Amazon várzea wetlands. **Remote Sensing**, v. 10, n. 9, p. 1355, 2018.

PETROPOULOS, G. P.; KONTOES, C.; KERAMITSOGLOU, I. Burnt area delineation from a uni-temporal perspective based on Landsat TM imagery classification using Support Vector Machines. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 1, p. 70-80, 2011.

POPE, K. O.; REY-BENAYAS, J. M.; PARIS, J. F. Radar remote sensing of forest and wetland ecosystems in the central American tropics. **Remote Sensing of Environment**, n. 48, 205–219, 1994.

PÔSSA, É. M., GAMA, F. F., SANTOS, J. R., MURA, J. C., BISPO, P. C. Análise de uso e cobertura da terra na região do Tapajós, Amazônia central, a partir de dado polarimétrico PALSAR/ALOS-1 e coerência interferométrica TanDEM-X. **Revista Brasileira de Geografia Física**, v. 11, n. 6, p. 2094-2108, 2018.

REICHE, J.; VERBESSELT, J.; HOEKMAN, D.; HEROLD, M. Fusing Landsat and SAR time series to detect deforestation in the tropics. **Remote Sensing of Environment**, v. 156, 276-293, 2015.

RICHARDS, J.A. **Remote sensing with imaging radar**. Berlim: Springer, 2009, 361 p.

RÖDIG, E.; CUNTZ, M.; RAMMIG, A.; FISCHER, R.; TAUBERT, F.; HUTH, A. The importance of forest structure for carbon fluxes of the Amazon rainforest. **Environmental Research Letters**, v. 13, n. 5, p. 054013, 2018.

SCHWARTZ, W. R. **Segmentação de imagens baseada em dependência espacial utilizando**

campo aleatório de Markov associado com características de texturas. Dissertação de Mestrado em Informática, Universidade Federal do Paraná, 2005, 120 f.

SILVA, M.; SILVA, J. D.; BORGES, E. Análises de componentes principais para elaborar índices de desempenho no setor público. **Revista Brasileira de Biometria**, v. 33, n. 3, p. 291-309, 2015.

SOTHE, C.; ALMEIDA, C. M.; LIESENBERG, V.; SCHIMALSKI, M. B. Evaluating Sentinel-2 and Landsat-8 data to map successional forest stages in a subtropical forest in Southern Brazil. **Remote Sensing**, v. 9, n.8, p. 838, 2017.

TELESPAZIO. **Programmes – COSMO-SkyMed.** Disponível em: <<https://www.telespazio.com/en/programmes/cosmo-skymed>> Acesso em: 13 jul. 2020.

TEMPORIM, F. A.; GAMA, F. F.; MURA, J. C.; PARADELLA, W. R.; SILVA, G. G. Application of persistent scatterers interferometry for surface displacements monitoring in N5E open pit iron mine using TerraSAR-X data, in Carajás Province, Amazon region. **Brazilian Journal of Geology**, 47, 225-235, 2017.

THANH NOI, P.; KAPPAS, M. Comparison of random forest, K-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. **Sensors**, v. 18, n.1, p. 18, 2017.

TREUHART, R.; GONÇALVES, F.; SANTOS, J. R.; KELLER, M.; PALACE, M.; MADSEN, S. N.; et al. Tropical-forest biomass estimation at X-band from the spaceborne TanDEM-X interferometer. **IEEE Geoscience and Remote Sensing Letters**, v. 12, n. 2, p. 239- 243, 2015.

TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data.** Boca Raton: CRC Press, 2009, 357 p.

UHL, C.; BUSBACHER, R; SERRÃO, A. S. Abandoned pastures in eastern Amazonia. I. Patterns of plant succession. **Journal of Ecology**, v. 76, p. 663–681, 1988.

ULABY, F; LONG, D. **Microwave radar and radiometric remote sensing.** The University of Michigan Press, 2014. 1013 p.

VAN ZYL, J. J. Unsupervised classification of scattering behavior using radar polarimetry data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 27, n. 1, p. 36-45, 1989.

WEGMÜLLER, U.; SANTORO, M.; WERNER, C. On the estimation and interpretation of Sentinel-1 TOPS InSAR coherence. In: **Proceedings** of FRINGE. Workshop, Frascati, Italia. 2015. p. 23-27.

WIEDERKEHR, N. C.; GAMA, F. F.; CASTRO, P. B.; BISPO, P. D. C.; BALZTER, H.; SANO, E. E.; MURA, J. C. Discriminating Forest successional stages, forest degradation, and land use in central amazon using ALOS/PALSAR-2 full-polarimetric data. **Remote Sensing**, v. 12, p. 3512, 2020.

WOODHOUSE, I. H. **Introduction to microwave remote sensing**. Boca Raton: Taylor & Francis Group CRC Press, 2006. 370p.

YAMAGUCHI, Y.; MORIYAMA, T.; ISHIDO, M.; YAMADA, H. Four-component scattering model for polarimetric SAR image decomposition. **IEEE Transactions on Geoscience Remote Sensing**, v. 43, n. 8, p. 1699–1706, 2005.

YANG, J.; YAMAGUCHI, Y.; LEE, J. S.; TOUZI, R.; BOERNER, W. M. Applications of polarimetric SAR. **Journal of Sensors**, 2015.

YU, Y.; LI, M.; FU, Y. Forest type identification by Random Forest classification combined with SPOT and multitemporal SAR data. **Journal of Forestry Research**, v. 29, n. 5, p. 1407-1414, 2017.

ZAKERI, H.; YAMAZAKI, F.; LIU, W. Texture analysis and land cover classification of Tehran using polarimetric synthetic aperture radar imagery. **Applied Sciences**, v. 7, n. 5, p. 452, 2017.

APÊNDICE A

Comprovantes de submissão:

Revista Ciência Florestal



Bárbara Hass Kiyohara <babs.hass@gmail.com>

[Ci. Fl.] Decisão editorial

2 mensagens

Ciência Florestal <cienciaflorestal@ufsm.br>

1 de dezembro de 2022 às 14:05

Para: Bárbara Hass Kiyohara <babs.hass@gmail.com>

Bárbara Hass Kiyohara, Edson Eyji Sano:

Nós chegamos a uma decisão referente a sua submissão para o periódico Ciência Florestal, "Avaliação de dados polarimétricos e de atributos de textura em imagens SAR para discriminar a floresta secundária em uma área de domínio de floresta amazônica".

Nossa decisão é de: Aceitar a Submissão

Equipe Editorial da Ciência Florestal

Revista Ciência Florestal

<https://periodicos.ufsm.br/cienciaflorestal>

International Journal of Remote Sensing



Bárbara Hass Kiyohara <babs.hass@gmail.com>

Manuscript submission to the International Journal of Remote Sensing - Manuscript ID TRES-PAP-2022-1303

1 mensagem

International Journal of Remote Sensing <onbehalf@manuscriptcentral.com> 11 de novembro de 2022 16:37
 Responder a: IJRS-Administrator@dundee.ac.uk
 Para: babs.hass@gmail.com
 Cc: babs.hass@gmail.com, edson.sano@gmail.com

11-Nov-2022

Dear Ms. Bárbara Hass Kiyohara
 (cc'd to co-authors, if any)

Your manuscript entitled "Combining ALOS-2/PALSAR-2 full-polarimetric and COSMO-SkyMed interferometric coherence data to discriminate secondary vegetation and land use classes in a region of deforestation hotspot in the Brazilian Amazon" has been successfully submitted online and is presently being given full consideration for publication in International Journal of Remote Sensing.

Your manuscript ID is TRES-PAP-2022-1303.

Please mention the above manuscript ID in all future correspondence. If there are any changes in your contact details, please log in to the International Journal of Remote Sensing - ScholarOne Manuscripts site at <https://mc.manuscriptcentral.com/tres> and edit your user account information as appropriate.

You can also view the status of your manuscript at any time by checking the appropriate folder in your "Corresponding Author Centre" after logging in to <https://mc.manuscriptcentral.com/tres>.

The journal to which you are have submitted to is participating in the PEER project. This project, which is supported by the European Union EC eContentplus programme(http://ec.europa.eu/information_society/activities/econtentplus/index_en.htm), aims to monitor the effects of systematic self-archiving (author deposit in repositories) over time. If your submission is accepted, and you are based in the EU, you may be invited to deposit your accepted manuscript in a repository as part of this project. The project will develop models to illustrate how traditional publishing systems may coexist with self-archiving For further information please visit the PEER project website at <http://www.peerproject.eu>.

Thank you for submitting your manuscript to the International Journal of Remote Sensing.

Yours sincerely

Mrs Catherine Murray
 Administrator, International Journal of Remote Sensing
IJRS-Administrator@Dundee.ac.uk

APÊNDICE B

Artigo publicado:

Revista Brasileira de Geografia Física: “Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica”.



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: www.ufpe.br/rbgf

Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica

Bárbara Hass Miguel ¹, Edson Eyji Sano ²

¹Doutoranda em Geociências Aplicadas e Geodinâmica, Instituto de Geociências - Universidade de Brasília, Campus Darcy Ribeiro - 70910-900 - Brasília -DF, Brasil, babs.hass@gmail.com (autora correspondente)

²Chefe do Centro de Sensoriamento Remoto, Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis - IBAMA, SCEN Trecho 2, L4 Norte - 70818-900 - Brasília - DF, Brasil, edson.sano@ibama.gov.br.

Artigo recebido em 05/02/2019 e aceito em 24/05/2019

RESUMO

O objetivo do presente trabalho foi avaliar o potencial das imagens de radar do satélite Sentinel 1A (banda C) para discriminar classes representativas de uso e cobertura da terra do Distrito Federal, Brasil. As imagens de coerência interferométrica utilizadas nesse estudo foram obtidas a partir de pares de imagens *Single Look Complex* (SLC) de junho e julho de 2018. Foi gerada uma composição colorida RGB a partir de imagens de coerência, intensidade de retroespalhamento e razão de retroespalhamento. Essa imagem foi classificada pelos métodos supervisionados *Support Vector Machine* (SVM) e *Random Forest* (RF). A validação temática foi realizada por matrizes de confusão, índice Kappa e exatidão global. Nesse contexto, foram investigadas cinco classes temáticas (água, área urbana, vegetação nativa, pastagem e agricultura). O classificador RF obteve melhor desempenho classificatório (Kappa= 0,68 e exatidão global = 79,1%) que o classificador SVM (Kappa= 0,64 e exatidão global = 75,7%). A coerência mostrou-se eficiente principalmente na identificação de corpos d'água e da área urbana. Os resultados foram satisfatórios para a classificação de uso e cobertura da terra do Distrito Federal, no entanto, houve confusão entre algumas classes e erros de comissão na classe área urbana em ambas as classificações.

Palavras-chave: uso e cobertura da terra, Interferometria, coerência interferométrica, Sentinel 1A, radar, Sensoriamento Remoto.

Use and land cover classification of the Federal District, Brazil from interferometric coherence data

ABSTRACT

The aim of this study was to evaluate the potential of Sentinel 1A (C band) satellite radar images to discriminate representative classes of land use and land cover in the Federal District, Brazil. The interferometric coherence images used in this study were obtained from pairs of *Single Look Complex* images (SLC) of June and July of 2018. An RGB color composition was generated from images of coherence, backscattering intensity and backscattering ratio. This image was classified by the Supervised Methods *Support Vector Machine* (SVM) and *Random Forest* (RF). Thematic validation was performed by matrices of confusion, Kappa index and overall accuracy. In this context, five thematic classes (water, urban area, native vegetation, pasture and agriculture) were investigated. The RF classifier obtained a better classificatory performance (Kappa= 0.68 and overall accuracy = 79.1%) than the SVM classifier (Kappa= 0.64 and overall accuracy = 75.7%). The coherence was shown to be efficient mainly in the identification of water and the urban area. The results were satisfactory for the classification of use and land cover of the Federal District, however, there was confusion between some classes and errors of commission in the urban area class in both classifications.

Keywords: use and land cover, Interferometry, interferometric coherence, Sentinel 1A, radar, Remote Sensing.

Introdução

O estudo de uso e cobertura da terra é essencial para o entendimento da dinâmica ambiental e para a compreensão das possíveis implicações decorrentes de mudanças causadas pela ação antrópica. Nesse contexto, a utilização das imagens de sensores remotos na confecção de mapas de uso e cobertura da terra é uma técnica muito difundida, devido à necessidade de identificar a dinâmica espacial de mudanças sobre grandes áreas (Congalton et al., 2014).

Os sensores ópticos são mais fáceis de serem interpretados, porém, são sensíveis à visibilidade atmosférica. Este problema os torna pouco adequados à obtenção de imagens em algumas épocas do ano, devido à cobertura persistente de nuvens em algumas regiões. Já os sensores de micro-ondas, entre os quais se incluem os radares de abertura sintética (SAR), podem ser utilizados sob condições adversas de visibilidade.

As imagens SAR têm sido muito utilizadas em diversas aplicações, explorando diferentes sensores e técnicas de processamento. Tais sensores vem sendo explorados em estudos de monitoramento de enchentes (Chini et al., 2017; Schlaffer et al., 2017), áreas cobertas por gelo (Johansson et al., 2017; Wang et al., 2016), derramamento de óleo (Migliaccio et al., 2015; Skrunes et al., 2015), deslizamentos de terra (Confueorto et al., 2017), mapeamento de áreas agrícolas (Gibril et al., 2017; Erten et al., 2016), áreas urbanas (Khalil e Haque, 2018; Salentinig e Gamba, 2015), uso e cobertura da terra (Paradella et al., 2017; Baltzter et al., 2015) e estudos florestais (Minh et al., 2016).

Os sensores que operam com maiores comprimentos de onda (bandas C, L e P) permitem maior penetração do sinal, e consequentemente registram informações sobre a estrutura volumétrica dos alvos. Já os sensores de ondas menos longas (banda X) interagem mais superficialmente com a estrutura do alvo, sendo mais utilizados em estudos de detecção de alvos. Contudo, é necessário aprimorar técnicas de processamento desses dados, entre as quais encontra-se a interferometria (Khalil e Haque, 2018; Pôssa et al., 2018).

A interferometria SAR (InSAR) está baseada na combinação de duas imagens SAR, adquiridas sobre a mesma área, com uma geometria de aquisição ligeiramente diferente uma da outra, para garantir o efeito de interferometria, ou diferença de fase (Temporim et al., 2017).

A comparação entre as diferenças de fase de duas imagens de uma mesma região, obtidas a partir de antenas com ligeira diferença de geometria, torna possível encontrar as localizações dos pixels em três dimensões. A diferença de fase entre pixels de mesma coordenada nas imagens está relacionada à distância entre as duas trajetórias de pulsos de energia eletromagnética durante as aquisições (linha-base) e a altitude correspondente no solo. Por meio destes dados também pode-se gerar imagens de coerência interferométrica, muito úteis para fins de classificação (Olesk et al., 2016; Wegmüller et al., 2015).

Cada pixel de uma imagem de coerência representa a informação do módulo do coeficiente de correlação complexa de um par interferométrico. Este tipo de produto pode contribuir para a estratificação temática da paisagem, considerando que regiões florestadas apresentam baixa coerência interferométrica, em razão da instabilidade dos componentes florestais quando comparados a outras tipologias de uso e cobertura da terra, como, pastagem, solo exposto e regiões de vegetação esparsa (Olesk et al., 2016).

Combinando interferometria e polarimetria, que nada mais é que a natureza vetorial das ondas eletromagnéticas dos alvos imageados, é possível maximizar a coerência interferométrica, que é a medida da correlação entre as duas imagens utilizadas no processamento interferométrico. A coerência também é um indicativo da qualidade de fase do interferograma, visando a geração de modelos de elevação mais precisos (Mohammadimanesh et al., 2018; Pôssa et al., 2018).

Dessa forma, o objetivo desse estudo é avaliar o potencial das imagens de coerência interferométrica do Sentinel 1A, banda C, para discriminar classes representativas de uso e cobertura da terra do Distrito Federal. As imagens de coerência interferométrica utilizadas nesse estudo foram obtidas a partir de pares de imagens *Single Look Complex* (SLC) de junho e julho de 2018.

Caracterização da área de estudo

A área de estudo, com uma extensão de 2.862,26 km², corresponde à porção noroeste do Distrito Federal (DF) (Figura 1). A área selecionada engloba a cidade de Brasília, o Lago Paranoá, o Parque Nacional de Brasília, a Reserva Ecológica do IBGE, dentre outras feições.

O DF está localizado na região central do Brasil, onde são encontradas chapadas elevadas e nascentes de três das oito grandes bacias

hidrográficas brasileiras: Paraná, Tocantins e São Francisco (Neves et al., 2015).




Figura 1. Localização da área de estudo.

A localização do DF evidencia a heterogeneidade de suas paisagens e consequentemente de sua apropriação pelo homem, com a concentração de áreas urbanas e o predomínio de agricultura de larga escala ao longo de sua área. A vegetação do DF é representativa do bioma Cerrado, isto é, apresenta um mosaico heterogêneo de formações campestres, savânicas e florestais (Marengo, 2010).

O clima predominante na área de estudo é a tropical com estações seca e chuvosa bem definidas (tipo Aw na classificação climática de Köppen), com temperaturas médias mensais superiores a 18 °C e precipitação média anual de

1.540 mm, concentrados entre os meses de outubro e abril (Marengo, 2010).

Material e métodos

Dados utilizados

Neste trabalho, foram utilizadas imagens do Sentinel 1A (nível de processamento: SLC) da Agência Espacial Europeia (ESA), obtidas em 12 de junho e 18 de julho de 2018 (Tabela 1). Os dados foram processados no *Sentinel Application Platform* (SNAP) da ESA.

Tabela 1. Características das imagens Sentinel 1A.

Atributos	Sentinel 1A
Datas de aquisição	12/06/2018 e 18/07/2018
Modo	IW
Órbita	Descendente
Largura de faixa	250 km
Comprimento de onda (cm)	~ 30
Polarização	VV/VH
Ângulo de incidência	~ 20° - 45°
Resolução radiométrica	16 bits
Resolução espacial (m)	5 x 20

Processamento de dados SAR

Primeiramente, as imagens passaram pelo processo de *split* e correção de órbita, selecionando-se uma subárea menor, para minimizar o esforço computacional. Nas etapas de geocodificação das imagens, foi utilizado o modelo digital de elevação obtido pelo *Shuttle Radar*

Topography Mission (SRTM). Nesta operação, os dados foram georreferenciados para o referencial geodésico WGS84 e reamostrados para uma resolução de 15 m por meio de uma interpolação bilinear. Ambas as imagens SAR foram convertidas para coeficiente de retroespalhamento (σ^0 , unidade em decibéis - dB) (Figura 2).




Figura 2. Fluxograma das etapas do processamento de dados SAR.

A coerência γ de duas imagens SAR complexas é definida de acordo com a seguinte equação:

$$\gamma = \frac{E\{uv^*\}}{\sqrt{E\{|u|^2\}E\{|v|^2\}}}$$

Onde E é o valor esperado, u e v são as duas imagens complexas coregistradas e v^* é o complexo conjugado de v (Wegmüller et al., 2015). O tamanho da janela de intervalo de coerência foi definido como 10 e o tamanho da janela de azimute de coerência foi de 1.

Em seguida, procederam-se as operações *deburst* para fundir as subfaixas de cada imagem e *multilooking* para converter as imagens de alcance inclinado em alcance no terreno. Para atenuar o ruído (*speckle*) das imagens, aplicou-se o filtro passa-baixa *Refined-Lee*, com uma janela de 5x5 (Lee, 1981; Pôssa et al., 2018). O *speckle* é um efeito multiplicativo e surge em razão da natureza coerente das ondas utilizadas no processo de aquisição, que ao interagirem com os diversos alvos independentes no terreno, podem sofrer interferências construtivas ou destrutivas, causando bruscas variações nos níveis de cinza da cena. Por fim, na etapa de ortorretificação, aplicou-se uma correção de terreno *Range-Doppler*.

Classificação e Validação

Dos processamentos mencionados no item anterior, foram geradas três imagens: "coerência", "intensidade de retroespalhamento (*backscatter*)" e "razão de retroespalhamento". A razão de retroespalhamento foi gerada pois destaca as áreas onde ocorreu alguma mudança entre as datas das imagens (Khalil e Haque, 2018; Chini et al., 2017). A razão entre as duas imagens de intensidade de

retroespalhamento foi calculada de acordo com a seguinte equação:

$$\text{Mudança ou razão [dB]} = \left| 10 \cdot \log \frac{i_2}{i_1} \right|$$

Onde i_1 e i_2 são duas imagens de intensidade de retroespalhamento.

Esta composição RGB foi submetida à duas classificações supervisionadas: *Support Vector Machine* (SVM) e *Random Forest* (RF). Os algoritmos de aprendizagem de máquina SVM têm como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (Zhang et al., 2016; Kumar et al., 2015).

Já o algoritmo de aprendizagem supervisionado RF consiste em uma coleção ou conjunto de preditores de uma árvore de decisões simples, capaz de produzir uma resposta quando apresentado com um conjunto de valores preditores. Para problemas de classificação, essa resposta assume a forma de uma associação de classe, que associa ou classifica um conjunto de valores preditores independentes a uma das categorias presentes na variável dependente. Em problemas de regressão, a resposta da árvore é uma estimativa da variável dependente dados os preditores (Belgiu e Drăgut., 2016).

Para examinar a eficiência do sensor Sentinel 1A em discriminar as diferentes características da imagem, foram definidas cinco classes de uso e cobertura da terra: área urbana, água, vegetação, pastagem e agricultura (Tabela 2):

Tabela 2. Descrição das classes de uso e cobertura da terra.

Classes	Descrição
Área urbana	Cidades consolidadas e condomínios habitacionais em consolidação.
Água	Corpos d'água (lagos e reservatórios).
Vegetação nativa	Áreas ocupadas por matas nativas de porte arbóreo.
Pastagem	Áreas campestres.
Agricultura	Áreas de cultivo perene ou permanente.

A seleção de amostras de treinamento de cada classe temática foi realizada utilizando-se de pontos de amostragem de uma imagem Sentinel-2 do dia 27 de julho de 2018 da área de estudo. A validação da classificação foi feita através da coleta de amostras de treinamento. Foram coletadas

amostras em uma composição colorida R11G8G5 de 10 m de resolução espacial. Essas bandas correspondem aos canais SWIR, NIR e vermelho do Sentinel-2, respectivamente.

Parte do conjunto amostral destinou-se ao treinamento do algoritmo de classificação,

enquanto outro conjunto de amostras foi destinado à validação do mapeamento, conforme descrito a Tabela 3.

Tabela 3. Número de pixels selecionados para cada classe.

Treinamento	Classes	Número de pixels	Validação	Classes	Número de pixels
	AU	27030		AU	9366
	AG	33205		AG	2239
	VN	18073		VN	1759
	PA	9698		PA	6543
	AR	1994		AR	1732

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

A banda 11 do Sentinel-2, naturalmente de 20 m de resolução precisou passar por um processo de reamostragem de pixels por vizinho mais próximo. Além dessa etapa, foi realizada a correção atmosférica da imagem através do algoritmo *Sen2Cor* dentro da plataforma SNAP.

Por fim, a acurácia da classificação supervisionada foi avaliada através de uma matriz de confusão, do índice *Kappa* e da exatidão global, baseando-se no conjunto amostral de referência para validação (Congalton e Green, 2012).

Resultados e discussão

Composição RGB

A composição RGB colorida, utilizada como referência no processo de classificação, foi gerada a partir das imagens de polarização VV. Essa escolha se sucedeu, pois, sabe-se que as co-polarizações (VV) estão mais relacionadas com a rugosidade da superfície (espalhamento superficial) e as polarizações cruzadas (VH) estão mais relacionadas com o espalhamento, dessa forma apresentam mais ruídos na imagem. Para a composição, colocou-se a imagem de intensidade de retroespalhamento, ou seja, a intensidade de retorno do sinal, no canal vermelho, a imagem de razão de intensidade de retroespalhamento no canal verde e a imagem de coerência no canal azul (Khalil e Haque, 2018). (Figura 3).

Os coeficientes médios de retroespalhamento (σ^0) foram identificados para as cinco principais classes de uso e cobertura da terra

da área de estudo: água, área urbana, vegetação nativa, pastagem e agricultura. A Figura 4 apresenta a distribuição dos valores de retroespalhamento (*backscatter*) para cada classe de cobertura da terra de acordo com a data da imagem e a respectiva polarização da imagem, segundo os resultados da classificação SVM.

Observou-se que a classe água apresentou os menores valores de intensidade de retroespalhamento. A maioria dos pixels ficaram situados na faixa de -19 a -17 dB na imagem do dia 12 de junho e -22 a -20 dB na imagem do dia 18 de julho. As classes agricultura e pastagem também apresentaram baixa intensidade de retroespalhamento, porém um pouco mais alta que os corpos d'água devido ao envolvimento da rugosidade da superfície do solo, variando de -18 a -10 dB de forma dominante para ambas as datas. Devido à homogeneidade relativamente alta, tanto a classe água como as classes que possuem áreas sem vegetação apresentaram baixos valores de coeficiente de retroespalhamento médio. Os valores mais altos foram observados nas áreas de vegetação, variando proeminentemente de -10 a -7 dB e -7 a -5 dB, respectivamente. Observa-se também que os valores de retroespalhamento são bem menores nas imagens de polarização VH. Esse aspecto pode ser identificado principalmente nas áreas sem vegetação, pois elas aparecerem mais escuras (menor σ^0) nas imagens de polarização cruzada VH, indicando um domínio do espalhamento superficial (Lin et al., 2017).




Figura 3. Composição colorida R (retroespalhamento VV) G (razão de retroespalhamento VV) B (coerência VV) de imagens Sentinel 1A.

Análise da classificação supervisionada SVM

Esses gráficos esclarecem como é bastante difícil discriminar as áreas urbanas de vegetação utilizando apenas o coeficiente de retroespalhamento. Dessa forma, a informação de coerência também foi incluída na composição RGB, junto a intensidade e razão de retroespalhamento, para distinguir as características da cobertura terrestre mais proeminente na classificação SVM.

A Figura 5 apresenta o padrão de distribuição da coerência para as diferentes classes de cobertura terrestre para a classificação SVM. Os valores mais altos foram observados para a classe área urbana, enquanto valores mais baixos foram observados para a pastagem, vegetação, agricultura e corpos d'água, respectivamente.

O valor de coerência varia de 0 a 1, sendo inversamente correlacionada com o grau de aleatoriedade dos dispersores entre as duas imagens SAR interferentes. Isto diminui com o movimento ou alterações físicas dos espalhadores, por exemplo, as áreas de vegetação ou floresta, entretanto, os alvos artificiais como as áreas urbanas podem permanecer coerentes por um

período relativamente mais longo, resultando em maior correlação (Lazecky et al., 2017; Watanabe et al., 2016).

De acordo com o resultado da classificação SVM (Figura 6), a maior parte da área de estudo é composta pela classe “vegetação”, com 45,4% do total da área, seguida pela classe “pastagem” com 41,3% do total. Já as outras classes apresentaram áreas bem menores. A classe “área urbana” apresenta 9% do total, seguida pela classe “agricultura” com 2,4% e o restante, cerca de 1,9% do total da área de estudo pertence à classe “água”.

A exatidão global e o índice Kappa da imagem classificada foram de 75,7% e 0,64, respectivamente. É possível notar algumas diferenças de contraste entre as classes de uso e cobertura da terra, principalmente nas classes “área urbana” e “água” na composição RGB. Esse destaque é previsível conforme já mencionado nos estudos de Strozzi et al. (2000) e Stehman (1997). A matriz de confusão está apresentada na Tabela 4.




Figura 4. Box Plot da distribuição das intensidades de retroespalhamento de acordo com a classificação SVM da cobertura e do uso da terra do Distrito Federal.

Revista Brasileira de Geografia Física v.12, n.02 (2019) 427-442.




Figura 5. Distribuição da coerência das classes de uso e cobertura da terra de acordo com a classificação SVM nas polarizações VH e WV.




Figura 6. Resultado da classificação supervisionada de imagens do Sentinel-1A pelo algoritmo SVM.

Tabela 4. Matriz de confusão da classificação SVM do uso e cobertura da terra em [%].

	AG	AU	VG	PA	AR	Acurácia do usuário
AG	100	0	0	0	0	100
AU	0	53,29	1,81	0,96	4,5	96,21
VN	0	11,54	94,62	3,48	0	88,67
PA	0	17,91	1,89	84,41	27,73	16,66
AR	0	17,26	1,67	11,16	67,77	18,30
Acurácia do produtor	100	53,29	94,62	84,41	67,77	

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

De acordo com a matriz de confusão da classificação SVM, as classes “água” e “vegetação” obtiveram a maior acurácia, enquanto as classes “área urbana” e “agricultura” foram as classes que apresentaram as maiores confusões. O classificador não conseguiu detectar a diferença entre as classes “agricultura” e “pastagem”. Enquanto que para a classe “área urbana” houve erros de comissão de praticamente todas as classes, com exceção da classe “água”.

Análise da classificação supervisionada RF

A Figura 7 apresenta a distribuição dos valores de retroespalhamento para cada classe de cobertura da terra de acordo com a data da imagem e a respectiva polarização da imagem, segundo os resultados da classificação RF.

Os valores de coeficiente de retroespalhamento para cada classe, segundo a classificação RF foram muito semelhantes aos valores das classes para a classificação SVM. Não havendo grande diferença entre os valores.

Novamente, observa-se que os dados de intensidade de retroespalhamento da banda C não são apropriados para a separação das classes de cobertura terrestre, exceto para algumas áreas urbanizadas que possuem espalhadores artificiais, podendo ser separados devido aos altos valores do coeficiente de retroespalhamento e a corpos d'água superficiais devido aos valores muito baixos de retroespalhamento (Paradella et al., 2017; Alcântara et al., 2016).

A Figura 8 apresenta o boxplot com o padrão de distribuição da coerência para as diferentes classes de cobertura terrestre segundo a classificação RF. Os valores mais altos também foram observados para a classe “área urbana”, enquanto valores mais baixos foram observados para a pastagem, vegetação, agricultura e corpos d'água, respectivamente, seguindo o mesmo padrão que a classificação SVM (Olesk et al., 2015).




Figura 7. Box Plot da distribuição das intensidades de retroespalhamento de acordo com a classificação RF da cobertura e do uso da terra do Distrito Federal.




Figura 8. Distribuição da coerência das classes de uso e cobertura da terra de acordo com a classificação RF nas polarizações VH e VV.

A área de estudo apresentou um valor de coerência médio muito baixo em ambas as classificações, devido principalmente à cobertura vegetal dominante na área (Olesk et al., 2016). Nesse contexto, é preciso ressaltar que as imagens utilizadas nesse estudo correspondem a estação seca do Distrito Federal, que se inicia em maio e termina em setembro e, consequentemente, muitas árvores perdem as suas folhas, mudando os padrões de vegetação para se adequar a estação sem chuvas.

Os resultados mostram que o uso de coerência interferométrica contribuiu para uma melhor classificação de uso da terra e identificação

de mudanças temporais, em relação ao uso somente de coeficiente de retroespalhamento e razão de retroespalhamento (Wegmüller et al., 2015).

De acordo com a classificação RF (Figura 9), a maior parte da área de estudo é composta pela classe “vegetação”, com 34,72% do total da área, seguida pela classe “área urbana” com 26,3% do total e “pastagem” com 24,1% do total. Já as classes agricultura e água apresentaram áreas bem menores, com 13,12% e 1,76% do total da área respectivamente.




Figura 9. Resultado da classificação supervisionada de imagens do Sentinel 1A pelo algoritmo RF.

Comparando os resultados das duas classificações (Tabela 5), nota-se que a classificação RF apresentou uma área de pastagem quase seis vezes maior e uma área urbana três vezes maior que a classificação SVM detectou, enquanto isso, as classes vegetação nativa e pastagem foram

bem menos representativas na classificação RF do que na classificação SVM.

Já a classe água permaneceu praticamente com a mesma área nas duas classificações.

Tabela 5. Comparação das classificações SVM e RF.

Classes	Área – SVM [km ²]	Porcentagem [%]	Área – RF [km ²]	Porcentagem [%]
AU	257,64	9	753,126	26,3
AG	54,595	1,9	50,457	1,76
VN	1301,5	45,4	993,791	34,72
PA	1182	41,3	689,179	24,1
AR	68,282	2,4	375,71	13,12

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

A exatidão global e o índice Kappa da imagem classificada pelo algoritmo RF foram de 79,1% e 0,68, respectivamente. A classificação RF obteve um desempenho melhor que a classificação pelo algoritmo SVM, pois apresentou valores de índice Kappa e exatidão global um pouco superior (Kussul et al., 2017; Du et al., 2015).

Adam et al. 2014, ao compararem o desempenho dos algoritmos SVM e RF para a classificação do uso e cobertura da terra também obtiveram desempenhos similares nestes dois algoritmos, sendo que a maior acurácia foi alcançada pelo RF.

Segundo a matriz de confusão apresentada na Tabela 6, as classes “agricultura” e “pastagem” apresentaram as maiores confusões entre as classes, assim como na classificação SVM.

Já as classes “água” e “vegetação nativa” apresentaram a maior acurácia. Comparando com a classificação SVM, a classe “área urbana” apresentou menos erros de comissão, apesar de

apresentar uma área maior para essa classe do que a classificação SVM.

Os resultados indicaram que a combinação de coerência com intensidade de retroespalhamento contribuiu para uma classificação de uso e cobertura da terra considerada boa (Kappa 0,61~0,80) tanto para RF como para o SVM, de acordo com a classificação de Congalton e Green (2012).

Tabela 6 - Matriz de confusão da classificação RF do uso e cobertura da terra em [%].

	AG	AU	VG	PA	AR	Acurácia do usuário
AG	98,91	0	0	0	0	100
AU	1,09	67,34	1,68	1,73	4,8	97,77
VN	0	8,1	94,32	1,33	0	88,58
PA	0	12,67	2,52	85,86	27,64	16,35
AR	0	11,89	1,47	11,07	67,55	18,5
Acurácia do produtor	98,91	67,34	94,32	85,86	67,55	

AU = Área urbana; AG = água; VN = Vegetação nativa; PA = Pastagem; AR = Agricultura.

Conclusões

O presente estudo avaliou o potencial da coerência interferométrica do Sentinel 1A para a classificação do uso e cobertura da terra do Distrito Federal. A análise e os resultados do estudo indicaram que a combinação de coerência, intensidade de retroespalhamento e razão de retroespalhamento pode ser efetivamente utilizada como uma composição colorida para a discriminação das diferentes classes de uso e cobertura da terra.

Os resultados mostraram o bom potencial da coerência interferométrica do Sentinel 1A para a classificação supervisionada SVM, apresentando um índice kappa de 0,64 e 75,7% de exatidão global e também para a classificação RF, com índice Kappa de 0,68 e exatidão global de 79,4%. Nesse estudo, o algoritmo RF apresentou um melhor desempenho que o algoritmo SVM.

A imagem de coerência mostrou-se eficiente principalmente na identificação de corpos d'água e da área urbana na imagem, entretanto, houve confusão entre as áreas agrícolas e de pastagem e erros de comissão na classe área urbana para ambas as classificações.

Nesse contexto, os resultados enfatizaram que o uso de coerência interferométrica contribuiu para uma melhor classificação de uso da terra e

identificação de mudanças temporais, em relação ao uso somente de coeficiente de retroespalhamento e razão de retroespalhamento.

Sugere-se que futuras pesquisas sejam realizadas com imagens do Sentinel 1A e Sentinel 1B para aprimorar ou formular novas técnicas.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsa de Desenvolvimento Tecnológico e Industrial (DTI) à primeira autora.

Referências

- Adam, E., Mutanga, O., Odindi, J., & Abdel-Rahman, E. M., 2014. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing* 35, 3440-3458.
- Alcântara, E., Watanabe, F., Rodrigues, T., Bernardo, N., Rotta, L., Carmo, A., Imai, N., 2016. Field measurements of the backscattering coefficient in a cascading reservoir system: first results from Nova Avanhandava and Barra Bonita Reservoirs

- (São Paulo, Brazil). *Remote Sensing Letters* 7, 417-426.
- Balzter, H., Cole, B., Thiel, C., Schmullius, C., 2015. Mapping CORINE land cover from Sentinel-1A SAR and SRTM digital elevation model data using random forests. *Remote Sensing* 7, 14876-14898.
- Belgic, M., Drăguț, L., 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114, 24-31.
- Chini, M., Hostache, R., Giustarini, L., Matgen, P., 2017. A hierarchical split-based approach for parametric thresholding of SAR images: Flood inundation as a test case. *IEEE Transactions on Geoscience and Remote Sensing* 55, 6975-6988.
- Confuorto, P., Di Martire, D., Centolanza, G., Iglesias, R., Mallorqui, J. J., Novellino, A., Calcaterra, D., 2017. Post-failure evolution analysis of a rainfall-triggered landslide by multi-temporal interferometry SAR approaches integrated with geotechnical analysis. *Remote sensing of environment* 188, 51-72.
- Congalton, R. G., Green, K., 2012. Assessing the accuracy of remotely sensed data: principles and practices. Second edition. CRC press, pp 174.
- Congalton, R. G., Gu, J., Yadav, K., Thenkabail, P., Ozdogan, M., 2014. Global land cover mapping: A review and uncertainty analysis. *Remote Sensing* 6, 12070-12093.
- Du, P., Samat, A., Waske, B., Liu, S., & Li, Z., 2015. Random forest and rotation forest for fully polarized SAR image classification using polarimetric and spatial features. *ISPRS Journal of Photogrammetry and Remote Sensing* 105, 38-53.
- Erten, E., Lopez-Sanchez, J. M., Yuzugullu, O., Hajnsek, I., 2016. Retrieval of agricultural crop height from space: A comparison of SAR techniques. *Remote Sensing of Environment* 187, 130-144.
- Gibril, M. B. A., Bakar, S. A., Yao, K., Idrees, M. O., Pradhan, B., 2017. Fusion of RADARSAT-2 and multispectral optical remote sensing data for LULC extraction in a tropical agricultural area. *Geocarto international* 32, 735-748.
- Johansson, A. M., King, J. A., Doulgeris, A. P., Gerland, S., Singha, S., Spreen, G., Busche, T., 2017. Combined observations of Arctic sea ice with near-coincident colocated X-band, C-band, and L-band SAR satellite remote sensing and helicopter-borne measurements. *Journal of Geophysical Research: Oceans* 122, 669-691.
- Khalil R. Z., Haque, S. 2018. InSAR coherence-based land cover classification of Okara, Pakistan. *The Egyptian Journal of Remote Sensing and Space Science* 21, S23-S28.
- Kumar, P., Gupta, D. K., Mishra, V. N., Prasad, R., 2015. Comparison of support vector machine, artificial neural network, and spectral angle mapper algorithms for crop classification using LISS IV data. *International Journal of Remote Sensing* 36, 1604-1617.
- Kussul, N., Lavreniuk, M., Skakun, S., Shelestov, A., 2017. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters* 14, 778-782.
- Lazecky, M., Hlavacova, I., Bakon, M., Sousa, J. J., Perissin, D., Patricio, G., 2017. Bridge displacements monitoring using space-borne X-band SAR interferometry. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10, 205-210.
- Lee, J.S., 1981. Speckle Analysis and Smoothing of Synthetic Aperture. *Computer Graphics and Image Processing* 17, 24-32.
- Lin, B., Shao, W., Li, X., Li, H., Du, X., Ji, Q., Cai, L., 2017. Development and validation of an ocean wave retrieval algorithm for VV-polarization Sentinel-1 SAR data. *Acta Oceanologica Sinica* 36, 95-101.
- Marengo, J. A., 2010. Vulnerabilidade, impactos e adaptação à mudança do clima no semiárido do Brasil. *Parcerias Estratégicas* 13, 149-176.
- Migliaccio, M., Nunziata, F., Buono, A., 2015. SAR polarimetry for sea oil slick observation. *International Journal of Remote Sensing* 36, 3243-3273.
- Minh, D. H. T., Le Toan, T., Rocca, F., Tebaldini, S., Villard, L., Réjou-Méchain, M., Chave, J., 2016. SAR tomography for the retrieval of forest biomass and height: Cross-validation at two tropical forest sites in French Guiana. *Remote Sensing of Environment* 175, 138-147.
- Mohammadimanesh, F., Salehi, B., Mahdianpari, M., Motagh, M., Brisco, B., 2018. An efficient feature optimization for wetland mapping by synergistic use of SAR intensity, interferometry, and polarimetry data. *International journal of applied earth observation and geoinformation* 73, 450-462.

- Neves, G., Sena-Souza, J. P., Gomes, M. P., Reatto, A., Nardoto, G. B., de Souza Martins, É., Junior, A. F. C., 2015. Relação entre a dinâmica da expansão das atividades agropastoris e o relevo da bacia hidrográfica do rio São Bartolomeu, Planalto Central Brasileiro. Anais... XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE, 2015-2022.
- Olesk, A., Praks, J., Antropov, O., Zalite, K., Arumäe, T., Voormansik, K., 2016. Interferometric SAR coherence models for characterization of hemiboreal forests using TanDEM-X data. *Remote Sensing* 8, 700-715.
- Olesk, A., Voormansik, K., Vain, A., Noorma, M., Praks, J., 2015. Seasonal differences in forest height estimation from interferometric TanDEM-X coherence data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8, 5565-5572.
- Paradella, W. R., dos Santos, A. R., Veneziani, P., Morais, M. C., 2017. Synthetic Aperture Radar for geological applications in the moist tropics: experiences from the Brazilian Amazon region. *Revista Brasileira de Geociências* 30, 538-542.
- Pôssa, E. M., Gama F. F., Santos J. R., Mura, J. C., Bispo, P. C., 2018. Análise de uso da terra e cobertura florestal na Amazônia central, a partir de dado polarimétrico PALSAR/ALOS-1 e coerência interferométrica TanDEM-X. *Revista Brasileira de Geografia Física* 11, 2094-2108.
- Salentinig, A., Gamba, P., 2015. Combining SAR-based and multispectral-based extractions to map urban areas at multiple spatial resolutions. *IEEE Geoscience and Remote Sensing Magazine* 3, 100-112.
- Schlaffer, S., Chini, M., Giustarini, L., Matgen, P., 2017. Probabilistic mapping of flood-induced backscatter changes in SAR time series. *International Journal of Applied Earth Observation and Geoinformation* 56, 77-87.
- Skrunes, S., Brekke, C., Eltoft, T., Kudryavtsev, V., 2015. Comparing near-coincident C-and X-band SAR acquisitions of marine oil spills. *IEEE Transactions on Geoscience and Remote Sensing* 53, 1958-1975.
- Stehman, S. V., 1997. Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment* 62, 77-89.
- Strozzi, T., Dammert, P. B., Wegmüller, U., Martinez, J. M., Askne, J. I., Beaudoin, A., Hallikainen, N. T., 2000. Land use mapping with ERS SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing* 38, 766-775.
- Temporim, F. A., Gama, F. F., Mura J. C., Paradella, W. R., Silva, G. G., 2017. Application of persistente scatterers interferometry for surface displacements monitoring in NSE open pit iron mine using TerraSAR-X data, in Carajás Province, Amazon region. *Brazilian Journal of Geology* 47, 225-235.
- Wang, L., Scott, K. A., Xu, L., Clausi, D. A., 2016. Sea ice concentration estimation during melt from dual-pol SAR scenes using deep convolutional neural networks: A case study. *IEEE Transactions on Geoscience and Remote Sensing* 54, 4524-4533.
- Watanabe, M., Thapa, R. B., Ohsumi, T., Fujiwara, H., Yonezawa, C., Tomii, N., Suzuki, S., 2016. Detection of damaged urban areas using interferometric SAR coherence change with PALSAR-2. *Earth, Planets and Space* 68, 131.
- Wegmüller, U., Santoro, M., Werner, C., 2015. On the estimation and interpretation of Sentinel-1 TOPS InSAR coherence. In: *Proceedings of FRINGE, ESA SP. European Space Agency*.
- Zhang, Y., Lu, S., Zhou, X., Yang, M., Wu, L., Liu, B., Wang, S. 2016. Comparison of machine learning methods for stationary wavelet entropy-based multiple sclerosis detection: decision tree, k-nearest neighbors, and support vector machine. *Simulation* 92, 861-871.

APÊNDICE C

Código de extração de NDVI e EVI temporal para imagens Landsat 5, 7 e 8 no *Google Earth Engine*

```

var app = function (image)
{
  //Índice de Vegetação
  var ndvi = image.normalizedDifference(['B5', 'B4']);
  image = image.addBands(ndvi.rename('NDVI'));

  var evi = image.expression(
    '2.5 * (nir - red) / (nir + 6 * red - 7.5 * blue + 1)',
    {
      red: image.select('B4'), // 620-670nm, RED
      nir: image.select('B5'), // 841-876nm, NIR
      blue: image.select('B2') // 459-479nm, BLUE
    });
  image = image.addBands(evi.rename('EVI'));

  //var savi = image.expression(
  // '1.5 * (nir - red) / (nir + red + 0.5)',
  //{
  // red: image.select('B4'), // 620-670nm, RED
  // nir: image.select('B5'), // 841-876nm, NIR
  //});
  //image = image.addBands(savi.rename('SAVI'));

  return (image);
}

//Coleção de imagens
var OLI = ee.ImageCollection('LANDSAT/LC08/C01/T1_RT_TOA')
  .filterDate('2013-04-01', '2017-08-01')
  .filterMetadata('CLOUD_COVER', 'less_than', 2)
  .map(app);

//Gráficos
var lon = ui.Label();
var lat = ui.Label();

Map.onClick(function(coords)
{

```

```

// Update the lon/lat panel with values from the click event.
lon.setValue('lon: ' + coords.lon.toFixed(2)),
lat.setValue('lat: ' + coords.lat.toFixed(2));

// Add a red dot for the point clicked on.
var point = ee.Geometry.Point(coords.lon, coords.lat);
var chart = ui.Chart.image.series(OLI.select('NDVI', 'EVI'), point);
chart.setOptions
({
  title: 'Vegetation Index',
  vAxis: {title: 'Value'},
  hAxis: {title: 'date', format: 'MM-yy', gridlines: {count: 7}},
});

// Add the chart to the map.
chart.style().set
({
  position: 'bottom-right',
  width: '500px',
  height: '300px'
});
Map.add(chart);
})

//Colorindo o mapa
var palette = ['FFFFFF', 'CE7E45', 'DF923D', 'F1B555', 'FCD163', '99B718',
              '74A901', '66A000', '529400', '3E8601', '207401', '056201',
              '004C00', '023B01', '012E01', '011D01', '011301'];

//Show Map
Map.addLayer(OLI.median(), {bands: 'B6,B5,B4'}, 'OLI')
Map.addLayer(OLI.median(), {min: 0, max: 1, bands:['NDVI'], palette: palette}, 'NDVI');
Map.addLayer(OLI.median(), {min: 0, max: 1, bands:['EVI'], palette: palette}, 'EVI');
//Map.addLayer(OLI.median(), {min: 0, max: 1, bands:['SAVI'], palette: palette}, 'SAVI');

```