



UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ANÁLISE DE INUNDAÇÕES E CLASSIFICAÇÃO DA COBERTURA  
VEGETAL NO BIOMA AMAZÔNICO USANDO SÉRIES TEMPORAIS  
SENTINEL-1 SAR E TÉCNICAS DE DEEP LEARNING**

**Tese de Doutorado**

**Ivo Augusto Lopes Magalhães**

Brasília, agosto de 2022

UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ANÁLISE DE INUNDAÇÕES E CLASSIFICAÇÃO DA COBERTURA  
VEGETAL NO BIOMA AMAZÔNICO USANDO SÉRIES TEMPORAIS  
SENTINEL-1 SAR E TÉCNICAS DE DEEP LEARNING**

Ivo Augusto Lopes Magalhães

Orientador: Osmar Abílio de Carvalho Júnior

Tese de Doutorado

Brasília/DF, agosto de 2022

UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE CIÊNCIAS HUMANAS  
DEPARTAMENTO DE GEOGRAFIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**ANÁLISE DE INUNDAÇÕES E CLASSIFICAÇÃO DA COBERTURA  
VEGETAL NO BIOMA AMAZÔNICO USANDO SÉRIES TEMPORAIS  
SENTINEL-1 SAR E TÉCNICAS DE DEEP LEARNING**

Ivo Augusto Lopes Magalhães

Tese de doutorado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários à obtenção do Grau de Doutor em Geografia, área de concentração: Gestão Ambiental e Territorial.

Aprovado por:

---

Prof. Dr. Osmar Abílio de Carvalho Júnior (GEA/UnB)

(Orientador)

---

Prof. Dr. Edson Eyji Sano (EMBRAPA)

(Examinador Externo)

---

Prof. Dr. Alexandre Rosa dos Santos (UFES)

(Examinador Externo)

---

Prof. Dr. Alexandre Cândido Xavier (UFES)

(Examinador Interno)

---

Prof. Dr. Renato Fontes Guimarães

(Suplente)

Brasília/DF, 05 de agosto de 2022

## FICHA CATALOGRÁFICA

MAGALHÃES, IVO AUGUSTO LOPES.

Análise de inundações e classificação da cobertura vegetal no bioma Amazônico usando séries temporais Sentinel – 1 SAR e técnicas de Deep Learning, 122 p., (UnB-IH-GEA, Doutor, Gestão Ambiental e Territorial, 2022).

Tese de Doutorado – Universidade de Brasília. Departamento de Geografia.

1. Áreas Inundáveis

2. Sensoriamento Remoto

3. Deep Learning

4. Recursos florestais

1. UnB-IH-GEA

II. Título (série)

## REFERÊNCIA BIBLIOGRÁFICA

MAGALHÃES, I. A. L. **Análise de inundações e classificação da cobertura vegetal no bioma Amazônico usando séries temporais Sentinel – 1 SAR e técnicas de Deep Learning**. 2022. 122p. Tese (Doutorado em Geografia) – Instituto de Ciências Humanas, Universidade de Brasília, Distrito Federal, 2022.

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva os direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem a autorização por escrito do autor.

---

Ivo Augusto Lopes Magalhães

## **DEDICATÓRIA**

Dedico este trabalho aos meus queridos pais,  
Minha irmã e a família Lopes Magalhães.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus por me conceder saúde, sabedoria e bom ânimo em todas as etapas do curso de Doutorado.

Agradeço ao meu professor orientador Dr. Osmar Abílio de Carvalho Júnior pelos conhecimentos científicos, liberdade, autonomia na pesquisa, pelos conselhos e dedicação nesse longo período de aprendizagem e convivência.

Agradeço ao professor Dr. Edson Eyji Sano pelos ensinamentos transmitidos em sensoriamento remoto com Imagens SAR, e também pela paciência, dedicação e amizade verdadeira construída des do Simpósio de Sensoriamento remoto em Santos.

Agradeço aos professores da UnB que tive o prazer de conhecer, em especial aos Professores Renato Fontes Guimarães e Roberto Gomes.

Aos amigos e colegas de trabalho do Laboratório de Sistemas e Informações Espaciais – LSIE, em especial ao Marcos Pereira, Anesmar, Gustavo, Nikolas, Petrônio, Hugo, Felipe, Núbia, Diego, Diandra, Daniela, Gabi e Osmarzinho, muito obrigado pela convivência.

Agradeço a Daniele Silva Oliveira pelo apoio, a minha família e aos amigos do Distrito Federal.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior e o CNPQ pela concessão da bolsa de estudos e a FAP-DF pelo incentivo e interesse na Pesquisa Científica do Distrito Federal.

E a toda a Universidade de Brasília – UnB.

## RESUMO

Os recursos hídricos e os estudos fenológicos florestais são extremamente importantes para a compreensão de diversos fenômenos naturais como as mudanças climáticas, dinâmica hidrogeomorfológica, condicionamento ambiental e gestão dos recursos. Inserida na dinâmica hídrica, estão presentes as áreas inundáveis que estão intrinsecamente ligadas à manutenção da biota e da fauna nos biomas brasileiros. Nesse contexto, os produtos derivados de sensoriamento remoto têm sido bastante utilizados para a análise e monitoramento de áreas inundáveis, mapeamento de uso e ocupação da terra e dinâmica fenológica devido à sua importância ambiental. As imagens de radar de abertura sintética (SAR) são produtos potenciais por não apresentar interferências atmosféricas, entretanto, necessitam de diversos tratamentos iniciais, definidos de pré-processamento para assim ser possível obter uma melhor extração de informações de uma determinada área. Nesse sentido, essa pesquisa teve como objetivo aplicar as técnicas de *deep learning* utilizando algoritmos de processamento de séries temporais de imagens de satélite baseados em redes neurais para extração e identificação de áreas inundáveis, corpos hídricos e fenologias florestais em áreas de cerrado, floresta amazônica, mangues, cultivos agrícolas e várzea. O presente estudo foi dividido em três capítulos principais: (a) análises métricas e estatísticas de filtragens espaciais em imagem Sentinel-1 SAR da Amazônia Central, Brasil; (b) análise de série temporal Sentinel-1 SAR em inundações na Amazônia Central; e (c) classificação fenológica de floresta, mangues, cerrado e vegetação alagada do bioma Amazônia por meio de comparação dos modelos LSTM, Bi-LSTM, GRU, Bi-GRU e modelos de aprendizagem de máquina baseados em séries temporais do satélite Sentinel-1. As etapas metodológicas foram distintas para cada capítulo e todos apresentaram precisão e altos valores métricos para mensuração e análise dos corpos hídricos, inundação e fenologias florestais. Dentre os métodos de filtragem analisados na imagem SAR, o filtro Lee com janela  $3 \times 3$  apresentou os melhores desempenhos na redução do ruído *speckle* (MSE igual a 1,88 e MAE igual a 1,638) e baixo valor de distorção de contraste na polarização VH. Entretanto, para a polarização VV, mensuraram-se diferentes resultados para análise da redução do ruído *speckle*, onde o filtro Frost com janela  $3 \times 3$  apresentou o melhor desempenho, com baixo valor para as métricas em geral (MSE igual a 1,2 e MAE igual a 6,28) e também um baixo valor de distorção de contraste. Por apresentar os melhores valores estatísticos, o filtro de mediana com janela  $11 \times 11$  nas

polarizações VH e VV pode ser utilizado como uma técnica de filtragem alternativa na imagem Sentinel-1 nas duas polarizações. As áreas de inundação mensuradas nas polarizações VH e VV apresentaram uma forte correlação e sem significância estatística entre as amostras, presumindo que se pode utilizar as duas polarizações para obtenção do pulso de inundação e mapeamento da dinâmica das áreas inundáveis na região. Pelo fato de não haver imagens Sentinel-1 anteriores ao ano de 2016, quando os eventos extremos de LMEO foram superiores a 100%, não foi possível delimitar a LMEO por meio de dados SAR. Algumas áreas ao longo da costa e rios apresentam assinaturas temporais de retroespalhamento que evidenciam transições entre ambientes terrestres e áreas cobertas por água. A variação temporal do retroespalhamento de valores mais altos para mais baixos indica erosão e inundação progressiva, enquanto o inverso indica aumento terrestre. O modelo Bi-GRU apresentou a maior acurácia geral, precisão, *recall* e *F-score* tanto na polarização individual como na polarização combinada VV+VH. A combinação entre as polarizações forneceu os melhores resultados na classificação e a polarização VH obteve melhores resultados quando comparado à polarização VV. O presente estudo atestou o procedimento metodológico adequado para mensurar as áreas de corpos hídricos e seu pulso de inundação como também obteve a classificação de fenologias com alta precisão na Amazônia Central por meio de *deep learning* advindas de série temporal de imagens Sentinel-1 SAR.

Palavras-chave: Áreas inundáveis; *deep learning*; *recurrent neural network*; sensoriamento remoto; radar.



## ABSTRACT

Water resources and forest phenological studies are extremely important for the understanding of various natural phenomena, such as climate variation, hydrogeomorphological dynamics, environmental conditioning, and resource management. In this context, products derived from remote sensing have been widely used for the analysis and monitoring of flooding areas, land use and occupation mapping, and phenological dynamics due to their environmental importance. Synthetic aperture radar (SAR) images are potential products as they do not present atmospheric interference, however, they require several initial treatments, defined as pre-processing, so that it is possible to obtain a better extraction of information from a certain area. In this sense, this research aimed to apply deep learning techniques using algorithms based on neural networks for the extraction and identification of flooding areas, water bodies, and forest phenologies such as cerrado, Amazon forest, mangroves, agricultural crops, and floodplain through time series of remote sensing images. This study was divided into three main chapters: (a) metric and statistical analysis of spatial filtering in Sentinel-1 SAR images of Central Amazonia, Brazil; (b) Sentinel-1 SAR time series analysis in flooding areas of Central Amazon; and (c) phenological classification of forest, mangroves, savannas, and two flooded vegetation of the Amazon biome by comparing LSTM, Bi-LSTM, GRU, Bi-GRU, and machine learning models from Sentinel-1 time series. The methodological steps were different for each chapter and all presented precision and high metric values for measurement and analysis of water bodies, flooding and forest phenologies. Among the filtering methods analyzed in the SAR image, the Lee filter with  $3 \times 3$  window presented the best performance in reducing speckle noise (MSE of 1.88 and MAE of 1.638) and low value of contrast distortion in the VH polarization. However, for the VV polarization, different results were measured for the analysis of the speckle noise reduction, where the Frost filter with  $3 \times 3$  window presented the best performance, with a low value for the metrics in general (MSE of 1.2 and MAE of 6.28) and also a low contrast distortion value. Statistical values derived from the median filter with  $11 \times 11$  window in the VH and VV polarizations can be used as an alternative filtering technique in the Sentinel-1 SAR image in both polarizations. The flooding areas measured in the VH and VV polarizations showed a strong correlation and no statistical significance between the samples, assuming that both polarizations can be used to obtain the flood pulse and

mapping the dynamics of the flooded areas in the region. Because there are no Sentinel-1 SAR images prior to 2016 when extreme LMEO events were greater than 100%, it was not possible to delimit the LMEO through SAR data. Some areas along the coast and rivers show temporal backscatter signatures with transitions between terrestrial environments and areas covered by water. The temporal variation of backscatter from higher to lower values indicates erosion and progressive flooding, while the inverse indicates terrestrial increase. The Bi-GRU model showed the highest overall accuracy, precision, recall, and F-score in both separate polarization and combined VV+VH polarization. The combination between the polarizations provided the best results in the classification and the VH polarization obtained better results when compared to the VV polarization. This study attested an adequate methodological procedure to measure the areas of water bodies and their flood pulse, as well as obtaining the classification of phenologies with high precision in the Central Amazon by means of deep learning applied to the time series of Sentinel-1 SAR images.

Keywords: Flooding areas; deep learning; recurrent neural network; remote sensing, radar.

## Sumário

RESUMO.....	vii
ABSTRACT.....	ix
LISTA DE FIGURAS.....	xiv
LISTA DE TABELAS.....	xviii
LISTA DE ABREVIATURAS E SIGLAS.....	xx
CAPÍTULO I. APRESENTAÇÃO.....	24
I.1 Introdução.....	24
I.2 Objetivos.....	27
I.3 Estrutura da Tese.....	28
Referências.....	29
CAPÍTULO II. ANÁLISES MÉTRICAS E ESTATÍSTICA DE FILTRAGENS ESPACIAIS EM IMAGEM SENTINEL – 1 SAR NA AMAZÔNIA CENTRAL, BRASIL.....	33
Resumo.....	33
Abstract.....	33
II.1 Introdução.....	34
II.2 Materiais e Métodos.....	36
II.2.1 Área de estudo.....	36
II.2.2 Caracterização climática.....	37
II.2.3 Processamento digital de imagem.....	37
II.2.4 Filtro Mediana.....	39
II.2.5 Filtro Boxcar.....	40
II.2.6 Filtro Lee.....	40
II.2.7 Filtro Frost.....	41
II.2.8 Filtro refined Lee.....	41
II.2.9 Filtro Gamma Map.....	42
II.2.10 Filtro IDAN.....	42
II.2.11 Métricas de avaliação da qualidade de imagens SAR.....	43
II.2.12 Erro médio quadrático.....	43
II.2.13 Erro médio Absoluto.....	43
II.2.14 Relação sinal ruído.....	43
II.2.15 Pico relação sinal ruído.....	44

II.2.16 Diferença de contraste.....	44
II.2.17 Número equivalente de Looks.....	45
II.3 Resultados e discussão.....	46
II.4 Conclusões.....	52
CAPÍTULO III. ANÁLISE DE SÉRIE TEMPORAL SENTINEL 1 EM INUNDAÇÕES NA AMAZÔNIA CENTRAL.....	56
Resumo.....	57
Abstract.....	57
III.1 Introdução.....	58
III.2 Materiais e métodos.....	60
III. 2.1 Área de estudo.....	60
III. 2.2 Imagens sentinel-1 e pré-processamento.....	61
III.2.3 Filtragem dos dados.....	62
III. 2.4 Cubo temporal de imagens.....	62
III. 2.5 Os campos de vento.....	62
III. 2.6 Cálculo da LMEO.....	64
III. 2.7 Análise estatística dos dados temporais.....	64
III. 3 Resultados e discussão.....	65
III. 3.1 Atenuação dos ruídos nas imagens.....	65
III. 3.2 Cubo temporal de imagens SAR.....	68
III. 3.3 Caracterização do retroespalhamento dos corpos hídricos.....	68
III. 3.4 Análise da dinâmica pluviométrica e pulso de inundação.....	70
III. 3.5 Análise estatística das áreas inundadas.....	76
III. 3.6 Análise da LMEO.....	77
III. 4 Conclusões.....	79
CAPÍTULO IV. PHENOLOGICAL CLASSIFICATION OF FOREST, MANGROVES, SAVANNAS, AND 2 FLOODED VEGETATION OF THE AMAZON BIOME COMPARING LSTM, BI-LSTM, GRU, BI-GRU AND MACHINE LEARNING MODELS FROM SENTINEL-1 TIME SERIES.....	82
Resumo.....	82
Abstract.....	83
IV. 1 Introduction.....	84
IV. 2 Study area.....	87

IV. 3 Materials and methods.....	89
IV. 3.1 Data preparation.....	90
IV. 3.2 Ground Truth and Sample Dataset.....	91
IV. 3.3 RNN and Traditional Machine Learning Models.....	92
IV. 3.4 Accuracy Assessment.....	94
IV. 4 Results.....	96
IV. 4.1 Image Denoising.....	95
IV. 4.2 Multitemporal Backscattering Signatures.....	95
IV. 4.3 Comparison between RNN and others Machine Learning methods.....	104
IV. 5 Discussion.....	108
IV. 6 Conclusions.....	110

## LISTA DE FIGURAS

<b>Figura II.1</b> Mapa de Localização geográfica da área de estudo na Amazônia Central, Brasil.....	37
<b>Figura II.2</b> Localização espacial das amostras casualizadas na área de estudo na Amazônia Central.....	39
<b>Figura II.3</b> Fluxograma metodológico das etapas de desenvolvimento do estudo.....	46
<b>Figura II.4</b> Desempenho das três áreas de amostragens nas polarizações VH e VV por meio do teste t de student ao nível de 0,05% de significância estatística.....	47
<b>Figura II.5</b> Imagem Sentinel 1 – SAR polarizações VH e VV, imagem filtrada por meio do filtro Lee 3x3 na polarização VH e filtro Frost 3x3 na polarização VV com ênfase visual nos alvos, Floresta Amazônica, corpos hídricos e área urbana de Parintins, AM.....	50
<b>Figura II.6</b> Gráfico dos valores métricos mensurados para as Polarizações VH e VV na região de Parintins, AM.....	51
<b>Figura III.1</b> Localização geográfica da área em estudo na Amazônia Central.....	61
<b>Figura III.2</b> Mapa das estações meteorológicas utilizadas para interpolação dos campos de vento na Amazônia Central, estado do Pará.....	63
<b>Figura III.3</b> Fluxograma metodológico das etapas realizadas na análise de inundação no trecho central do rio Amazonas.....	65
<b>Figura III.4</b> Imagem Sentinel-1 dos corpos hídricos na polarização VH (A1) e filtrada pelo Lee 3x3 (A2), e na polarização VV (B1) e filtrada pelo Frost 3x3.....	67
<b>Figura III.5</b> Cubo temporal composto por 59 imagens Sentinel -1 nas polarizações VH e VV entre 26/09/2016 e 08/02/2020.....	68
<b>Figura III.6</b> Gráfico dos valores de retroespalhamento SAR nas polarizações VH e VV no rio Amazonas, Lago Moratinga e Lago Grande na Amazônia Central de 26/09/2016 até 08/02/2020.....	69
<b>Figura III.7</b> Mapa da velocidade média do vento de 01/09/2016 até 08/02/2020 para Amazônia Central.....	70

<b>Figura III.8</b> Valores pluviométrico na estação de Parintins (AM), salientando a maior e menor área inundada dentro da série temporal Sentinel – 1 para anos de 2000 a 2020.....	71
<b>Figura III.9</b> Mapa dos corpos d'água da Amazônia Central nos períodos de menor e maior área inundada para os anos de 2016 a 2020 nas polarizações VH e VV do Sentinel-1.....	72
<b>Figura III.10</b> Mapa sazonal do pulso de inundação no rio Amazonas e afluentes, em Janeiro do ano de 2016, Abril, Junho e Dezembro de 2017.....	73
<b>Figura III.11</b> Regressão linear entre as áreas inundadas entre as polarizações VH e VV.....	76
<b>Figura III.12</b> Modelo de regressão linear relacionado a área inundada nas polarizações VH e VV com a cota altimétrica da régua em Parintins, AM.....	77
<b>Figura III.13</b> Gráfico do regime fluviométrico no Rio Amazonas no período entre os anos 1967 a 2020 e o valor relativo da LMEO. ....	78
<b>Figura III.14</b> Mapa das áreas inundadas em trecho do rio Amazonas entre os municípios de Urucara e Parintins na Amazônia central no período de maior seca registrado por meio da série temporal das imagens Sentinel – 1 SAR.....	78
<b>Figura III.15</b> Mapa das áreas inundadas em trecho do rio Amazonas entre os municípios de Urucara e Parintins na Amazônia central no período de maior inundação registrado por meio da série temporal das imagen Sentinel – 1 SAR.....	79
<b>Figure IV.1</b> Location study area in the state of Amapá in Brazil and the South American continent (A). The image of the study area corresponds to the first component of the Minimum Fraction of Noise transformation considering the Sentinel 1 VH polarization time series in the period 2017–2020 (B).....	89
<b>Figure IV.2</b> Methodological flowchart.....	91
<b>Figure IV.3</b> Sentinel-1 time series denoising using the Savitzky and Golay (S-G) method in the Amazon savanna. The original data is the gray line, and the data smoothed with the S-G filter is the purple line. C-band backscattering differences in VH	

polarization correspond to seasonal biomass variations during the wet (high values) and dry (low values) seasons.....92

**Figure IV.4** Study area samples for training (cyan), validation (red), and test (orange).....94

**Figure IV.5** Mean temporal signatures of the 500 samples selected for water bodies (blue line), Ombrophilous Forest (gray line), and savannah (yellow line) considering VV (A) and VH (B) polarizations of Sentinel-1A. The curves display the standard deviation bars. ....98

**Figure IV.6** Mean temporal trajectory of the 500 samples selected considering Sentinel-1 data with VV (A) and VH polarization (B) for the classes: land accretion areas with water to land conversion (orange line), and land erosion areas with land to water conversion (blue line). The curves display the standard deviation bars.....99

**Figure IV.7** Time series image sequences that show in the state of Amapá: (A) coastal erosion process, (B) coastal land accretion process, and (C) fluvial dynamic. The last image represents an RGB color composite (CC) composed of the images from January 2017, January 2019, and December 2020. The red colors in the images represent areas of land erosion and the blue ones of accretio.....100

**Figure IV.8** Average temporal signatures of the 500 samples selected for each seasonally flooded grasslands: sparse herbaceous (blue line) and grasslands with the presence of sparse woody (orange line) with VH (A) and VV (B) polarizations. In addition, grassland with a medium and dense herbaceous (black and sea green lines) with VH (C) and VV (D) polarizations. All graphs present the non-floodable shrub grassland time series (red line) compared with seasonally flooded areas. The curves display the standard deviation bars .....101

**Figure IV.9** Average temporal signatures (Sentinel 1 VV and VH radar signals) of 500 samples with their respective standard deviation bars for the following vegetation classes: (A and E) pioneer formations with the increase of the tree-shrub stratum (herbaceous (magenta line) > shrub (yellow line) > arboreal (green line)); (B and F) shrub grassland (dark purple line) and savanna/shrub savanna curve (light purple line); (C and G) two time series of ombrophilous forest (green lines) and mangroves (brown line) with the insertion of the savanna time series (red line) for



comparison; and (D e H) agricultural planting (blue line) and eucalyptus plantation (orange line).....103

**Figure IV.10** McNemar's statistical test at a significance level of 0.05 containing red cells represent paired methods significantly different from each other, and green cells describe s similar results. The models are shown in numbered order: (1) Bidirectional Gated Recurrent Unit (Bi-GRU), (2) GRU, (3) Bidirectional Long Short-Term Memory (Bi-LSTM), (4) LSTM, (5) Random Forest, (6) XGBoost, (7) Support Vector Machine, (8) k-Nearest Neighbor, and (9) Multilayer perceptron.....107

**Figure IV.11** Comparing the phenology-based classification of land-cover types with the highest and lowest accuracy metrics between the RNN (Bi-GRU and LSTM) and ML (SVM and k-NN) methods for the different datasets (VV only, VH only, and VV&VH) in a detail area.....109

**Figure IV.12** Land-cover map of the southeastern region of the State of Amapá using the Bi-directional Gated Recurrent Unit (Bi-GRU) method, which obtained the best accuracy measures. The dashed square corresponds to the area in Figure 11.....110

## LISTA DE TABELAS

Tabela II-1 Parâmetros dos modos de aquisição da missão Sentinel-1 SAR.....	37
Tabela II-2 Valores referente aos índices métricos para as técnicas de filtragem na polarização VH.....	48
Tabela II-3 Valores referente aos Índices métricos para as técnicas de filtragem na polarização V.....	48
Tabela III-1 Parâmetros dos modos de aquisição da missão Sentinel-1 SAR.....	61
Tabela III-2 Nomenclatura das estações meteorológicas e dados de velocidade do vento.....	64
Tabela III-3 Valores dos índices métricos para as técnicas de filtragem na polarização VH.....	66
Tabela III-4 Valores dos índices métricos para as técnicas de filtragem na polarização VV.....	67
Tabela III-5 Área inundada mensurada em km <sup>2</sup> por meio da série temporal das imagens Sentinel-1 SAR nas polarizações VH e VV.....	74
Table IV-1 Configuration of the Recurrent Neural Network (RNN) models, pertaining to Deep Learning (DL) procedures, and grid search values used for each Machine Learning (ML) models: Random Forest (RF), Extreme Gradient Boosting (XGBoost), Support Vector Machines (SVM), Multilayer Perceptron (MLP), and k-Nearest Neighbors (k-NN).....	94
Table IV-2 Overall Accuracy (OA), precision, recall, and F-score metrics for the following methods: Deep Learning (DL), Machine Learning (ML), Long Short Term-Memory (LSTM), Bidirectional LSTM (Bi-LSTM), Gated Recurrent Unit (GRU), Bidirectional GRU (Bi-GRU), Multilayer Perceptron (MLP), Extreme Gradient Boosting (XGBoost), Random Forest (RF), Supporting Vector Machine (SVM), and k-Nearest Neighbors (k-NN).....	103

Table IV-3 Per category metrics for the best model (Bi-GRU) considering precision, recall, and F-score. The land-cover and land-use classes are: (1) water bodies, (2) land erosion, (3) land accretion, (4) sparse seasonally flooded grassland, (5) dense seasonally flooded grassland 1, (6) dense seasonally flooded grassland 2, (7) humid dense grassland and floodplain areas, (8) pioneer herbaceous formation, (9) pioneer shrub formation, (10) pioneer arboreal formation, (11) shrub grassland, (12) savanna/shrub savanna, (13) mangroves, (14) forest 1, (15) forest 2, (16) agriculture plantations (soybean), and (17) planted forest.....105

## LISTA DE ABREVIATURAS E SIGLAS

- $\sigma^0$ . Backscattering coefficient
- °C. Celsius
- dB**. Decibéis
- $\sigma$ . Desvio-Padrão
- ALOF**. Average ordinary flood line
- ALOS**. Advanced Land Observing Satellite
- B**. Blue
- BDMEP**. Banco de Dados Meteorológicos de Ensino e Pesquisa
- Bi-GRU**. Bidirecional Gated Recurrent Unit
- Bi-LSTM**. Bidirecional Long Short-Term Memory
- CCE**. Categorical cross-entropy
- CoC**. Coeficiente de Correlação
- CNN**. Convolutional neural network
- Cvar**. Coeficiente de Variação
- DCON**. Distorção de Contraste
- DEM**. Modelo Digital de Elevação
- DL**. Deep learning
- DT**. Decision Tree
- ELM**. Extreme Learning Machine EQM. Erro Quadrático Médio
- ESA**. European Space Agency
- FN**. False Negative
- FP**. False Positive
- FPR**. False Positive Rate
- G**. Green
- GHz**. Gigahertz
- GPS**. Global Positioning System
- GRU**. Gated Recurrent Unit
- INMET**. Instituto Nacional de Meteorologia
- IWS**. Interferometric Wide Swath
- GRD**. Ground Range Detected
- LMEO**. Linha Média de Enchente Ordinária
- LSTM**. Long Short-Term Memory

**MAE.** Erro Absoluto Médio  
**MLP.** Multilayer Perceptron  
**Mps.** Metros por segundo  
**MMSE.** Erro Quadrático Médio Mínimo  
**MODIS.** Moderate Resolution Imaging Spectroradiometer  
**MSE.** Erro médio quadrático  
**MSI.** Multispectral Instrument  
**NDVI.** Normalized difference vegetation index  
**NEL.** Número Equivalente de Looks  
**PSNR.** Pico de Relação Sinal-Ruído  
**QDA.** Quadratic Discriminant Analysis  
**S-1.** Sentinel -1 SAR  
**SAR.** Synthetic Aperture Radar  
**S-G.** Savitzky and Golay  
**SLC.** Single-look Complex  
**SNAP.** Sentinel Application Platform  
**SR.** Sensoriamento Remoto  
**SRTM.** Shuttle Radar Topographic Mission  
**R.** Red  
**RF.** Random forest  
**R<sup>2</sup>.** Coeficientes de determinação  
**RAR.** Real Aperture Radar  
**RN.** Referencial de nível  
**RNA.** Redes Neurais Artificiais  
**kNN.** K - Nearest Neighbors  
**VANT.** Veículo Aéreo não Tripulável  
**R.** Recall  
**RNN.** Recurrent neural network  
**SNR.** Signal Noise Ruido  
**SVM.** Support Vector Machines  
**TA.** Total accuracy  
**TN.** True Negative  
**TP.** True Positive  
**TPR.** True Positive Rate

**UTM.** Universal Transverse Mercator

**VH.** Vertical transmitting, Horizontal receiving

**VV.** Vertical transmitting, Vertical receiving

**WGS.** World Geodesic System

**XGBoost.** Extreme Gradient Boosting

# CAPÍTULO I

## APRESENTAÇÃO

### I.1 Introdução

O planeta Terra é composto por mais de 70% de superfície líquida. Essa quantidade de água é responsável pela variação climática, manutenção dos rios, lagos e oceanos e desenvolvimento de condições para o desenvolvimento humano, da biota e da fauna (RIBEIRO & ROLIM, 2017). No contexto histórico, não houve uma mudança significativa na quantidade de água presente na Terra e sim na sua qualidade que vem sendo poluída ou contaminada por processos antrópicos e naturais. A manutenção da quantidade de água na Terra está diretamente ligada à sua recomposição por meio do ciclo hidrológico que atua praticamente como repositório e regulador da presença de água nas bacias hidrográficas.

Atualmente, no Brasil, cada vez mais os órgãos públicos, instituições e pesquisadores estão monitorando os recursos hídricos nacionais para análise e levantamento de informações por meio de parâmetros hidrológicos como vazão (MENDES; CECILIO; ZANETTI, 2018), escoamento superficial (HOLLANDA et al., 2015), chuvas intensas (ABREU et al., 2018) e áreas inundáveis por meio de técnicas de sensoriamento remoto (HESS et al., 2015; FURTADO et al., 2016; MARQUES et al., 2019).

As áreas inundáveis apresentam um constante intercâmbio de água, sedimentos e nutrientes que os diferenciam dos ambientes terrestres e aquáticos (ARNESEN, 2012). Estes ambientes correspondem a 6% da superfície terrestre e, apesar da pouca representatividade, prestam importantes serviços ecossistêmicos (DUFFY & KAHARA, 2011), tais como a reciclagem de nutrientes, sequestro de carbono e nitrogênio, regulação da emissão de gás metano e melhora na qualidade da água e habitats de espécies endêmicas que as utilizam tanto para reprodução quanto para alimentação (JUNK & SPARKS, 1989; KAHARA, 2011; DEÁK et al., 2015).

No Brasil, os ambientes com maiores áreas de inundação estão presentes na região dos biomas Pantanal e Amazônia. Conforme Junke et al. (1989), as notáveis

mudanças na distribuição espacial e temporal das áreas de inundação na vegetação Amazônica são causadas pela grande variação anual dos níveis de água, sendo a amplitude e a periodicidade os principais fatores de produtividade da biodiversidade e biogeoquímica na planície de inundação. A planície de inundação do rio Amazonas é responsável por aproximadamente 12% da área total da área úmida na bacia amazônica e é coberta por uma grande variedade de fitofisionomias herbáceas, arbustivas e arbóreas, tanto terrestres quanto aquáticas (MELACK & HESS, 2010).

No território nacional, as áreas inundáveis adjacentes aos rios federais são consideradas de patrimônio da União. A Constituição Federal de 1988, em seu artigo nº 20, define as áreas que estão sob a gestão da União, sendo elas: as terras devolutas, os lagos, rios e quaisquer corrente d'água em terrenos sob seu domínio; as ilhas fluviais e lacustres nas zonas limítrofes com outros países; as praias marítimas; as ilhas oceânicas e costeiras; o mar territorial; os terrenos de marinha; os recursos minerais; os sítios arqueológicos e pré-históricos; e as terras indígenas; entre outros (BRASIL, 1988).

A definição de Terrenos Marginais está ancorada no Decreto-Lei nº 9.760, de 5 de setembro de 1946, dizendo que são áreas “que banhados pelas correntes navegáveis, fora do alcance das marés, vão a distância de 15 (quinze) metros, medidos horizontalmente para a parte da terra, contados desde a linha média das enchentes ordinárias”. Ou seja, a real definição dos Terrenos Marginais está diretamente atrelada ao entendimento da dinâmica de pulso de inundação que um rio federal apresenta.

A demarcação da linha média das enchentes ordinárias (LMEO) atualmente é realizada com o aporte dos dados das estações fluviométricas no qual se realiza os estudos da série histórica e define-se a média máxima anual da cota de inundação por um período de no mínimo 20 anos. Outro dado importante são as referências de nível (RN) mais próximas do trecho a ser demarcado para realizar a etapa do nivelamento geométrico entre a RN e a estação fluviométrica, por conseguinte, obter a cota básica da LMEO (SPU/MPOG, 2001).

Dados auxiliares como cartas topográficas, documentos históricos e/ou fotografias aéreas são elementos adicionais para a definição do trecho a ser demarcado, pois a LMEO deverá corresponder à média das enchentes do período em que consta em lei, que é de 1831 (BRASIL, 1946). A partir daí, realizam-se trabalhos de campo com instrumentos topográficos de precisão posicional adequada, com vistas à realização da



definição do trecho que separa o que é patrimônio da União e o que é de domínio particular.

Este método, dentro do contexto do bioma Amazônico, que contém grandes rios e áreas de inundação, mostra-se oneroso e dispendioso, tendo em vista a demanda de logística, equipamentos, transportes e recursos humanos para este tipo de trabalho. Uma alternativa bastante viável para obtenção de informações a respeito de corpos hídricos é por meio de técnicas de sensoriamento remoto e geoprocessamento.

Entretanto, em determinadas regiões terrestres de baixa latitude, como na região Amazônica com intensa cobertura de nuvem, as imagens de satélites que operam na região de bandas espectrais na região do visível até o infravermelho de ondas longas não são tão eficazes, pois as suas bandas espectrais não conseguem transpor as nuvens e obter as devidas informações. A alternativa para esse intempérie atmosférico é o uso de imagens de sensores ativos como os radares de abertura sintética (SAR) (FORQUOR et al., 2014). Além da transposição de nuvens, os sinais de radar são sensíveis às propriedades do solo (umidade e rugosidade) e da vegetação (estrutura e biomassa), proporcionando informação adicional dos tipos de cobertura do solo (JIN et al., 2014).

Dentro da classe dos radares imageadores, existem os radares de abertura real (*Real Aperture Radar – RAR*) e os radares de abertura sintética (*Synthetic Aperture Radar – SAR*), onde “abertura” significa antena. Um sistema SAR usa um sofisticado processamento de sinais para sintetizar uma antena maior do que seu tamanho físico real para a mesma finalidade (ALMEIDA, 2008).

Uma imagem de radar é uma matriz bidimensional de pixels onde cada pixel é formado por um número complexo (amplitude e informação de fase) associado à refletividade dos espalhadores contidos dentro da célula de resolução do radar (LEE & POTTIER, 2009). Usualmente, os sistemas radar utilizam polarizações lineares paralelas, HH e VV, ou cruzadas, HV e VH (a primeira letra refere-se à polarização da radiação transmitida e a segunda à polarização da radiação recebida pela antena) (JENSEN, 2011).

Em 2014, foi lançado o satélite Sentinel-1 SAR, com um sensor de micro-ondas que opera na banda C. Essas imagens pertencem à Agência Espacial Europeia (ESA – *European Space Agency*). As imagens do satélite Sentinel-1 são adquiridas na banda C e nos modos de polarização única (HH ou VV) ou dupla (HH/HV ou VV/VH)

com uma alta resolução espacial e temporal, entretanto, o principal fator de interferência associado à interpretação de imagens SAR é a presença do ruído *speckle* (DONG, MILNE, FORSTER, 2001; BREKKE & SOLBERG, 2005; TELLO; LOPEZ-MARTINEZ; MALLORQUI, 2006; CHANG et al., 2007, SANTOSO et al., 2016).

Este ruído é inerente ao sistema, sendo causado por interferências locais construtivas e destrutivas, no sinal de retorno retroespalhado pela superfície. O *speckle* gera na imagem uma aparência granular, composta por mudanças bruscas no nível de cinza em pixels espacialmente próximos (LEE & HOLT, 1982; DUTRA et al., 2003; BENTZ, 2006). Desta forma, o *speckle* é uma forma de ruído que degrada a qualidade das imagens, interferindo em todas as etapas de detecção dos alvos escuros, sendo recomendada a utilização do processamento em múltiplas visadas (*multi-look*) ou a aplicação de filtros para sua suavização (DONG; MILNE; FORSTER, 2001; SANT'ANNA; FERNANDES; LACAVALA, 2004; FURTADO et al., 2016).

Após o tratamento do ruído *speckle* e das etapas de pré-processamento das imagens, iniciou-se a extração e mensuração da linha média de inundação por meio de técnicas de sensoriamento remoto para trechos do rio Amazonas inseridos na região entre os municípios de Urucara e Parintins, na Amazônia Central. Posteriormente, utilizaram-se métodos de inteligência artificial na classificação de fenologias florestais no estado do Amapá por meio de análises métricas entre 9 classificadores de *deep learning* e *machine learning* provenientes de série temporal de imagens Sentinel-1 SAR no período entre 2017 a 2020.

A classificação de imagens por *deep learning* e *machine learning* destacam-se em relação aos métodos de classificação convencionais como árvores de decisão, Random Forest ou vizinhos mais próximos, que tendem a ser muito limitados para determinados alvos e em séries temporais alvo, uma vez que a análise é feita por pixel (MA et al., 2019).

Nesse contexto, as técnicas de *deep learning*, juntamente com arquiteturas conhecidas como *Recurrent Neural Network* (RNN) ou redes neurais recorrentes, têm apresentado grande potencial para detecção automática em imagens e distinção de alvos florestais, uma vez que possuem a capacidade de usar informações sequenciais dos dados em séries temporais de imagens (CHO et al., 2014).

O conhecimento de áreas inundáveis na Amazônia central e a classificação com precisão no mapeamento temporal das fenologias florestais por meio de *deep learning* no ambiente amazônico no estado do Amazonas e no Amapá inovará no entendimento dos recursos ambientais presentes no bioma, tornando-se um agente norteador para tomada de decisões e manejo ambiental sustentável.

## I.2 Objetivos

A presente tese possui, como objetivo geral, propor um aprimoramento no mapeamento para as classes fenológicas florestais e áreas inundáveis, como também a análise da precisão entre os classificadores de imagens em áreas localizadas no estado do Amazonas e Amapá a partir de série temporal de imagens Sentinel-1 SAR utilizando técnicas de *deep learning* e *machine learning*.

Os objetivos específicos desta tese estão elucidados separadamente por cada capítulo a seguir:

### Capítulo 2

- Avaliar o desempenho de sete diferentes técnicas de filtragem espaciais para redução do ruído *speckle* nas imagens do satélite Sentinel-1 SAR na Amazônia Central;

### Capítulo 3

- Mensurar as áreas inundáveis e o ALOF através de dados fluviométricos (1967-2020) e séries temporais de imagens Sentinel-1 SAR (2016-2020) em dupla polarização VH e VV em um trecho altamente inundável da Amazônia; e

### Capítulo 4

- Avaliar o comportamento das polarizações VV e VH na diferenciação das fenologias florestais e comparar as diferentes classificações de uso e ocupação da terra por meio de RNNs (LSTM Bi-LSTM, GRU e Bi-GRU e *machine learning* (RF, XGBoost, SVM, k-NN e Naïve Bayes) em série temporal de imagens SAR.

### I.3 Estrutura da Tese

Esta pesquisa está subdividida em quatro capítulos baseados na identificação e análise de fenologias florestais e áreas inundáveis utilizando *deep learning* com diferentes metodologias em séries temporais de imagens Sentinel-1 SAR. Os capítulos 2, 3 e 4 são relativos a artigos científicos elaborados com o objetivo geral da tese, considerando algumas particularidades, como área de estudo, metodologia, resultados e conclusões.

No primeiro capítulo, é apresentada uma contextualização geral sobre o tema, utilização de dados de sensoriamento remoto, além da explanação geral sobre áreas inundáveis, imagens de radar e aprendizado profundo usando *deep learning*.

O artigo do Capítulo 2 intitulado **Análises métricas e estatística de filtragens espaciais em imagem Sentinel-1 SAR na Amazônia Central, Brasil** foi submetido à Revista Geográfica Venezolana. Nele, foram aplicadas e testadas sete técnicas distintas de filtragem espaciais em imagens de radar do satélite Sentinel-1 para a primeira imagem disponibilizada pelo sensor, em setembro de 2016, para a região em estudo na Amazônia Central. As técnicas de filtragem do ruído *speckle* foram analisadas por meio de métricas de precisão e testes estatísticos. Além de obter as melhores técnicas de filtragem para cada polarização na região em estudo, foi proposta uma técnica de filtragem alternativa que apresentou resultados precisos para a dupla polarização VV e VH.

O artigo do Capítulo 3 intitulado **Análise de série temporal Sentinel-1 SAR em inundações na Amazônia Central**, foi submetido à Revista Mercator e aceito para publicação em 08 de maio de 2022. Nesse artigo, foram aplicadas técnicas de extração de corpos hídricos e manchas de inundação por meio de técnicas de sensoriamento remoto advindas de imagens multitemporais do satélite Sentinel-1 SAR para os anos de 2016 a 2020. O uso de imagens de radar supera limitações das imagens óticas na série temporal, pois a sazonalidade na área em estudo apresenta enorme presença de nuvens e interferências atmosféricas na Amazônia.

Já o artigo do Capítulo 4, ***Phenological classification of forest, mangroves, savannas, and two flooded vegetation of the Amazon biome by comparing LSTM, Bi-LSTM, GRU, Bi-GRU and machine learning models from Sentinel-1 time series***, foi submetido em 10 de julho de 2022 para a revista Remote Sensing. Nesse artigo, foi

utilizada série multitemporal de imagens Sentinel-1 SAR no período de 2017 a 2020 para análise, mapeamento e extração de informações de retroespalhamento das fenologias florestais e hídricas presentes no estado do Amapá por meio de técnicas de *deep learning* e *machine learning*. Além disso, foi analisada a precisão das 17 classes extraídas por meio de análise das polarizações distintas VV, VH e combinadas VV+VH.

## Referências

ALMEIDA, F. C. Simulação de Resposta de Estruturas Simplificadas de Vegetação ao Radar de Abertura Sintética Interferométrico. Dissertação 2008. 104 f. (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 2008.

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 Amazonica**. v. 46, n. 3, p. 291-302, 2016.

ALSDORF, D. E.; SMITH L. C.; MELACK, J. M. Amazon Floodplain Water Level Changes Measured with Interferometric SIR-C Radar. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 2, p. 0196–2892, 2001.

ARNESEN, A. S. Monitoramento da área inundada na planície de inundação do Lago Grande de Curuai (PA) por meio de imagens SCANSAR/ALOS e dados auxiliares. Dissertação Mestrado – Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, SP, 2012.

BARBOSA, C. C. F. Sensoriamento remoto da dinâmica da circulação da água no sistema planície de Curuai/Rio Amazonas. Tese de Doutorado – Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, SP, 2005.

BARBOSA, C. C. F.; NOVO, E. M. L. M.; MELACK, J. M.; FREITAS, R. M.; FILHO, W. P. Metodologia de análise da dinâmica de área e volume inundável: o exemplo da Várzea do Lago Grande de Curuai. **Revista Brasileira de Cartografia**, v. 1, p. 03-24, 2006.

BATES P. D.; WILSON M. D.; HORRITT M. S.; MASON D. C.; HOLDEN N.; CURRIE A. Reach scale floodplain inundation dynamics observed using airborne synthetic aperture radar imagery: Data analysis and modelling. **Journal of hydrology**, v. 328, p. 306-318, 2006.

BAXTER. R. SEIBERT, M. Synthetic aperture radar image coding. **MIT Lincoln Laboratory Journal**, v. 11, n. 2, p. 121–158, 1998.

BENTZ, C. M. Reconhecimento automático de eventos ambientais costeiros e oceânicos em imagens de radares orbitais. Tese de Doutorado - Universidade Federal do Rio de Janeiro, COPPE, D. Sc., Engenharia Civil, Rio de Janeiro, 2006.

BREKKE, C.; SOLBERG, A. H. S. Oil Spill Detection by Satellite Remote Sensing. **Remote Sensing of Environment**, v. 95, p. 1-13, 2005.

CARVALHO JÚNIOR, O. A.; SAMPAIO, C. S.; SILVA, N. C.; COUTO JÚNIOR, A. F.; GOMES, R. A. T.; CARVALHO, A. P. F.; SHIMABUKURO, Y. E. Classificação de padrões de savana usando assinaturas temporais NDVI do sensor MODIS no Parque Nacional Chapada dos Veadeiros. **Revista Brasileira Geofísica**. V. 26, n. 4, p. 505-507, 2008.

CHANG, J.; HANSEN, M. C.; PITTMAN, K.; CARROLL, M.; DIMICELI, C. Corn and soybean mapping in the United States using MODIS time-series data sets. **Agronomy Journal**, v. 99, n. 6, p. 1654-1664, 2007.

DELLEPIANE, S. G.; ANGIATI, E. Quality Assessment Despeckled SAR Images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 6, p. 3803-3806, 2017.

DONG, Y. M.; MILNE, A. K.; FORSTER, B. C. Segmentation and Classification of Vegetated Areas Using Polarimetric SAR Image Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 2, p. 321-329, 2001.

ESA - European Space Agency. <https://sentinel.esa.int/web/sentinel/home>. Acesso em: 05 de jan 2017.

FERREIRA, G. H. S. Identificação de áreas inundáveis na porção sul de Roraima com auxílio de imagens de radar. Dissertação de Mestrado - Universidade de Brasília, Departamento de Geografia, Brasília, 2018.

FISCH, G.; MARENCO, J. A.; NOBRE, C. A. Uma revisão geral sobre o clima da Amazônia. **Acta Amazonica**, v. 28, n. 2, p. 101-126, 1998.

FORKUOR, G.; CORAND, C.; THIEL, M.; ULMANN, T.; ZOUNGRANA, E. Integration of Optical and Synthetic Aperture Radar Imagery for Improving Crop Mapping in Northwestern Benin, West Africa. **Remote Sensing**, v. 6, n. 7, p. 6472-6499, 2014.

FOUCHER, S.; LÓPEZ-MARTÍNEZ, C. Analysis, Evaluation, and Comparison of Polarimetric SAR Speckle Filtering Techniques. **IEEE Transactions on Image Processing**, v. 23, p. 1751-1764, 2014.

FU, L. L.; HOLT, B. Seasat Views Oceans and Sea Ice with Synthetic-Aperture Radar. NASA/JPL Publ. 81-120. Califórnia Instituto de tecnologia. Pasadena.

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

GERHARD, F. Previsão de níveis fluviais de inundação para a cidade de Lajeado, Rio Grande do Sul, a partir de diferentes abordagens matemáticas. Dissertação de Mestrado - Universidade do Vale do Taquari - UNIVATES, Departamento de Engenharia Ambiental, Lajeado, 2017.

HESS, L. L.; MELACK, J. M.; AFFONSO, A. G.; BARBOSA, C.; GASTIL-BUHL, M.; NOVO, E. M. L. M. Wetlands of the Lowland Amazon Basin: Extent, Vegetative Cover, and Dual-season Inundated Area as Mapped with JERS-1 Synthetic Aperture Radar. **Wetlands**, v. 35, p. 745-756, 2015.

JENSEN, J. R. Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres. 3a ed. Parêntese, São José dos Campos, 2011.

JIN, H.; MOUNTRAKIS, G.; STEHMAN, S. V. 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**, v. 98, p. 70-84, 2014.

LEE, J. S. Digital image enhancement and noise filtering by use of local statistics. **IEEE Transactions on Paternal Analysis and Machine Intelligence**, PAMI-, n 2. 1980.

LEE, J. S.; POTTIER, E. **Polarimetric SAR Radar Imaging: From Basic to Applications**, CRC Press, Taylor & Francis Group, 2009.

MARQUES, J. B. Uso de série temporal de imagens PALSAR-2/ALOS 2 para classificação de uso e cobertura do solo e detecção de áreas úmidas na região da Ilha do Bananal, trecho médio do Rio Araguaia. Dissertação de Mestrado - Universidade de Brasília, Departamento de Geografia, Brasília, 2017.

MARQUES, R. C. P. Filtragem de Ruído Speckle em Imagens de Radar de Abertura Sintética e Avaliação dos Efeitos sobre a Segmentação. 2004. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Ceará, Fortaleza, CE, 2004.

MARINHO, R. R.; PARADELLA, W. R.; RENNO, C. D.; OLIVEIRA, C. G. Aplicação de imagens SAR orbitais em desastres naturais: Mapeamento das inundações de 2008 no Vale do Itajai, SC. **Revista Brasileira de Cartografia**, v. 64, p. 317-330, 2012.

MANSOURPOUR, M.; RAJABI, M.A; BLAIS, J.A.R. Effects and performance of speckle noise reduction filters on active radar and SAR images. 2006.

NOVO, E. M. L. M. Sensoriamento Remoto - Princípios e Aplicações – 4a ed. BLUCHER. São Paulo.

RAMALHO, E. E.; MACEDO, J.; VIEIRA, T. M.; VALSECCHI, J.; CALVIMONTES, J.; MARMONTEL, M.; QUEIROZ, H. L. Ciclo hidrológico nos ambientes de várzea da reserva de desenvolvimento sustentável Mamirauá – Médio rio Solimões, período de 1990 A 2008. **Uakari**, v. 5, n. 1, p. 61-87, 2009.

SANT’ANNA, S. J. S. Avaliação de filtro redutores do speckle em imagens de radar de abertura sintética. Dissertação 1995. 209 f. (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 1995.

SANTOSO, A. W.; BAYUAJI, L.; TIEN SZE. L.; LATEH, H.; ZAI, J. M. Comparison of Various Speckle Noise Reduction Filters on Synthetic Aperture Radar Image. **International Journal of Applied Engineering Research**, v. 11, p. 8760-8767, 2016.

SRINIVAS, R.; PANDA, S. Performance Analysis of Various Filters for Image Noise Removal in Different Noise Environment. **International Journal of Advanced Computer Research**, v. 3, p. 2277-7970, 2013.

TELLO, M.; LOPEZ-MARTINEZ, C.; MALLORQUI, J. J. Automatic vessel monitoring with single and multidimensional SAR images in the wavelet domain. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 61, p. 260-278, 2006.

VASCONCELOS, A. O. Modelagem da biomassa do manguezal da APA de Guapi-Mirim utilizando dados multitemporais polarimétricos do sensor Radarsat-2. Tese 2016. 151 f. (Doutorado em Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, 2016.

VASILE, G.; TROUVÉ, E.; LEE, J.; BUZULOIU, V. Intensity-Driven-Adaptive-Neighborhood Technique for Polarimetric and Interferometric SAR Parameters Estimation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, p. 1609–1621, 2006.

ZUHLKE, M.; FOMFERRA, N.; BROCKMANN, C.; PETERS, M.; VECCI, L.; MALIK, J.; REGNER, P. SNAP (Sentinel Application Platform) and the ESA Sentinel 3 Toolbox. In: **Sentinel-3 for Science Workshop**, v. 734, p. 21, 2015.



## CAPÍTULO II

### ANÁLISES MÉTRICAS E ESTATÍSTICA DE FILTRAGENS ESPACIAIS EM IMAGEM SENTINEL-1 SAR NA AMAZÔNIA, BRASIL

#### Resumo

Objetivou-se com esse estudo comparar o desempenho de sete técnicas de filtragem espacial para redução do ruído *speckle* na imagem do satélite Sentinel-1 SAR na região de Parintins, Amazônia Central. O desenvolvimento metodológico do estudo consistiu na obtenção da imagem por meio do catálogo eletrônico da ESA-Copernicus e posteriormente realizou-se o processamento digital de imagem por etapas: definição de órbita, calibração radiométrica, correção do terreno pelo Ranger doppler, filtragem do ruído *speckle* e conversão do valor de retroespalhamento para decibéis no *software* SNAP 6.0. Utilizaram-se métricas estatísticas e o teste não paramétrico t-Student ao nível de significância 95% para análise de desempenho dos filtros. Em geral, os métodos de filtragem apresentaram bons desempenhos métricos e estatísticos, entretanto, o filtro de mediana com janela  $11 \times 11$  demonstrou ser uma técnica de filtragem alternativa para a dupla polarização VH e VV, pois apresentou ótimos resultados estatísticos para a imagem SAR.

Palavras Chave: Sensoriamento remoto; radar de abertura sintética; geoprocessamento; índices métricos; filtros espaciais.

#### Abstract

The objective of this study was to compare the performance of seven spatial filtering techniques to reduce speckle noise in the Sentinel-1 SAR satellite image in the Parintins region, Central Amazon. The methodological development of the study consisted in obtaining the image through the electronic catalog of ESA-Copernicus and later the digital image processing that was carried out in stages: orbit definition, radiometric calibration, terrain correction by Doppler Ranger, speckle noise filtering, and conversion of the backscatter values to decibels in the SNAP 6.0 software. Statistical metrics and the non-parametric t-Student test at 95% significance level were used to analyze the performance of the filters. In general, the filtering methods presented good

metric and statistical performances, however, the median filter with  $11 \times 11$  window proved to be an alternative filtering technique for the VH and VV dual polarization, as it presented excellent statistical results for the SAR image.

Keywords: Remote sensing; synthetic aperture radar; geoprocessing; metric indices; spatial filters.

## II.1 Introdução

Atualmente houve um crescimento considerável de obtenção de imagens por meio de dados de sensores remotos. Dentre os diversos modos de obtenção de imagens, destacam-se as imagens por aquisição dos veículos aéreos não tripuláveis (VANT), sensores ópticos e imagens de radar de abertura sintéticas (SAR). As imagens dos VANT apresentam a desvantagem de captar pequenas áreas por imageamento em baixa altitude de sobrevoo, o que não ocorre na grande maioria das imagens de satélites, pois proporcionam uma visão sinóptica, maior visada de imageamento, periodicidade de varredura e enorme acervo de imagens gratuitas. Em determinadas regiões terrestres com baixa latitude, como na região deste estudo na Amazônia Central, ocorre intensa cobertura de nuvem, limitando o uso dos sistemas passivos, isto é, imagens ópticas de satélites por não conseguir transpor as nuvens (FORQUOR et al., 2014).

Além da transposição de nuvens, os sinais provenientes de sensores de radar são sensíveis às propriedades do solo (umidade e rugosidade) e da vegetação (estrutura e biomassa), proporcionando informação adicional dos tipos de cobertura do solo, relativamente à obtida através de imagens óticas (JIN et al., 2014).

Segundo Novo (2014), os sistemas sensores são definidos conforme a aquisição dos dados em ativos ou passivos, sendo que os passivos dependem da propagação da radiação eletromagnética para aquisição dos dados. Os sensores remotos ativos, em que se incluem os radares, geram a sua própria energia eletromagnética que é transmitida do sensor para a superfície do terreno, interage com este produzindo um retroespalhamento da energia que é registrada pelo receptor do sensor remoto (JENSEN, 2011).

Dentre os radares imageadores, existem os radares de abertura real (*Real Aperture Radar* – RAR) e os radares de abertura sintética (*Synthetic Aperture Radar* – SAR), onde “abertura” significa antena. Um sistema SAR usa um sofisticado

processamento de sinais para sintetizar uma antena maior do que seu tamanho físico real para a mesma finalidade (ALMEIDA, 2008). Uma imagem de radar é uma matriz bidimensional de pixels onde cada pixel é formado por um número complexo (amplitude e informação de fase) associado à refletividade dos espalhadores contidos dentro da célula de resolução do radar (LEE & POTTIER, 2009). Usualmente, os sistemas de radar utilizam polarizações lineares paralelas, HH e VV, ou cruzadas, HV e VH, em que a primeira letra refere-se à polarização da radiação transmitida e a segunda à polarização da radiação recebida pela antena (LEE & POTTIER, 2009).

Em 2014, foi lançado, pela Agência Espacial Europeia (ESA), o satélite Sentinel-1 com um sensor de micro-ondas SAR operante na banda C (ESA, 2017). As imagens Sentinel-1 são adquiridas nos modos de polarização única (HH ou VV) ou dupla (HH/HV ou VV/VH) e com uma alta resolução espacial e temporal. Porém, no Brasil, essas imagens Sentinel-1 SAR estão disponíveis apenas nas polarizações direta VV e cruzada VH.

O principal fator de interferência associado à interpretação de imagens de radar é a presença do ruído *speckle* (DONG et al., 2001; BREKKE & SOLBERG, 2005; TELLO et al., 2006; CHANG et al., 2007; SANTOSO et al., 2016). Este ruído é inerente ao sistema, causado por interferências locais construtivas ou destrutivas no sinal de retorno retroespalhado pela superfície. O *speckle* gera, na imagem, uma aparência granular composta por mudanças bruscas no nível de cinza em pixels espacialmente próximos (FU & HOLT, 1982; BENTZ, 2006; NUTHMMACHOT et al., 2017). Desse modo, o *speckle* é uma forma de ruído que degrada a qualidade das imagens, interferindo em todas as etapas de detecção dos alvos escuros que, para amenização, é recomendada a utilização do processamento em múltiplas visadas (*multi-look*) ou a aplicação de filtros para sua suavização (DONG et al., 2001; SRINIVAS & PANDA, 2013).

As técnicas de filtragem apresentam a vantagem de manter mais próximo os valores reais de retroespalhamento dos alvos nas imagens de radar. Na região em estudo, ocorre uma carência de dados de cunho geoespaciais, o que de fato fez-se jus ao desenvolvimento de análise de alvos por meio de imagens do satélite Sentinel-1. Todavia, para uma análise criteriosa dos dados inseridos na imagem, é necessário testar estatisticamente qual método de filtragem é mais adequado para cada polarização, pois

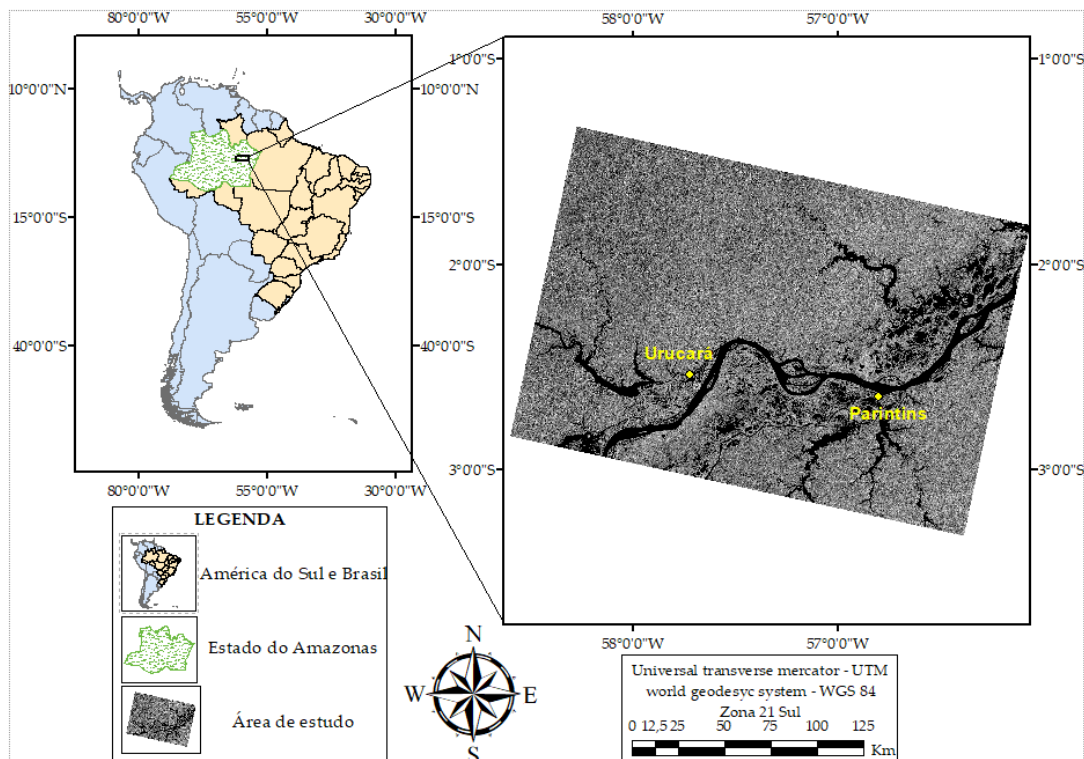
se comprova que a potencialidade do filtro é diferente para cada região mapeada devido à distinção de alvos em cada região geográfica.

Diante do exposto, o objetivo deste estudo é comparar o desempenho de sete diferentes técnicas de filtragens espaciais para redução do ruído nas imagens do satélite Sentinel-1 SAR na Amazônia Central.

## II.2 Material e métodos

### II.2.1 Área de estudo

O estudo foi desenvolvido entre os municípios de Urucará e Parintins a leste do município de Manaus, estado do Amazonas. A região em estudo situa-se em um trecho do rio Amazonas no quadrante com as seguintes coordenadas geográficas:  $2^{\circ} 32' 11''$  S e  $57^{\circ} 45' 38''$  W; e  $2^{\circ} 37' 42''$  S e  $56^{\circ} 44' 11''$  W na projeção Universal Transverse Mercator (UTM), Zona 21 Sul, no sistema de referência World Geodesic System (WGS84) (**Figura II.1**).



**Figura II.1** Mapa de Localização geográfica da área de estudo na Amazônia Central, Brasil.

## II.2.2 Caracterização climática

O clima é do tipo "Am" na classificação de Köppen com precipitação anual de 1.355 mm a 2.839 mm. A temperatura média oscila de 25,6 °C a 27,6 °C, com umidade relativa do ar variando de 84% a 90% ao longo do ano; os meses mais chuvosos vão do período de dezembro a maio e com estiagem nos meses de agosto a novembro (FISCH et al., 1998).

## II.2.3 Processamento digital de imagem – PDI

Realizou-se a aquisição de uma cena SAR da área em estudo por meio do site da ESA no endereço eletrônico (<https://scihub.copernicus.eu/dhus/#/home>). As imagens Sentinel-1 apresentam quatro diferentes modos de aquisição: *Stripmap* (SM); *Interferometric Wide Swath* (IWS); *Extra Wide Swath* (EW); e *Wave* (WV) (**Tabela II.1**).

**Tabela II.1** - Parâmetros dos modos de aquisição da missão Sentinel-1 SAR.

Modo	Ângulo Incidente	Resolução Espacial	Largura de Faixa	Polarização
SM	20° - 45°	5 × 5 m	80 km	HH/HV, VV/VH, HH, VV
IW	29° - 46°	5 × 20 m	250 km	HH/HV, VV/VH, HH, VV
EW	19° - 47°	20 × 40 m	400 km	HH/HV, VV/VH, HH, VV
WV	22° - 35° 35° - 38°	5 × 5 m	20 × 20 km	HH, VV

Fonte: ESA (2017).

A imagem utilizada na pesquisa compreende parte da região da Amazônia Central na data de 26 de setembro de 2016, no modo interferométrico IW, descendente, nas polarizações VH e VV e processada no nível 1. Este nível de pré-processamento indica que a imagem é fornecida com um processamento de calibração inicial de dados. Cada cena IW é formada por uma composição de três observações sobre o solo, que produz uma imagem com 250 km de largura de faixa e resolução espacial de 10 metros. Os produtos resultantes são *single-look complex* (SLC) ou *ground range detected* (GRD).

Utilizou-se, nesse estudo, o produto GRD e posteriormente realizaram-se os processamentos iniciais para o tratamento das informações deste produto na seguinte sequência metodológica: no toolbox Graph Builder, primeiramente aplicou-se o *Appy*

*Orbit File*, *Radiometric Calibrate* ( $\sigma_0$ ) e o *Correction Geometric* pelo método de *Range-Doppler Terrain Correction*. No *Speckle Filter*, analisou separadamente cada técnica de filtragem. Para finalizar o processamento, converteu-se o valor de linear da imagem para valores em decibéis (dB). Metodologia semelhante para o tratamento inicial em imagens SAR foi demonstrado nos estudos de Rahman & Sumantyo (2010) e Furtado et al. (2016).

De acordo com Lee & Pottier (2009), as imagens SAR possuem ruídos que prejudicam a interpretação visual dos dados. Com o intuito de amenizar esses ruídos, diversos filtros têm sido desenvolvidos. Nesse sentido, no presente estudo compararam-se estatisticamente os dados de retroespalhamento e visual das imagens pós-filtragem do ruído. Os testes estatísticos e métricas consideraram 200 amostras distribuídas uniformemente por toda a imagem referência com diâmetro de 5.000 km<sup>2</sup>. O mapa do projeto TerraClass de uso e ocupação da terra do ano de 2016 foi utilizado como suporte para distinção e localização de cada alvo na imagem de radar (ALMEIDA et al., 2016).

As amostras coletadas correspondem a áreas de floresta amazônica, corpos hídricos e área urbana em quatro repetições diferentes nos respectivos alvos, com a finalidade de testar a normalidade dos dados obtidos por meio do teste estatístico *t-student* ao nível de significância de 95% (**Figura II.2**). Utilizaram-se os seguintes filtros com três dimensões de janelas ( $3 \times 3$ ,  $7 \times 7$  e  $11 \times 11$ ), Frost; Gamma Map; Lee Enhanced; Lee; IDAM 1, 2 e 3; mediana; e Boxcar.

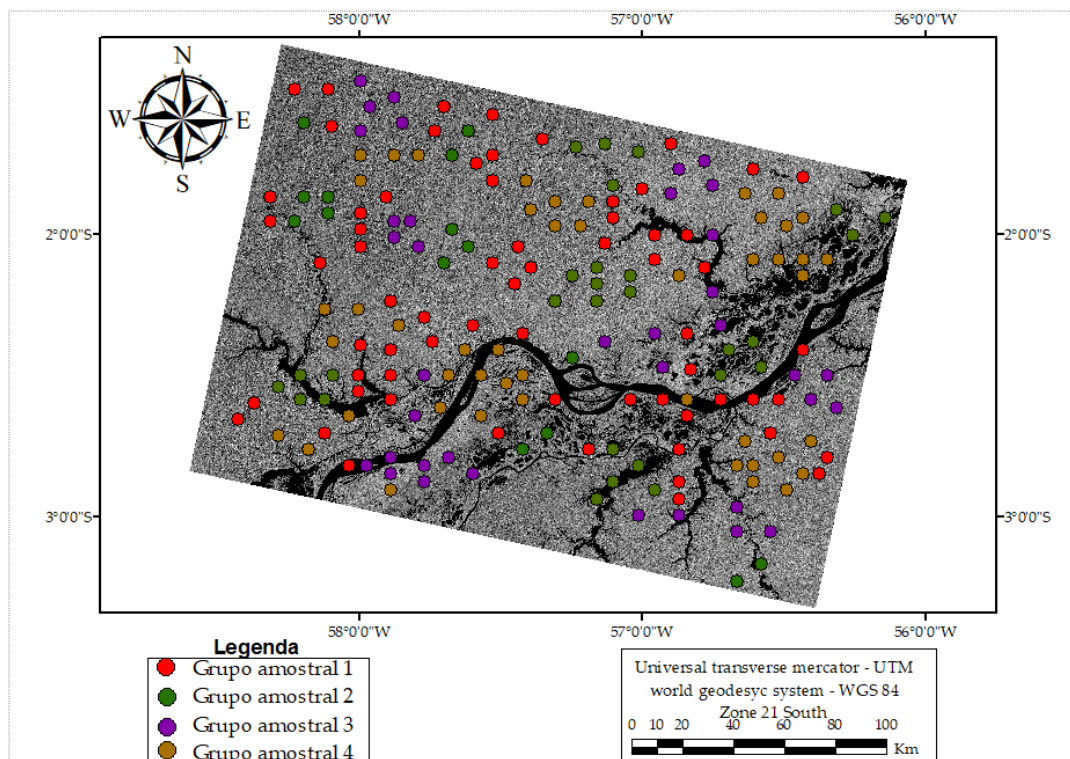


Figura II.2 Localização espacial das amostras casualizadas na área de estudo na Amazônia Central.

Os aplicativos computacionais empregados no tratamento das imagens foram o S1-Toolbox, desenvolvido na plataforma Sentinel Application Platform (SNAP), versão 6.0.0, e ArcGIS 10.6 nas etapas de geoprocessamento e validação dos dados.

## Técnicas de Filtragem

### II.2.4 Filtro Mediana

O Filtro da mediana é um método de transformação comum para suavizar os ruídos do tipo impulsivo em sinais de imagens digitais. A filtragem provoca um amaciamento do sinal ao descartar pontos muito altos ou muito baixos com relação à média do sinal, sem, no entanto, borrar as bordas das regiões como no caso do filtro passa-baixa.

O filtro de mediana é um filtro de vizinhança onde o valor de um pixel (x,y) é substituído pela mediana dos valores dos pixels da sua vizinhança. O valor mediano é aquele cujos elementos são menores ou iguais em valor, ou, são maiores ou iguais em valor na lista ordenada.

### **II.2.5 Filtro Boxcar**

Este filtro apresenta, como característica, capacidade de atenuar com muito rigor as altas frequências presente na imagem, mantendo as baixas frequências. É o filtro mais reconhecido para redução do ruído *speckle*, sendo convolucional, linear e geral por não apresentar um modelo específico para o ruído (SANT'ANNA, 1996).

Este filtro consiste em substituir um pixel (valor observado) pela média aritmética dos níveis de cinza de uma janela  $J \times J$  centrada nesse pixel. O algoritmo de filtragem BOXCAR é um filtro polarimétrico que substitui cada pixel da imagem por uma média de valores calculada para uma janela englobando um pixel central. Todos os canais de varredura na imagem de entrada são filtrados independentemente. A aplicação do BOXCAR é vantajosa, pois reduz o *speckle* preservando a informação polarimétrica da imagem (VASCONCELOS, 2016).

### **II.2.6 Filtro Lee**

De acordo com Lee (1980), este filtro tem a capacidade de transformar o modelo multiplicativo a uma aproximação usando um modelo linear por meio da expansão em série de Taylor em 1ª ordem em torno da média. Esta técnica utiliza estatística local para minimizar o Erro Quadrático Médio (EQM), por meio do filtro de Wiener. O filtro Lee é um filtro adaptativo e tem, como característica, a preservação de bordas nas imagens filtradas (LEE, 1980).

Este filtro estima o valor de um pixel através da soma ponderada do valor do pixel central e da média. A ponderação considerada é obtida como uma função da heterogeneidade dos sinais que compõe o valor do pixel. O valor  $\hat{x}$  do pixel corrente  $(x,y)$  é associado pelo filtro de Lee, de acordo com a Equação 1.

$$\hat{x} = \bar{x} + k(z - \bar{x}) \quad (1)$$

em que:

x: média local da janela;

z: valor do pixel corrente; e



k: coeficiente adaptativo entre 0 e 1.

### **II.2.7 Filtro Frost**

É um filtro convolucional e linear que minimiza o EQM, incorporado a dependência dos pixels vizinhos (correlação exponencial entre os pixels). É adaptativo e preserva estruturas do tipo bordas. O filtro de Frost substitui o pixel de interesse pela soma ponderada dos valores interiores à janela ( $n \times n$ ) (MANSOURPOUR et al., 2006). A ponderação de fatores decresce com a distância do pixel de interesse aos pixels locais e é definido por meio da Equação 2.

$$DN = \sum_{m \times n} k a e^{-a/t/} \quad (2)$$

em que:  $a = \left(\frac{4}{n\sigma^{-2}}\right) \cdot \left(\frac{\sigma^2}{I^2}\right)$ ;

K: constante de normalização;

I: média local;

$\sigma$ : variância local;

$\sigma^-$ : imagem com valor de coeficiente de variação;

t: expresso pela fórmula  $(x - x_0) + (y - y_0)$ ; e

n: resolução espacial do pixel.

### **II.2.8 Filtro Refined Lee**

Lee e Pottier (2009) propuseram um aprimoramento do sigma no filtro Lee, que apresenta deficiências, tais como: o viés dos dados filtrados, pontos pretos permanecendo nas imagens, borramento e omissão de objetos. A variação de sigma (I1, I2) foi redefinida baseando-se nas distribuições teóricas do *speckle*.

Assim, o novo intervalo para a seleção dos pixels, para qualquer média x, pode ser calculado como (I1 x, I2 x). A média x é estimada por meio do erro quadrático médio mínimo (MMSE) dada por Lee (1980) em uma janela  $3 \times 3$ .

### **II.2.9 Filtro Gamma Map**

Conforme Lopes et al. (1990), o Máximo a Posteriori (MAP) é um filtro baseado no modelo do ruído multiplicativo, com os parâmetros de média e variância não

estacionários. Este filtro assume que o valor do número digital original está entre o nível digital ou valor de retroespalhamento do pixel de interesse e da janela Kernel (MANSOURPOUR et al., 2006). De acordo com Lopes et al. (1990), o algoritmo de Gamma Map incorpora a hipótese de que, em áreas naturais, a seção transversal em Gamma é a mais apropriada para representar o modelo de distribuição, conforme representado pela Equação 3 de ordem cúbica.

$$I^3 - II^2 + \sigma(I - ND) = 0 \quad (3)$$

em que:

I: valor procurado;

II: média local;

DN: valor digital de entrada do pixel;

$\sigma$ : variância da imagem original.

#### ***II.2.10 Filtro Intensity-driven adaptive-neighborhood – IDAN***

O filtro IDAN possui a característica de possuir um alto número de amostras, preservando a estacionaridade e a resolução espacial da imagem pós-filtragem. Nessa técnica, ao invés de empregar janelas alinhadas com bordas, é definido um conjunto de pixels estacionários que cercam o pixel em análise, adaptando-se à morfologia local dos dados (VASILE et al., 2006).

Nesse sentido, nesse método de filtragem, considera-se apenas a informação fornecida pelos elementos diagonais das matrizes de covariância para determinar os pixels estacionários (FOUCHER & MARTÍNEZ, 2014).

O processo de busca do valor do vizinho mais próximo é iniciado por meio dos valores médios de um pixel derivado com janela  $3 \times 3$  e o valor estimado da matriz de covariância é obtido por meio do valor médio dos pixels dentro do vizinho mais próximo adaptável.

#### ***II.2.11 Métricas de Avaliação da Qualidade de imagens SAR***

A definição da melhor técnica de filtragem utilizou medidas ou métricas quantitativas de qualidade das imagens, tais como: Erro Quadrático Médio (EQM), Erro

Absoluto Médio (MAE), Relação Sinal Ruído (SNR), Pico de Relação Sinal Ruído (PSNR), Índice de Preservação de Borda (EPI), Coeficiente de Correlação de Pearson, Distorção de Contraste (DCON) e Número Equivalente de *Looks* (NEL).

### ***II.2.11 Erro médio quadrático (Mean Square Error – MSE)***

Este parâmetro é utilizado no intuito de encontrar diferenças da média entre o sinal das amostras da imagem ruidosa e a imagem filtrada, sendo definida pela Equação 4. Na comparação entre os filtros, é desejável um baixo valor para o MSE.

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{s}_i - s_i) \quad (4)$$

em que:

$\hat{s}_i$  e  $s_i$ : os  $i$ -ésimos pixels da imagem filtrada;

$\hat{s}$ : imagem original ruidosa;

$s$ : imagem filtrada;

$N$ : tamanho (quantidade de pixels) da imagem.

### ***II.2.12 Erro Absoluto Médio – MAE***

A estimativa do erro absoluto médio é definida conforme a Equação 5. Assim como na métrica MSE, é desejável um baixo valor para o MAE.

$$MAE = \frac{1}{n} \sum_{j=1}^n (x_j - y_j) \quad (5)$$

em que:

$x_j$  e  $y_j$ : coordenadas dos pixels das duas imagens.

### ***II.2.13 Relação Sinal-Ruído – SNR***

A relação sinal-ruído (SNR) em imagens SAR é expressa pela razão entre o desvio-padrão e a média em regiões homogêneas, onde os dados se ajustam ao modelo multiplicativo. Valores abaixo de  $0,5222/\sqrt{N}$  em que  $N$  é número de visadas da

imagem, indicam uma redução do desvio-padrão do ruído e de sua intensidade (MARQUES, 2004).

Para comparação entre os filtros, é desejável um maior valor de SNR. A relação entre o sinal e o ruído da imagem é definido por meio da Equação 6.

$$SNR = 10 \log_{10} \left( \frac{\sum_{i=1}^n s_i^2}{\sum_{i=1}^n (\hat{s}_i - s_i)^2} \right) \quad (6)$$

#### **II.2.14 Pico de Relação Sinal-Ruído – PSNR**

Este parâmetro representa a relação entre a potência máxima possível do sinal obtido e a imagem de ruído. É a medida do desempenho da redução de ruído *speckle* na imagem. Uma imagem de melhor qualidade é indicada por um alto valor de PSNR. Quanto maior o valor de PSNR significa que mais o ruído foi removido. Essa relação é calculada por meio da Equação 7.

$$PSNR = 10 \log_{10} \left( \frac{2^{n-1}}{MSE} \right)^2 \quad (7)$$

#### **II.2.15. Distorção de Contraste – DCON**

A métrica distorção de contraste realiza uma comparação entres as imagens com ruído *speckle* e após a filtragem. Essa métrica é calculada conforme a Equação 8.

$$DCON = \frac{1}{n} \sum_{i=1}^n \frac{(x_j - y_j)}{v + x_j + y_j} \quad (8)$$

em que:

v: relação entre a luminância e o nível de cinza do display. A utilização do valor  $v = 23/255$  para esta métrica é sugerida por Baxter & Seibert (1998).

### ***II.2.16 Número Equivalente de Looks – NEL***

Esse parâmetro representa a equivalência de valores médios de intensidade independentes por pixel. Este parâmetro é aplicado não apenas para descrever os dados originais, mas também para caracterizar os efeitos de suavização de operações de pós-processamento.

O NEL para uma região homogênea de uma imagem é a razão entre a média ao quadrado da variância, sendo definido por meio da Equação 9.

$$NEL = \frac{(4-\pi)}{\pi} \times \frac{(1)}{Cv} \quad (9)$$

em que:

$Cv$ : coeficiente de variação amostral estimado. Vale ressaltar que a SNR é diretamente proporcional ao NEL, ou seja, quanto maior o NEL maior também será o SNR.

### ***II.2.17 Análise Estatística de similaridade t-Student***

O teste não paramétrico de similaridade *t-Student* ao nível de 0,05% de significância foi utilizado para diferir estatisticamente as técnicas de filtragem nas imagens Sentinel-1. Para analisar a similaridade entre a imagem não filtrada e filtrada, utilizou-se a análise da variância, desvio-padrão e o coeficiente de correlação de Pearson, cujo valor obtido estará entre  $-1$  e  $1$ , em que os valores mais próximos de  $1$  significa que houve uma maior similaridade positiva entre a imagem original e a imagem filtrada, já valores negativos representa uma maior similaridade negativa. As etapas realizadas para o desenvolvimento deste estudo estão sintetizadas conforme o fluxograma (**Figura II.3**).

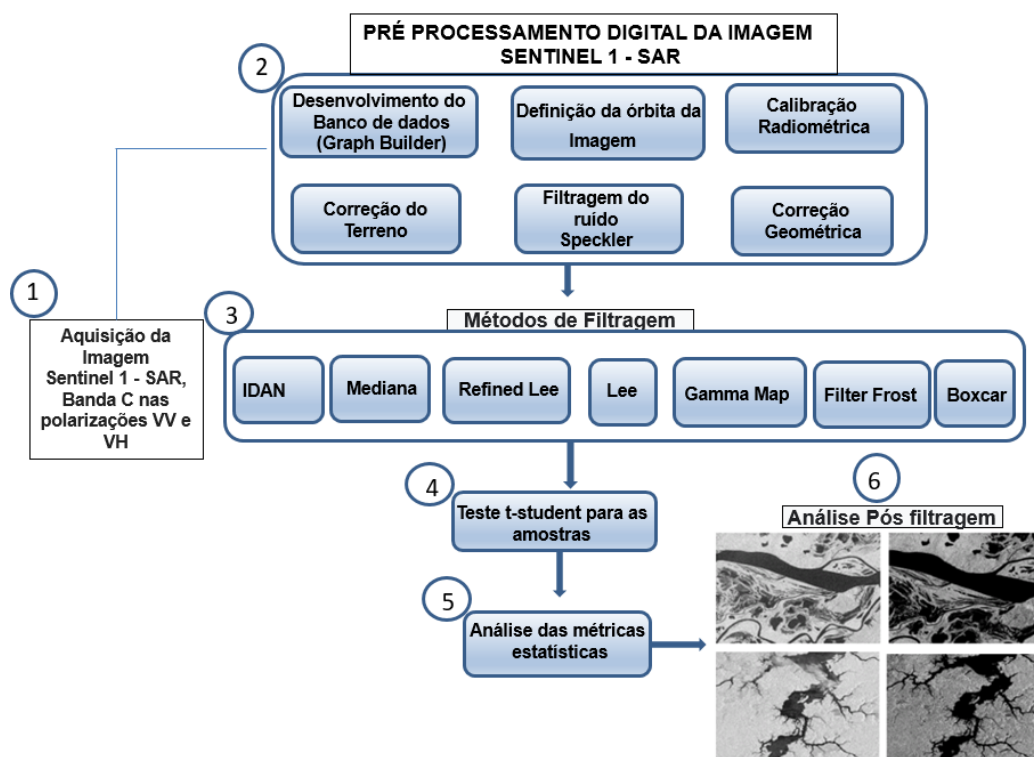
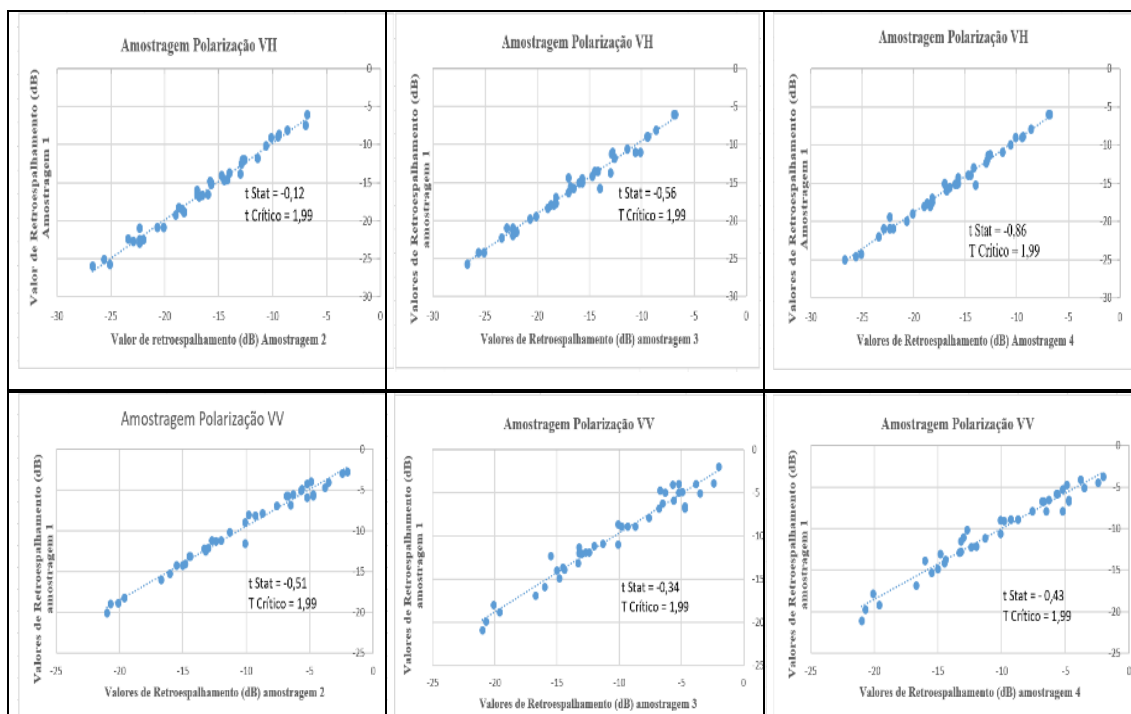


Figura II.3 Fluxograma metodológico das etapas de desenvolvimento do estudo.

## II.3 Resultados e discussão

O teste *t-Student* indicou que ocorreu uma normalidade para os dados amostrais quando analisados entre as quatro amostragens independentes na realização dos métodos de filtragens para as polarizações VH e VV da imagem Sentinel-1 SAR (Figura II.4). Comprovou-se, por meio do teste estatístico, a hipótese de igualdade entre os dados amostrais, apresentando um nível de significância com p valor menor que 0,05%.

As amostragens testadas apresentaram valores de t calculado abaixo do t crítico bi-caudal, com 1,99. Desse modo, não ocorreu diferença estatística significativa entre as amostras coletadas, comprovando a homogeneidade entre as amostras de retroespalhamento coletadas na imagem.



**Figura II.4** Desempenho das três áreas de amostragens nas polarizações VH e VV por meio do teste t de *student* ao nível de 0,05% de significância estatística.

As Tabelas II.2 e II.3 mostram os valores das métricas de qualidade para cada filtro na polarização VH e VV. Na polarização VH, a imagem filtrada pelo filtro Lee  $3 \times 3$  apresentou os melhores resultados na redução do ruído com o menor MSE (1,88) e MAE (1,638), como também os maiores valores de PSNR (13,35) e SNR (10,27).

A maioria dos filtros apresentaram resultados aproximados. No entanto, o filtro Frost  $3 \times 3$  apresentou uma discrepância entre as filtragens na polarização VH com alto de MSE (8,95). A polarização VV apresentou resultados diferentes da polarização VH, onde o melhor desempenho foi o filtro Frost com janela  $3 \times 3$  com baixos valores de MSE (1,2), MAE (6,28) e de distorção de contraste, quando comparado com a imagem original. Em geral, as métricas na polarização VV apresentaram valores concisos e aproximados. Contudo, o filtro IDAM 3 apresentou valores discrepantes dos demais com alto valor de MSE (6,4).

A polarização VV apresentou resultados diferentes da polarização VH, onde o melhor desempenho foi o filtro Frost com janela  $3 \times 3$  com baixos valores de MSE (1,2), MAE (6,28) e de distorção de contraste, quando comparado com a imagem original.

Em geral, as métricas na polarização VV apresentaram valores concisos e aproximados. Contudo, o filtro IDAM 3 apresentou valores discrepantes dos demais

com alto valor de MSE (6,4) para o MSE. Os valores obtidos por meio das métricas são apresentados nas Tabelas II.2 e II.3.

**Tabela II.2** - Valores referente aos Índices métricos para as técnicas de filtragem na polarização VH.

Filtros VH	MSE (dB)	MAE (dB)	SNR (dB)	PSNR (dB)	CoC	DCON (dB)	NEL (dB)	Cvar	$\sigma$	Media
Frost 3x3	8,95	1,634	4,1377	12,68	0,4702	1,7266	4,641	0,803	0,032	0,0405
Frost 7x7	2,88	1,638	8,6336	13,17	0,6994	1,7224	13,443	0,472	0,018	0,0395
Frost 11x11	2,68	1,637	8,9233	13,2	0,7222	1,7231	21,345	0,374	0,016	0,044
G M 3x3	3,89	1,641	6,804	13,04	0,6011	<b>1,719</b>	12,664	0,486	0,019	0,0395
G M 7x7	2,60	1,636	9,184	13,21	0,7361	1,724	22,513	0,365	0,016	0,044
G M 11x11	3,40	1,636	8,033	13,1	0,6303	1,724	<b>23,899</b>	0,354	0,016	0,045
Refined Lee	3,91	1,638	7,6331	13,04	0,644	1,721	7,782	0,620	0,023	<b>0,038</b>
Lee 3x3	<b>1,88</b>	<b>1,633</b>	<b>10,277</b>	<b>13,35</b>	<b>0,824</b>	1,722	8,454	0,595	0,022	<b>0,038</b>
Lee 7x7	2,490	1,636	9,6613	13,23	0,751	1,724	15,130	0,445	0,019	0,043
Lee 11x11	2,713	1,635	9,2503	13,19	0,725	1,725	20,795	0,379	0,017	0,045
IDAM 1	2,73	1,638	8,294	13,19	0,714	1,722	16,784	0,422	0,017	0,0421
IDAM 2	2,915	1,640	8,030	13,16	0,696	1,720	18,564	0,401	0,016	0,0400
IDAM 3	3,551	1,640	7,1902	13,08	0,614	1,720	17,560	0,413	0,016	0,0399
Mediana 3x3	3,46	1,637	8,2216	13,09	0,662	1,723	11,829	0,503	0,021	0,043
Mediana 7x7	3,64	1,637	7,7089	13,07	0,6112	1,723	15,084	0,445	0,018	0,041
Mediana 11x11	3,43	1,6394	7,4250	13,09	0,6212	1,72138	22,818	<b>0,362</b>	<b>0,015</b>	0,0415
Boxcar 3x3	3,48	1,638	8,0076	13,09	0,6602	1,72218	1,4121	0,556	0,08	0,1609
Boxcar 7x7	2,22	1,637	8,5251	12,28	0,6747	1,72378	1,9142	0,400	0,062	0,1556
Boxcar 11x11	2,17	1,636	8,4309	12,29	0,669	1,7242	2,9944	1,0009	0,043	0,0438

**Tabela II.3**- Valores referente aos Índices métricos para as técnicas de filtragem na polarização VV.

Filtros VV	MSE (dB)	MAE (dB)	SNR (dB)	PSNR (dB)	CoC	DCON (dB)	NEL (dB)	Cvar	$\sigma$	Media
Frost 3x3	<b>1,2</b>	<b>6,26</b>	<b>13,54</b>	<b>12,51</b>	<b>0,91</b>	6,59	12,09	0,49	0,77	0,15
Frost 7x7	3,4	6,28	8,97	12,09	0,75	6,59	17,67	0,41	0,63	0,15
Frost 11x11	4,5	6,27	8,11	11,97	0,64	6,59	21,78	0,37	0,61	0,16
G M 3x3	2,1	6,28	11,58	12,29	0,85	6,59	11,65	0,5	0,81	0,16
G M 7x7	3,9	6,27	8,92	12,03	0,7	6,6	18,38	0,4	0,66	0,165
G M 11x11	4,4	6,27	8,06	11,98	0,65	6,59	23,48	0,35	0,58	0,16
Refined Lee	4,1	6,29	7,86	12,01	0,7	<b>6,58</b>	14,02	0,46	0,67	0,14
Lee 3x3	3,7	6,27	9,44	12,06	0,74	6,6	11,559	0,5	0,81	0,16
Lee 7x7	4,9	6,27	7,78	11,93	0,61	6,59	18,17	0,4	0,65	0,16
Lee 11x11	5	6,27	7,73	11,92	0,6	6,6	21,23	0,37	0,6	0,16
IDAM 1	3,5	6,28	8,7	12,08	0,75	6,59	19,74	0,38	0,59	0,152



<b>IDAM 2</b>	4	6,28	8,33	12,02	0,7	6,59	20,13	0,38	0,59	0,154
<b>IDAM 3</b>	6,4	6,29	5,77	11,82	0,5	<b>6,58</b>	15,45	0,44	0,62	0,142
<b>Mediana 3x3</b>	2,5	6,29	3,76	11,22	0,22	<b>6,58</b>	10,49	0,53	0,74	0,14
<b>Mediana 7x7</b>	4,7	6,28	7,43	11,95	0,63	6,59	19,81	0,38	0,6	0,15
<b>Mediana 11x11</b>	5	6,28	6,99	11,92	0,6	<b>6,58</b>	25,58	<b>0,34</b>	<b>0,54</b>	0,16
<b>Boxcar 3x3</b>	3	6,28	8,34	11,15	0,68	6,59	18,74	1,45	0,6	<b>0,041</b>
<b>Boxcar 7x7</b>	2,9	6,27	7,14	11,16	0,55	6,59	24,62	1,25	<b>0,54</b>	0,043
<b>Boxcar 11x11</b>	2,9	6,27	7,55	11,15	0,57	6,6	<b>39,78</b>	1	1	0,043

Em ambas as polarizações VH e VV, o filtro de mediana  $11 \times 11$  apresentou resultados próximos às melhores técnicas e obteve o melhor desempenho estatístico de coeficiente de variação, desvio-padrão e média. Os baixos valores para os índices estatísticos comprovaram a eficiência do filtro de mediana  $11 \times 11$  nas imagens filtradas para as duas polarizações.

Nuthmmachot et al. (2017) compararam o desempenho de filtros em imagens Sentinel-1 na região da bacia hidrográfica do lago Songkhla na Tailândia e obtiveram, como melhor resultado, o filtro Gamma Map  $7 \times 7$ . Pode-se inferir que o filtro Gamma Map não obteve resultados semelhantes a esse estudo, devido à distinção de alvos analisados nas cenas entre os dois países, pois no estudo na Tailândia apresentou maior predominância de culturas agrícolas na cena SAR, já para a Amazônia central foi a maior presença de floresta tropical, corpos hídricos, áreas inundáveis e área urbanas.

Hatwa & Kher (2015) utilizaram e compararam técnicas de filtros adaptativos para na eliminação do ruído *speckle* em imagens do satélite Sentinel-1 SAR. Os autores atribuíram pesos distintos para as respectivas variâncias de 0,01 e 0,4 por meio da linguagem de programação no *software* Matlab. Diante dessa adaptação, os filtros que apresentaram melhores desempenhos estatísticos foram os filtros Enhanced Lee para a variância 0,1 e Enhanced Kuan para a variância 0,4.


Kuck et al. (2022) analisou a performance de diversos filtros espaciais para amenização do ruído Speckle em alvos in presentes no bioma Amazônico por meio de imagens SAR do satélite COSMO Sky-Med, como resultado neste estudo os autores obtiveram os melhores resultados métricos de desvio padrão ENL e  $ENL_{ratio}$  para o filtro


Lee com janela 3 x 3, por ser um estudo desenvolvido em áreas semelhantes, corrobora com os desempenhos métricos obtidos pelo filtro Lee nessa pesquisa.

Neste estudo, o filtro Lee Refined apresentou um bom desempenho de filtragem perante as duas polarizações, obtendo o melhor valor de média com 0,038 na polarização VH e melhor valor para a distorção de contraste com 6,38 na polarização VV.

Santoso et al. (2016) corroboraram com os resultados obtidos neste estudo ao analisar o desempenho das métricas estatísticas para imagens ALOS- PALSAR após a redução do ruído *speckle*. Os resultados obtidos demonstraram melhor desempenho para o filtro Frost nos parâmetros SNR, ENL e SSIM. Entretanto, esses autores observaram uma maior preservação de bordas por meio do filtro Lee. Nesse artigo, os alvos com maiores predominâncias são: os corpos hídricos, área urbana e vegetação que são os alvos também com maior predominância neste estudo na Amazônia Central.

A **Figura II.5** demonstra a imagem original do entinel-1 nas polarizações VH e VV. Os alvos mais distinguíveis e de maior presença são os corpos hídricos, floresta Amazônica e área urbana da região do município de Parintins, AM. Nessa figura, foram selecionadas essas áreas com aplicação de zoom para melhor distinção visual da imagem pós-filtradas por meio das técnicas Lee 3 × 3 na polarização VH e Frost 3 × 3 na polarização VV, que, respectivamente obtiveram os melhores desempenhos para os índices métricos.





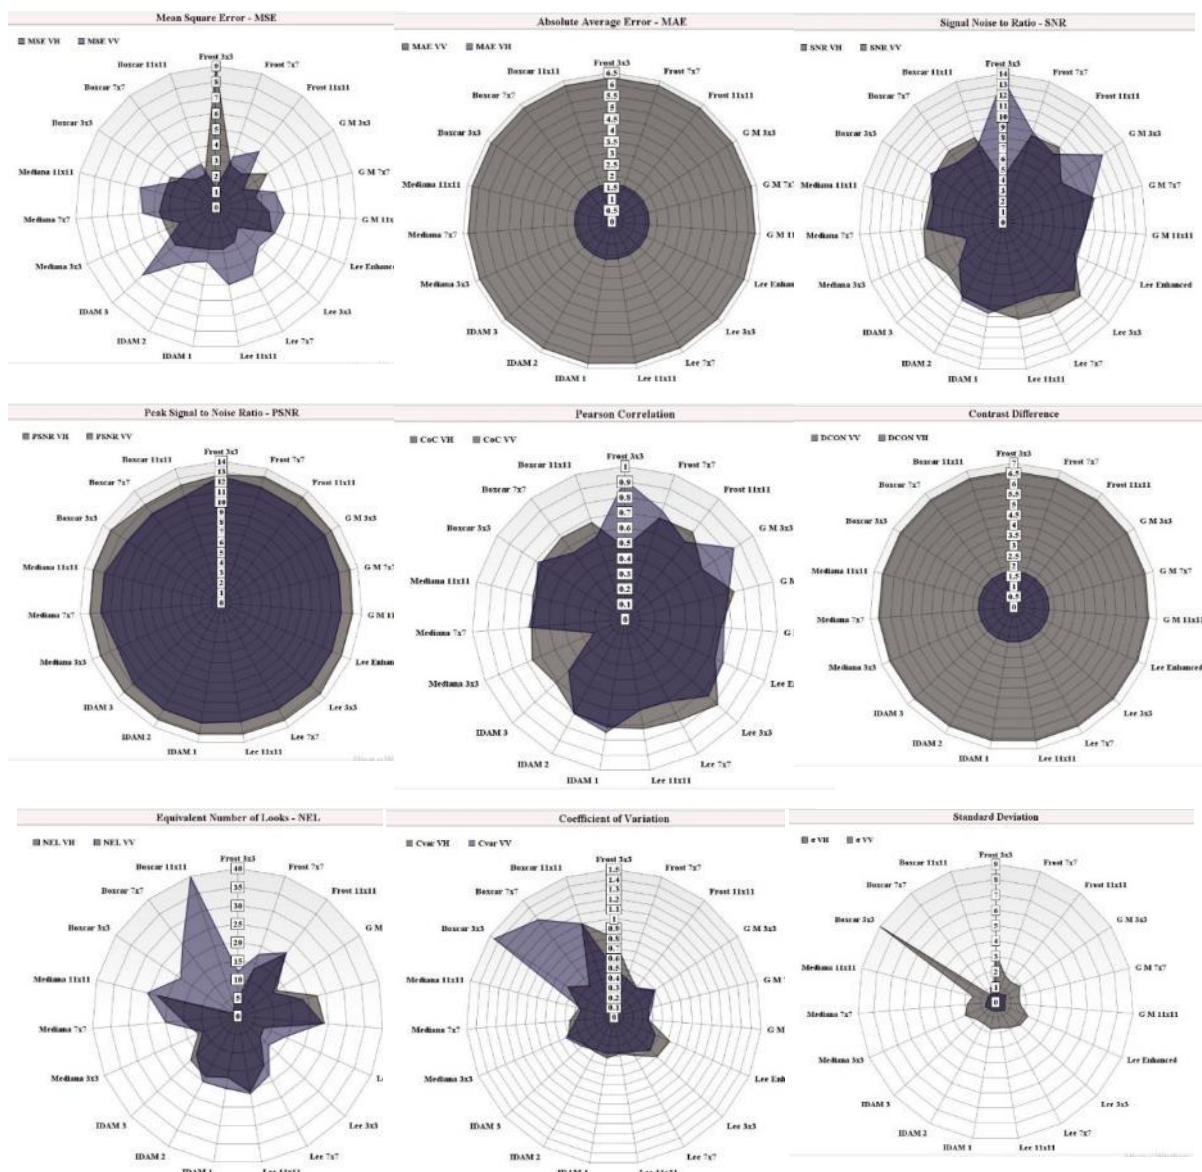
**Figura II.5** Imagem Sentinel-1 SAR, polarizações VH e VV, imagem filtrada por meio do filtro Lee 3x3 na polarização VH e filtro Frost 3x3 na polarização VV com ênfase visual nos alvos, Floresta Amazônica, corpos hídricos e área urbana de Parintins, AM.

A análise visual das imagens filtradas nas duas polarizações da imagem Sentinel-1 permitiu distinguir uma maior presença de ruído *speckle* nos corpos hídricos, quando comparado às áreas florestais e urbanas.

Os corpos hídricos e a floresta amazônica apresentam semelhança na análise visual para as duas polarizações após a filtragem do ruído *speckle* tanto para as técnicas de filtragem Frost  $3 \times 3$  quanto para o Lee  $3 \times 3$ . Já na análise visual da área urbana, comprovou-se que a imagem de SAR na polarização VV apresentou uma maior discriminação para esta classe de uso e ocupação, com a prevalência de pixels mais claros e mais distinguíveis quando comparado com a polarização VH.

Após a filtragem, a imagem com polarização VV também apresentou maior nitidez do alvo área urbana, aumentando a análise visual e distinguindo da floresta amazônica que são alvos próximos na área em estudo. Em geral, os valores nas métricas estatísticas para as filtrações na polarização VH apresentaram os melhores resultados quando analisado aos valores métricos obtidos pela polarização VV na área de estudo.

Para ilustrar a comparação entre os valores obtidos para cada índice métrico nas distintas polarizações, é apresentado por meio do gráfico da **Figura II.6**.



**Figura II.6** Gráfico dos valores métricos mensurados para as polarizações VH e VV na região de Parintins, AM.

Nas polarizações VH e VV, as métricas MAE, DCON e PSNR apresentaram os valores mais próximos entre todas as técnicas de filtragem. Entretanto, na análise estatística, os resultados demonstram diferenças entre as filtragens, tendo como destaque o filtro Boxcar com janela  $3 \times 3$  com os maiores valores para a variância e desvio-padrão na polarização VV.

## II.4 Conclusões

Em geral, os métodos de filtragem obtiveram bom desempenho métrico e estatístico, com valores aproximados para os índices nas sete técnicas de filtragem.

Os filtros Frost com janela  $3 \times 3$  na polarização VH e o filtro IDAN 3 na polarização VV apresentaram os piores performances para redução do ruído *speckle*, sendo desaconselhável o uso na região da Amazônia Central.

Por meio da análise estatística e visual, comprova-se que a polarização VV na imagem Sentinel-1 apresenta alta interferência do ruído *speckle* nos corpos hídricos, como também os maiores valores métricos.

Por apresentar os melhores valores estatísticos, o filtro de mediana com janela  $11 \times 11$  nas polarizações VH e VV, pode-se ser utilizado como técnica de filtragem alternativa na imagem Sentinel-1 SAR para as duas polarizações.

As melhores técnicas de filtragem foram analisadas pelo conjunto dos resultados obtidos por meio das métricas estatísticas. Contudo, para uma análise de parâmetros específicos na imagem SAR, outros filtros fazem jus, pois neste estudo alguns filtros apresentaram melhores valores métricos e estatísticos quando comparados com o Lee  $3 \times 3$  na polarização VH e Frost  $3 \times 3$  na polarização VV.

## Referências

- Almeida, F. C. (2008). Simulação de resposta de estruturas simplificadas de vegetação ao Radar de Abertura Sintética Interferométrico. (Dissertação de Mestrado, Instituto Nacional de Pesquisas Espaciais). Repositório do Instituto Nacional de Pesquisas Espaciais. [http://bdtd.ibict.br/vufind/Record/INPE\\_1ceafe6ab219d08c92db8fe9e16f0b44](http://bdtd.ibict.br/vufind/Record/INPE_1ceafe6ab219d08c92db8fe9e16f0b44)
- 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. (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*. <https://doi.org/10.1590/1809-4392201505504>
- Baxter, R.; & Seibert, M. (1998). Synthetic aperture radar image coding. *Lincoln Laboratory Journal*. 121-158.
- Brekke, C.; & Solberg, A. H. S. (2005). Oil Spill Detection by Satellite Remote Sensing. *Remote Sensing of Environment*. 1-13,. <https://doi.org/10.1016/j.rse.2004.11.015>
- Dellepiane, S. G.; & Angiati, E. (2017). Quality Assessment Despeckled SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*. 3803-3806,. <https://doi.org/10.1109/JSTARS.2013.2279501>
- Dong, Y. M.; Milne, A. K.; Forster, B. C. (2001). Segmentation and Classification of Vegetated Areas Using Polarimetric SAR Image Data. *IEEE Transactions on Geoscience and Remote Sensing*. 321-329. <https://doi.org/10.1109/36.905240>

- ESA. (2017). European Space Agency. Consultado em 20 de dezembro de 2020. <https://sentinel.esa.int/web/sentinel/home>
- Kuck, T. N.; Gomez, L. D.; Sano, E. E.; Bispo, P. C. Honório, D. D. C. 2022. Performance of Speckle Filters for COSMO-SkyMed Images from the Brazilian Amazon. *IEEE Geoscience and remote sensing letters*. 19: 1-5.
- Fisch, G.; Marengo, J. A.; Nobre, C. A. (1998). Uma revisão geral sobre o clima da Amazônia. *Acta Amazonica*. 101-126. <https://doi.org/10.1590/1809-43921998282126>
- Fu, L. L.; & Holt, B. (1982). *Seasat Views Oceans and Sea Ice with Synthetic-Aperture Radar*. NASA/JPL. Institute of technology Pasadena.
- Furtado, L. F. A.; Silva, T. S. F.; Novo, E. M. L. M. (2016). Dual-season and full-polarimetric C band SAR assessment for vegetation mapping in the Amazon varzea wetlands. *Remote Sensing of Environment*. 212-222. <https://doi.org/10.1016/j.rse.2015.12.013>
- Forkuor, G.; Corand, C.; Thiel, M.; Ulmann, T.; Zoungrana, E. (2014). Integration of Optical and Synthetic Aperture Radar Imagery for Improving Crop Mapping in Northwestern Benin, West Africa. *Remote Sensing*. 6472-6499. <https://doi.org/10.3390/rs6076472>
- Foucher, S.; & López-Martínez, C. (2014). Analysis, Evaluation, and Comparison of Polarimetric SAR Speckle Filtering Techniques. *IEEE Transactions on Image Processing*. 1751-1764. <https://doi.org/10.1109/TIP.2014.2307437>
- Jensen, J. R. (2011). *Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres*. Parêntese.
- Jin, H.; Mountrakis, G.; Stehman, S. V. (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*. 70-84, <https://doi.org/10.1016/j.isprsjprs.2014.09.017>
- Lee, J. S. (1980). Digital image enhancement and noise filtering by use of local statistics. *IEEE Trans. Pattern Analysis and Machine Intelligence*. 165-168. <https://doi.org/10.1109/TPAMI.1980.4766994>
- Lee, J. S.; & Pottier, E. (2009). *Polarimetric SAR Radar Imaging: From Basic to Applications*. CRC Press.
- Lopes, A.; Touzi, R.; Nezry, E. (1990). Adaptive speckle filters and scene heterogeneity. *IEEE Trans. Geoscience and Remote Sensing*, 992-1000. <https://doi.org/10.1109/36.62623>
- Mansourpour, M.; Rajabi, M. A; Blais, J. A. R. (2006). Effects and performance of speckle noise reduction filters on active radar and SAR images. In *Proc. ISPRS*. (pp. 1-9). Meubook

<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.70.1197&rep=rep1&type=pdf>

- Marques, R. C. P. (2004). Filtragem de Ruído Speckle em Imagens de Radar de Abertura Sintética e Avaliação dos Efeitos sobre a Segmentação. [Dissertação de Mestrado, Universidade Federal do Ceará].
- Novo, E. M. L. M. (2014). Sensoriamento Remoto: Princípios e Aplicações. Blucher.
- Sant'anna, S. J. S. (1995). Avaliação de Filtro redutores do speckle em imagens de radar de abertura sintética. [Dissertação de Mestrado, Instituto Nacional de Pesquisas Espaciais]. Repositório do Instituto Nacional de Pesquisas Espaciais. <http://mtc-m12.sid.inpe.br/col/sid.inpe.br/iris@1912/2005/07.20.06.48.47/doc/publicacao.pdf>
- Santos, A. W.; Bayuaji, L.; Tien Sze. L.; Lateh, H.; Zai, J. M. (2016). Comparison of Various Speckle Noise Reduction Filters on Synthetic Aperture Radar Image. International Journal of Applied Engineering Research. 8760-8767. <https://doi.org/10.1109 / ICCSP.2018.8524250>
- Srinivas, R.; & Panda, S. (2013). Performance Analysis of Various Filters for Image Noise Removal in Different Noise Environment. International Journal of Advanced Computer Research. 2277-7970.
- Tello, M.; Lopez-Martinez, C.; Mallorqui, J. J. (2006). Automatic vessel monitoring with single and multidimensional SAR images in the wavelet domain. ISPRS Journal of Photogrammetry & Remote Sensing. 260-278. <https://doi.org/10.1016 / j.isprsjprs.2006.09.012>
- Vasconcelos, A. O. (2016). Modelagem da biomassa do manguezal da APA de Guapi-Mirim utilizando dados multitemporais polarimétricos do sensor Radarsat-2. [Tese de doutoramento, Universidade Federal do Rio de Janeiro]. Repositório da Universidade Federal do Rio de Janeiro. [http://labsar.lamce.coppe.ufrj.br/pdf/VASCONCELOS\\_AO\\_TD\\_16.pdf](http://labsar.lamce.coppe.ufrj.br/pdf/VASCONCELOS_AO_TD_16.pdf)
- Vasile, G.; Trouvé, E.; Lee, J.; Buzuloiu, V. (2006). Intensity-Driven-Adaptive-Neighborhood Technique for Polarimetric and Interferometric SAR Parameters Estimation. IEEE Transactions on Geoscience and Remote Sensing,. 1609–1621. <https://doi.org/10.1109 / TGRS.2005.864142>

### CAPÍTULO III

## ANÁLISE DE SÉRIE TEMPORAL SENTINEL-1 SAR EM INUNDAÇÕES NA AMAZÔNIA CENTRAL

### **Resumo**

Este estudo teve, como objetivo, analisar a dinâmica das áreas alagadas da série temporal Sentinel-1 SAR em um trecho da Amazônia Central no período entre 26 de setembro de 2016 e 8 de fevereiro de 2020. O total de imagens foi de 59 para cada polarização. Além disso, a pesquisa calculou a linha de inundação ordinária média (LMEO) a partir das alturas das réguas fluviométricas entre os anos de 1967 a 2020 e a comparou com os valores presentes na série temporal do radar. O pré-processamento da série temporal Sentinel-1 nas polarizações VV e VH utilizou a seguinte sequência metodológica: correção de órbita, correção radiométrica ( $\sigma_0$ ), correção do terreno, filtragem do ruído, e conversão dos dados para decibéis (dB). A análise prévia dos filtros adaptativos mostrou resultados diferentes para as duas polarizações, obtendo o melhor resultado para a polarização VV utilizando o filtro Frost com  $3 \times 3$  e para a polarização VH o filtro Lee  $3 \times 3$ . A extração de corpos d'água e áreas úmidas utilizou um valor limite fazendo máscaras para todo o período. A maior extensão da área inundável foi medida em 17 de junho de 2019, com 6.611,86 km<sup>2</sup>, representando 16,42% da cena SAR na polarização VH e 6.443,19 km<sup>2</sup>, representando 16,10% da cena SAR na polarização VV. A relação entre as áreas úmidas VH e VV em relação à altura da régua foi satisfatória, com coeficientes de determinação ( $R^2$ ) de 0,79 na polarização VH e de 0,64 na polarização VV e p-valor menor que 0,05. No período das imagens do Sentinel-1, não há valores iguais ou superiores ao LMEO, mas foi possível analisar a dinâmica fluvial e as áreas de inundação do rio Amazonas.

Palavras-Chave: Sensoriamento Remoto; Radar; Mapeamento de Corpos Hídricos.

### **Abstract**

This study aimed to analyze the dynamics of the flooded areas of the Sentinel-1 SAR time series in a section of the Central Amazon between 26 September 2016 and 8 February 2020. The total of images was 59 for each polarization. In addition, the study calculated the average ordinary flood line (ALOF) from the heights of the fluviometric



rulers between the years 1967 to 2020 and compared it with the values present in the radar time series. The pre-processing of the Sentinel-1 time series in the VV and VH polarizations used the following methodological sequence: Apply Orbit File, Radiometric Calibration ( $\sigma_0$ ), Range-Doppler Terrain Correction, Speckle Filter, and conversion to decibels (dB). The previous analysis of the adaptive filters showed different results for the two polarizations, obtaining the best result for the VV polarization using the Frost filter with  $3 \times 3$  and the VH polarization with the Lee filter  $3 \times 3$ . The extraction of water bodies and wetlands used a threshold value, making masks for the entire period. The most considerable extent of the floodable area occurred on 17 June 2019, with 6,611.86 km<sup>2</sup>, representing 16.42% of the SAR scene in the VH polarization and 6,443.19 km<sup>2</sup>, representing 16.10% of the SAR scene in the VV polarization. The relationship between the VH and VV wetlands to the ruler's height was satisfactory, with coefficients of determination ( $R^2$ ) of 0.79 in the VH polarization and of 0.64 in the VV polarization and a p-value less than 0.05. In the period of the Sentinel-1 images, there were no values equal to or greater than the ALOF, but it was possible to analyze the fluvial dynamics and the flooding areas of the Amazon River.

Keywords: Remote sensing; Radar; Mapping of Water Bodies.

### **III.1 INTRODUÇÃO**

As extensões mais significativas de áreas inundáveis no Brasil estão nos biomas Pantanal e Amazônia. O rio Amazonas é responsável por aproximadamente 12% da área úmida total da bacia amazônica, possuindo uma grande variedade de fitofisionomias herbáceas, arbustivas e arbóreas, tanto terrestres quanto aquáticas (MELACK & HESS, 2010).

No território nacional, as áreas úmidas adjacentes aos rios federais são de propriedade da União. A Constituição Federal de 1988, em seu artigo 20, define que a União administra as seguintes áreas: terrenos baldios, lagos, rios e eventuais cursos d'água em terras sob seu domínio; ilhas fluviais e lacustres em áreas de fronteira com outros países; as praias do mar; ilhas oceânicas e costeiras; o mar territorial; as terras da marinha; recursos minerais; sítios arqueológicos e pré-históricos; e terras indígenas, entre outros (BRASIL, 1988).

O Decreto-Lei nº 9.760, de 5 de setembro de 1946, define Terras Marginais como áreas banhadas por águas navegáveis, fora do alcance das marés, com quinze metros medidos horizontalmente em direção a terra contados a partir da Linha Média de Inundações Ordinárias (LMEO). A definição de Terras Marginais considera a compreensão da dinâmica do pulso de inundação dos rios federais.

O cálculo da LMEO utiliza dados de séries históricas de estações fluviométricas considerando a média anual máxima da cota de inundação por pelo menos 20 anos. Outro dado crítico é o marco geodésico mais próximo do trecho de demarcação para realizar a etapa de nivelamento topográfico com transposição de cota altimétrica entre o marco geodésico e a estação fluviométrica, obtendo assim a altura topográfica da LMEO (SPU, 2001).

Os extensos rios e áreas desabitadas do bioma Amazônia tornam a aquisição de informações *in situ* bastante custosa devido à demanda de planejamento, equipamentos, transporte e recursos humanos. Assim, técnicas de sensoriamento remoto e geoprocessamento são alternativas viáveis para obtenção e coleta de informações sobre corpos d'água.

As imagens ópticas de satélite na região amazônica apresentam limitações devido à intensa interferência da cobertura de nuvens ao longo do ano (FORQUOR et al., 2014). Portanto, os sistemas de radar são os mais indicados para monitorar essa região por atravessar as nuvens e nebulosidade. Um sistema SAR usa processamento de sinal sofisticado para sintetizar uma antena mais extensa do que seu tamanho físico real. O satélite Sentinel-1 SAR pertencente à missão da Agência Espacial Europeia (ESA) foi lançado em 2014, com um sensor de micro-ondas operando na banda C em polarização simples (HH ou VV) ou dupla (HH/HV ou VV/VH) e alta resolução espacial e temporal.

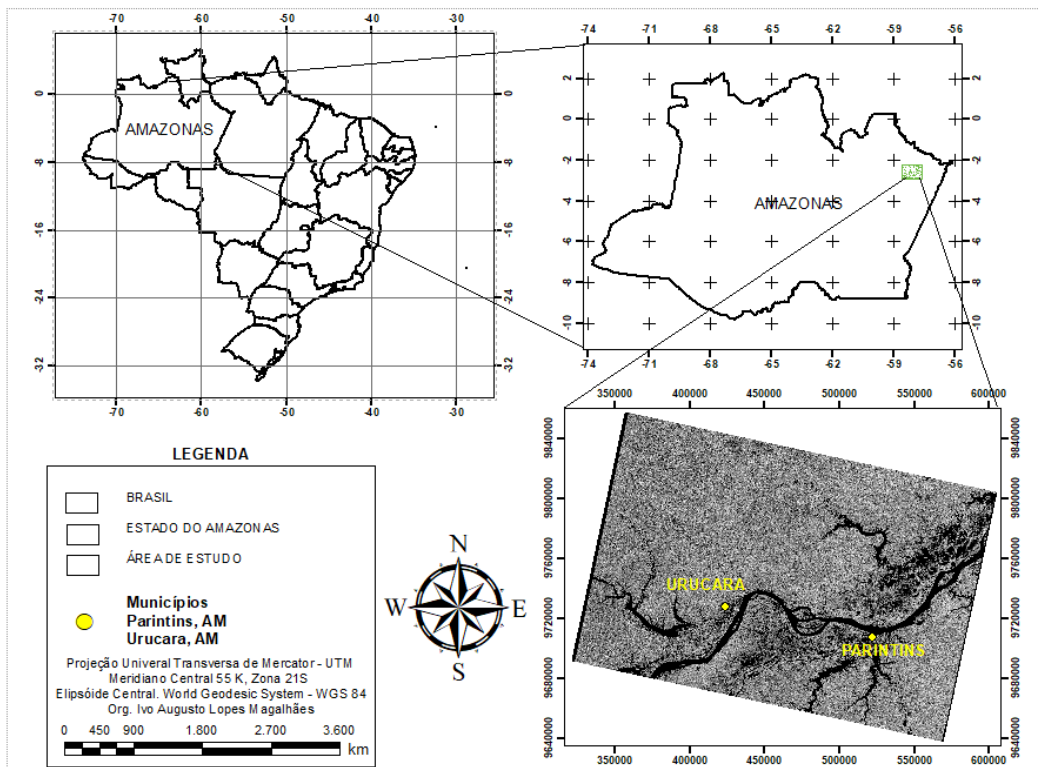
No entanto, o principal fator de interferência associado à interpretação das imagens radar é a presença de ruído *speckle* (TELLO, LOPEZ-MARTINEZ e MALLORQUI, 2006; CHANG et al., 2007; SANTOSO et al., 2016). O ruído *speckle* gera uma aparência granular na imagem, composta por mudanças bruscas no nível de cinza em pixels espacialmente próximos (FURTADO et al., 2016). Portanto, esse ruído degrada a qualidade das imagens, interferindo em todas as etapas de detecção de alvos escuros, exigindo o uso de processamento em múltiplas visualizações (*multi-look*) ou a aplicação de filtros para sua suavização (DONG, MILNE e FORSTER, 2001; FURTADO et al., 2016).

A presente pesquisa visa mensurar as áreas inundáveis e o ALOF através de dados fluviométricos (1967-2020) e séries temporais de imagens Sentinel-1 SAR (2016-2020) em dupla polarização VH e VV em um trecho altamente inundável da Amazônia.

## III.2 MATERIAIS E MÉTODOS

### III.2.1 ÁREA DE ESTUDO

A área de estudo está localizada entre os municípios de Urucará e Parintins a leste de Manaus no estado do Amazonas, compreendendo o rio Amazonas no quadrante com as seguintes coordenadas geográficas:  $2^{\circ} 32' 11''$  S e  $57^{\circ} 45' 38''$  W; e  $2^{\circ} 37' 42''$  S e  $56^{\circ} 44' 11''$  W (**Figura III.1**). O clima é Am na classificação de Köppen, com precipitação anual de 1.355 mm a 2.839 mm. O período de cheia começa em maio e se estende até meados de julho, seguido pelo período seco entre setembro e novembro (RAMALHO et al., 2009).



**Figura III.1** - Localização geográfica da área em estudo na Amazônia Central.

### III.2.2 IMAGENS SENTINEL-1 E PRÉ-PROCESSAMENTO

As imagens Sentinel-1 SAR são disponibilizadas gratuitamente no endereço eletrônico (<https://scihub.copernicus.eu/dhus/#/home>) da Agência Espacial Europeia (ESA), possuindo características distintas (**Tabela III.1**). O presente estudo adquiriu 59 imagens do satélite Sentinel-1 na polarização VH e VV na região da Amazônia Central no período anual entre os dias 26 de setembro de 2016 e 08 de fevereiro de 2020. As imagens correspondem ao modo *Interferometric Wide* (IW), modo descendente, e com nível 1 *Ground Range Detected* (GRD). O pré-processamento utilizou o programa SNAP considerando a seguinte sequência metodológica: Appy Orbit File, Radiometric Calibrate ( $\sigma_0$ ), Correction Geometric (Range-Doppler Terrain Correction), Speckle Filter e conversão dos dados de linear para decibéis (dB).

**Tabela III.1** - Parâmetros dos modos de aquisição da missão Sentinel-1.

Modo	Ângulo Incidente	Resolução Espacial	Largura de Faixa	Polarização
SM	20° - 45°	5 × 5 m	80 km	HH/HV, VV/VH, HH, VV
IW	29° - 46°	5 × 20 m	250 km	HH/HV, VV/VH, HH, VV
EW	19° - 47°	20 × 40 m	400 km	HH/HV, VV/VH, HH, VV
WV	22° - 35° 35° - 38°	5 × 5 m	20 × 20 km	HH, VV

Fonte: ESA (2017).

Os programas empregados nas fases de geoprocessamento e validação dos dados foram Envi 5.5 e ArcGIS 10.6. A extração temporal das áreas inundáveis utilizou a técnica de máscara no cubo temporal de imagens SAR a partir da definição de um valor limite dos corpos hídricos, usando o programa Envi 5.5. Subsequentemente, as máscaras dos corpos d'água foram convertidas para vetores para mensuração das áreas inundadas e a definição da LMEO para a região em estudo.

### III.2.3 FILTRAGEM DOS DADOS

O ruído *speckle* causado pela interferência aditiva ou destrutiva do sinal de retorno do radar para cada célula prejudica a interpretação visual das imagens (LEE & POTTIER, 2009). A seleção do melhor filtro para cada polarização considerou sete métodos de filtragem (Frost; Gamma Map; Lee Enhanced; Lee; IDAM 1, 2 e 3; mediana; e Boxcar) em três dimensões de janelas (3 × 3, 7 × 7 e 11 × 11). A análise utilizou 40 amostras distribuídas uniformemente por toda a imagem de referência com tamanho de 5.000 km<sup>2</sup>. As métricas analisadas foram: Erro Quadrático Médio (MSE),

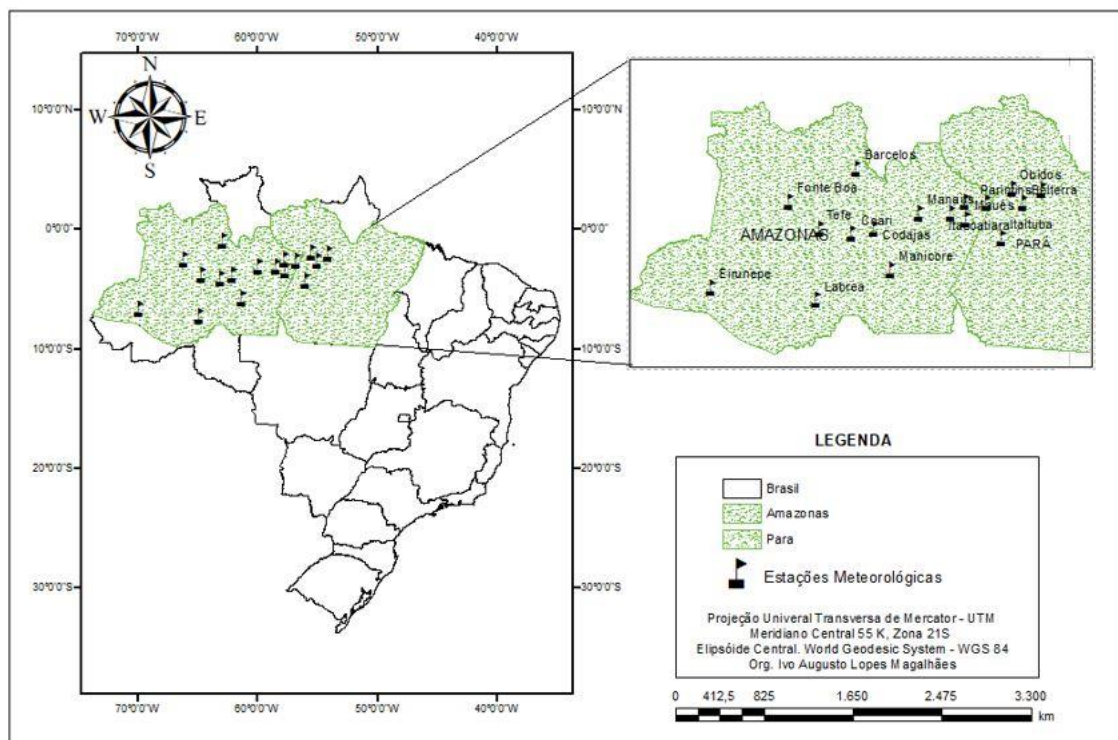
Erro Absoluto Médio (MAE), Relação Sinal Ruído (SNR), Pico de Relação Sinal Ruído (PSNR), Índice de Preservação de Borda (EPI), Distorção de Contraste (DCON) e Número Equivalente de Looks (NEL).

### III.2.4 CUBO TEMPORAL DE IMAGENS

A montagem do cubo temporal considerou as 59 imagens Sentinel-1 nas polarizações VH e VV para o período de 26/09/2016 a 08/02/2020. O cubo temporal apresenta nos eixos “x (linhas)” e “y (colunas)” as coordenadas geográficas e no eixo “z” a trajetória temporal com a sequência dos dias em ordem crescente (CARVALHO JÚNIOR et al., 2008). O atributo z do cubo temporal descreve a presença das áreas inundáveis nas duas polarizações VH e VV.

### III.2.5 OS CAMPOS DE VENTO

A velocidade do vento influencia nos valores de retroespalhamento no rio Amazonas, Lago Grande e Lago Moratinga, nas polarizações VH e VV. Os dados de velocidade do vento (m/s) utilizados são provenientes do sistema do Banco de Dados Meteorológicos de Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET) (**Tabela III.2**). A pesquisa utilizou 14 postos pluviométricos inseridos na Amazônia Central e 3 postos inseridos no estado do Pará, com o objetivo de eliminar o efeito de borda no processo de interpolação (GARDIMAN JÚNIOR et al., 2012). A interpolação da velocidade do vento utilizou as médias das 17 estações, compreendendo os mesmos dias das imagens SAR entre 01/09/2016 e 08/02/2020 (**Figura III.2**). De acordo com Gardiman Junior et al. (2012), a técnica de interpolação *spline* regularizada mantém o mesmo valor do dado amostral na estação, além de ser um método determinístico, exato e não convexo.



**Figura III.2** - Mapa das estações meteorológicas utilizadas para interpolação dos campos de vento na Amazônia Central, estado do Pará.

**Tabela III.2** - Nomenclatura das estações meteorológicas e dados da velocidade do vento.

Estação	Município e Estado	Latitude	Longitude	Velocidade média do vento (mps)
82240	Parintins, AM	-2,630	-56,730	1,03
A1222	Maués, AM	-3,399	-57,673	1,14
82317	Tefé, AM	-3,830	-64,700	0,52
82425	Coari, AM	-4,080	-63,130	1,15
82331	Manaus, AM	-3,110	-59,950	0,91
82336	Itacoatiara, AM	-3,130	-58,430	1,13
82113	Barcelos, AM	-0,960	-62,910	0,99
82326	Cadajás, AM	-3,830	-62,080	1,93
82533	Manicoré, AM	-5,8100	-61,300	0,68
82445	Itaituba, PA	-4,2800	-56,000	0,94
82178	Obidos, AM	-1,910	-55,510	1,66
82246	Belterra, PA	-2,630	-54,950	0,94
82181	Monte Alegre, PA	-2,000	-54,080	2,99
82723	Labrea, AM	-7,2500	-64,830	1,9
82212	Fonte Boa, AM	-2,530	-66,160	1,1

82610	Eirunepe, AM	-6,660	-69,860	0,04
A124	Urucará, AM	-2,534	-57,758	1,12

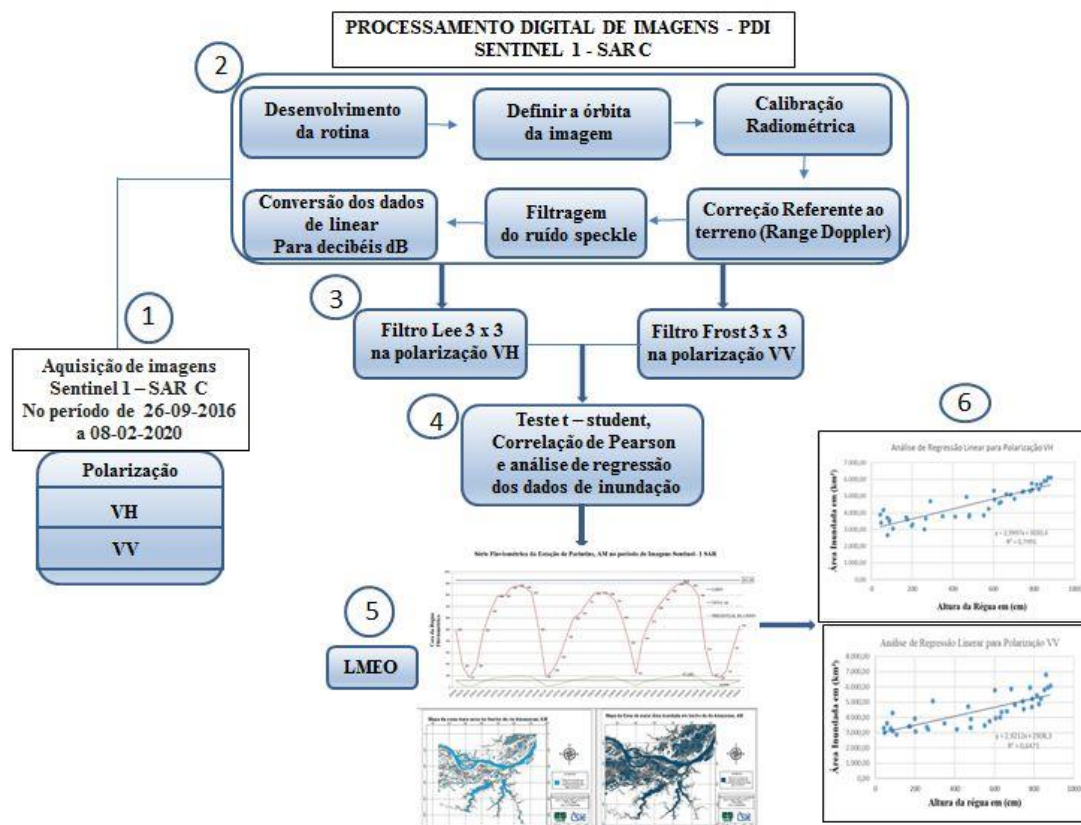
Fonte: INMET (2020).

### III.2.6 CÁLCULO DA LINHA MÉDIA DE ENCHENTE ORDINÁRIA – LMEO

O cálculo da LMEO utilizou os dados fluviométricos da série histórica (1967-2020) do rio Amazonas no município de Parintins, obtidos por meio do site hidroweb (<http://www.snirh.gov.br/hidroweb/>) da Agência Nacional de Águas (ANA). Os procedimentos técnicos obedeceram a Orientação Normativa de demarcação de Terrenos Marginais (SPU, 2001). O cálculo da LMEO utilizou uma série histórica de 65 anos, referente à estação de código 16350002 da ANA, considerando um período de retorno de mínimo de 3 anos e máximo de 20 anos, por meio da média da somatória das maiores leituras mensais da régua do rio, obtendo-se uma LMEO em centímetros baseada na régua local para o rio Amazonas na região de Parintins, AM. Esse dado deve ser posteriormente calculado a obter sua altitude topográfica. O dia da cota mais próxima a LMEO (em 65 anos) na curta série temporal SAR (4 anos) corresponde à maior área inundada.

### III.2.7 ANÁLISE ESTATÍSTICA DOS DADOS TEMPORAIS

A análise de regressão linear e a correlação de Pearson compararam os seguintes dados: valores mensurados entre as polarizações VH e VV, relação entre a área de inundação obtida pela série temporal SAR com as cotas fluviométricas da régua e a precipitação acumulada para cada mês na estação meteorológica de Parintins, AM. Essa análise permite estimar uma função entre a área inundada e os dados medidos em campo. O fluxograma metodológico sumariza as etapas de desenvolvimento deste estudo (**Figura III.3**).



**Figura III.3** - Fluxograma metodológico das etapas realizadas na análise de inundação no trecho central do rio Amazonas.

### III.3 RESULTADOS E DISCUSSÃO

#### III.3.1 ANÁLISE DAS TÉCNICAS PARA ATENUAÇÃO DE RUÍDOS NA IMAGEM

O ruído *speckle* é difundido em toda a cena SAR, com alta interferência em corpos d'água. A análise visual das imagens SAR demonstra que a filtragem espacial minimiza significativamente a fração de ruído, aumentando a nitidez do rio Amazonas, corpos d'água e vegetação nas polarizações. As **Tabelas III.3** e **III.4** listam os valores estatísticos das diferentes técnicas de filtragem para imagens SAR nas polarizações VH e VV. Os melhores resultados foram diferentes entre as duas polarizações. Na polarização VH, o filtro Lee  $3 \times 3$  apresentou os melhores resultados na redução de ruído com os menores MSE (1,88) e MAE (1,638), assim como os maiores valores de PSNR (13,35) e SNR (10,27). A maioria dos filtros apresentou resultados aproximados, mas o filtro Frost  $3 \times 3$  apresentou a discrepância mais significativa entre as técnicas de filtragem na polarização VH com alto MSE (8,95), MAE (6,28) e distorção de contraste.



Na polarização VV, o filtro Frost com  $3 \times 3$  obteve o melhor desempenho com valores baixos para MSE (1,2), MAE (628) e janela de distorção de contraste.

**Tabela III.3** - Valores dos índices métricos para as técnicas de filtragem na polarização VH.


Filtros VH	MSE	MAE	SNR	PSNR	CoC	DCON	NEL
Frost 3x3	8,95	1,634	4,1377	12,68	0,4702	1,7266	4,641
Frost 7x7	2,88	1,638	8,6336	13,17	0,6994	1,7224	13,443
Frost 11x11	2,68	1,637	8,9233	13,2	0,7222	1,7231	21,345
G M 3x3	3,89	1,641	6,804	13,04	0,6011	<b>1,719</b>	12,664
G M 7x7	2,60	1,636	9,184	13,21	0,7361	1,724	22,513
G M 11x11	3,40	1,636	8,033	13,1	0,6303	1,724	<b>23,899</b>
Lee Enhanced	3,91	1,638	7,6331	13,04	0,644	1,721	7,782
<b>Lee 3x3</b>	<b>1,88</b>	<b>1,633</b>	<b>10,277</b>	<b>13,35</b>	<b>0,824</b>	1,722	8,454
Lee 7x7	2,490	1,636	9,6613	13,23	0,751	1,724	15,130
Lee 11x11	2,713	1,635	9,2503	13,19	0,725	1,725	20,795
IDAM 1	2,73	1,638	8,294	13,19	0,714	1,722	16,784
IDAM 2	2,915	1,640	8,030	13,16	0,696	1,720	18,564
IDAM 3	3,551	1,640	7,1902	13,08	0,614	1,720	17,560
Mediana 3x3	3,46	1,637	8,2216	13,09	0,662	1,723	11,829
Mediana 7x7	3,64	1,637	7,7089	13,07	0,6112	1,723	15,084
Mediana 11x11	3,43	1,6394	7,4250	13,09	0,6212	1,72138	22,818
Boxcar 3x3	3,48	1,638	8,0076	13,09	0,6602	1,72218	1,4121
Boxcar 7x7	2,22	1,637	8,5251	12,28	0,6747	1,72378	1,9142
Boxcar 11x11	2,17	1,636	8,4309	12,29	0,669	1,7242	2,9944

**Tabela III.4** - Valores dos índices métricos para as técnicas de filtragem na polarização VV.

Filtros VV	MSE	MAE	SNR	PSNR	CoC	DCON	NEL
<b>Frost 3x3</b>	<b>1,2</b>	<b>6,26</b>	<b>13,54</b>	<b>12,51</b>	<b>0,91</b>	6,59	12,09
Frost 7x7	3,4	6,28	8,97	12,09	0,75	6,59	17,67
Frost 11x11	4,5	6,27	8,11	11,97	0,64	6,59	21,78
G M 3x3	2,1	6,28	11,58	12,29	0,85	6,59	11,65
G M 7x7	3,9	6,27	8,92	12,03	0,7	6,6	18,38
G M 11x11	4,4	6,27	8,06	11,98	0,65	6,59	23,48

Lee Enhanced	4,1	6,29	7,86	12,01	0,7	<b>6,58</b>	14,02
Lee 3x3	3,7	6,27	9,44	12,06	0,74	6,6	11,559
Lee 7x7	4,9	6,27	7,78	11,93	0,61	6,59	18,17
Lee 11x11	5	6,27	7,73	11,92	0,6	6,6	21,23
IDAM 1	3,5	6,28	8,7	12,08	0,75	6,59	19,74
IDAM 2	4	6,28	8,33	12,02	0,7	6,59	20,13
IDAM 3	6,4	6,29	5,77	11,82	0,5	<b>6,58</b>	15,45
Mediana 3x3	2,5	6,29	3,76	11,22	0,22	<b>6,58</b>	10,49
Mediana 7x7	4,7	6,28	7,43	11,95	0,63	6,59	19,81
Mediana 11x11	5	6,28	6,99	11,92	0,6	<b>6,58</b>	25,58
Boxcar 3x3	3	6,28	8,34	11,15	0,68	6,59	18,74
Boxcar 7x7	2,9	6,27	7,14	11,16	0,55	6,59	24,62
Boxcar 11x11	2,9	6,27	7,55	11,15	0,57	6,6	<b>39,78</b>

Portanto, a filtragem espacial através de filtros Lee  $3 \times 3$  na polarização VH e Frost  $3 \times 3$  na polarização VV minimizou significativamente a fração de ruído (**Figura III.4**).




**Figura III.4** –Imagem Sentinel-1 dos corpos hídricos na polarização VH (A1) e filtrada pelo Lee  $3 \times 3$  (A2), e na polarização VV (B1) e filtrada pelo Frost  $3 \times 3$ .

### III.3.2 CUBO TEMPORAL DE IMAGENS SAR

O cubo temporal possibilitou a análise da dinâmica sazonal das áreas inundadas, apresentando maior volume dos corpos hídricos nos meses de maio, junho e julho e

menor volume nos meses de novembro, dezembro e janeiro. A **Figura III.5** demonstra que as polarizações VV e VH não apresentam uma diferença visual significativa para os corpos hídricos.




**Figura III.5** - Cubo temporal composto por 59 imagens Sentinel-1 nas polarizações VH e VV entre 26/09/2016 e 08/02/2020.

No entanto, a incapacidade da banda C de penetrar nas copas das árvores (aproximadamente 5 cm) dificulta a medição confiável de áreas úmidas sobre cobertura florestal. Marques et al. (2019) analisaram áreas úmidas usando um cubo temporal de imagens PALSAR/ALOS-2 na Ilha do Bananal, trecho médio do Rio Araguaia no estado do Tocantins. Esses autores concluíram que a variação da área de inundação foi de 10% entre as imagens com os menores e as maiores cotas de inundação.

Ferreira (2018) utilizou um cubo temporal de 29 imagens Sentinel-1 com o método de aprendizado de máquina Random Forest e o valor limite em imagens SAR para identificar áreas úmidas no sul do estado de Roraima ao longo de 2017. Os resultados demonstraram o comportamento típico de áreas alagadas às margens dos rios e feições adjacentes ao Rio Branco. Em julho, o pico da cheia cobriu mais de 72.000 ha da área de estudo, e o pico da seca em dezembro cobriu mais de 37.000 ha.

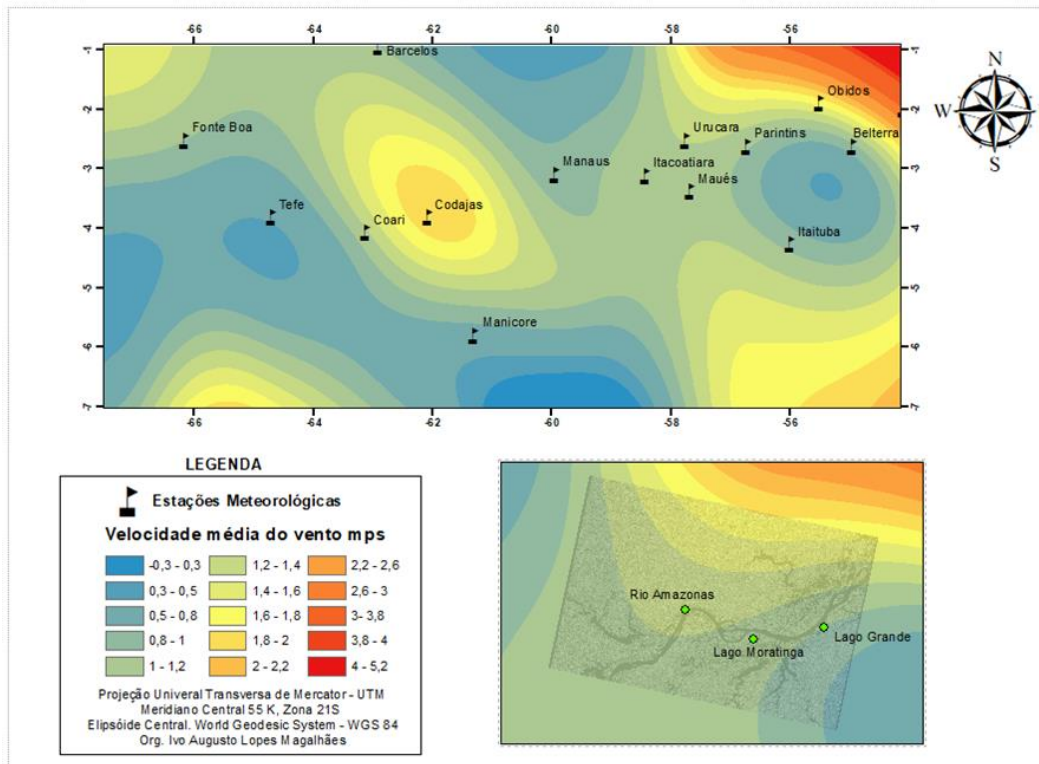
### **III.3.3 CARACTERIZAÇÃO DO RETROESPALHAMENTO SAR DOS CORPOS HÍDRICOS**

A análise temporal dos valores de retroespalhamento SAR possibilitou caracterizar o rio Amazonas, Lago Grande e Lago Moratinga com valores entre -21,49 dB a -25,78 dB, -22,52 dB a -28,2 dB e -21,98 dB a -27,69 dB na polarização VH e -13,34 dB a -23,27 dB, -18,14 dB a -24,57 dB e -17,36 dB a -26,44 dB) para polarização VV (**Figura III.6**).



**Figura III.6** - Gráfico dos valores de retroespalhamento SAR nas polarizações VH e VV no rio Amazonas, Lago Moratinga e Lago Grande na Amazônia Central de 26/09/2016 até 08/02/2020.


Os corpos hídricos da região apresentaram valores de limiares distintos nas duas polarizações, com um valor médio de -19 dB na polarização VH e -14 dB na polarização VV. Outros estudos de águas abertas obtiveram valores similares (ARNESEN, 2012; FERREIRA, 2018; FROTA, 2019). No entanto, os valores de retroespalhamento do rio Amazonas foram maiores nas duas polarizações do que os Lagos Grande e Moratinga, que obtiveram entre eles valores aproximados nas duas polarizações, VH e VV. A causa dessa variação pode ser devido aos seguintes fatores: (a) interferência de campos de vento com velocidade variando entre 1,2 mps a 1,4 mps sobre o rio Amazonas, superiores que os outros dois Lagos (1 mps a 1,2 mps), e (b) ação da correnteza da água contendo maior ondulação no rio e inferindo em uma maior resposta do retroespalhamento SAR (**Figura III.7**). Marinho et al. (2012) corroboram com este estudo ao mensurar valores semelhantes de retroespalhamento de corpos hídricos e áreas inundadas no Vale do Itajaí, estado de Santa Catarina, em imagens SAR do sensor ALOS-PALSAR.



**Figura III.7** - Mapa da velocidade média do vento de 01/09/2016 até 08/02/2020 para Amazônia Central.

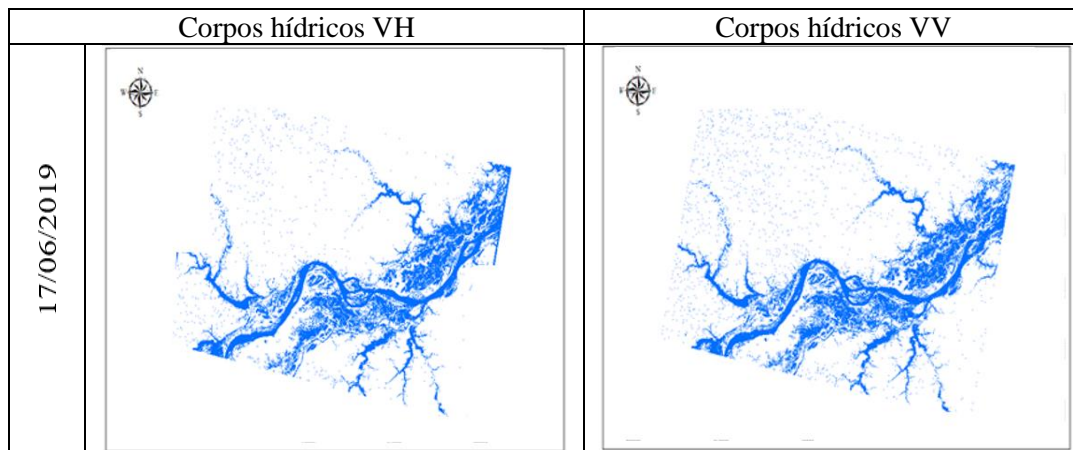
### III.3.4 ANÁLISE DA DINÂMICA PLUVIOMÉTRICA E O PULSO DE INUNDAÇÃO

A série temporal pluviométrica entre 2000 a 2020 na área em estudo demonstrou que as maiores médias mensais ocorreram nos meses de fevereiro (313 mm/ano), março (378 mm/ano) e abril (342 mm/ano). As menores médias pluviométricas mensais ocorreram nos meses de setembro (47 mm/ano), outubro (78 mm/ano) e novembro (89 mm/ano) (**Figura III.8**). Os resultados corroboram com outros estudos (JUNK, 1997; ARNESEN, 2012) que evidenciaram um pulso de inundação de comportamento monomodal anual no rio Amazonas e seus afluentes, uma ocorrência previsível ao longo do ano com o período de cheia entre maio e julho e período de seca entre outubro e dezembro.

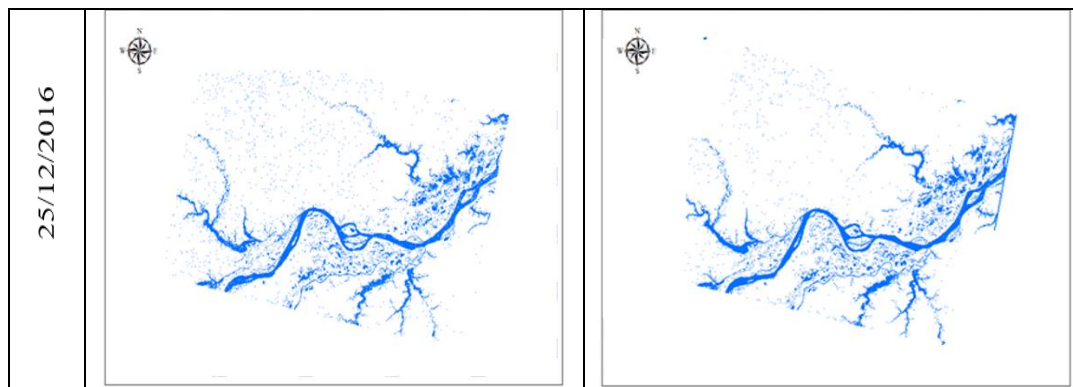


**Figura III.8** - Valores pluviométrico na estação de Parintins (AM), salientando a maior e menor área inundada dentro da série temporal Sentinel-1 para anos de 2000 a 2020.

A maior área inundável ocorreu em 17 de junho de 2019, com 6.611,86 km<sup>2</sup>, representando 16,42% da cena VH e 6.443,19 km<sup>2</sup>, representando 16,10% da cena VV. A menor área inundada ocorreu em 25 de dezembro de 2016, com 3.059,75 km<sup>2</sup>, representando 7,64% da cena SAR na polarização VH e 2.868,59 km<sup>2</sup> de corpos d'água, 7,17% da cena SAR na polarização VV. As imagens SAR nas duas polarizações (VH e VV) mostram uma semelhança entre as áreas alagadas nos períodos de chuva e seca sendo as diferenças praticamente imperceptíveis (**Figura III.9**).



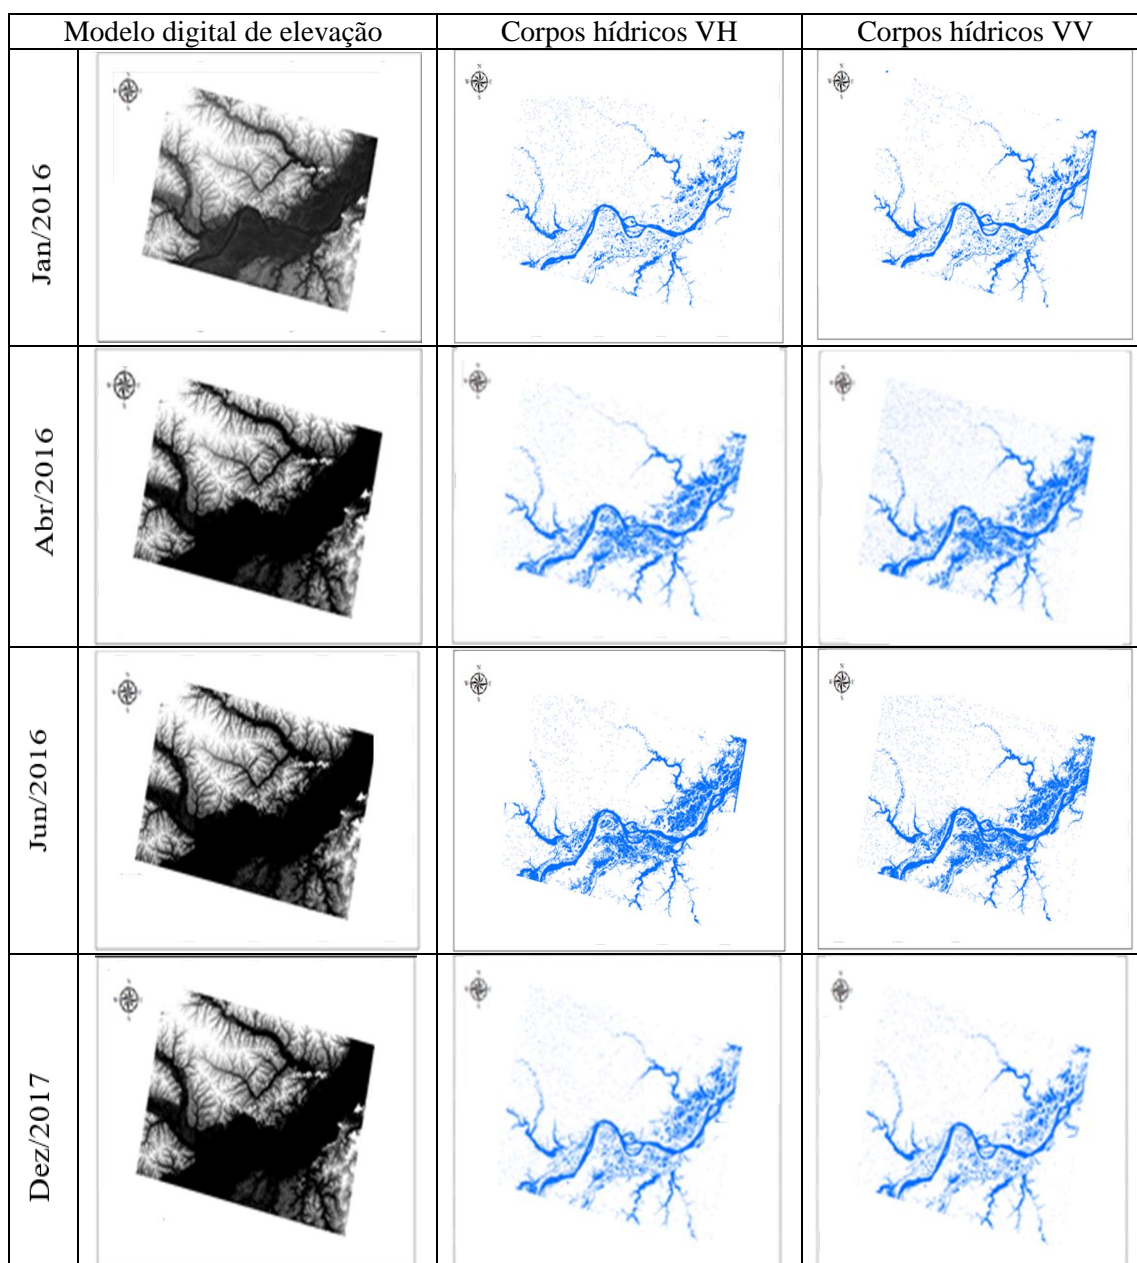




**Figura III.9** - Mapa dos corpos d'água da Amazônia Central nos períodos de menor e maior área inundada para os anos de 2016 a 2020 nas polarizações VH e VV do Sentinel-1.

O pulso de inundação no trecho da Amazônia Central ocorre com período de atraso entre 3 a 4 meses após o maior índice de precipitação no mês de março. Conforme Papa et al. (2010), o pulso de inundação no Baixo Rio Amazonas ocorre com um tempo de retardo de quatro a seis semanas em relação ao pico de precipitação na bacia devido à sua grande dimensão e complexidade hidráulica. Segundo Arnesen (2012), o pulso de inundação se origina da precipitação nas nascentes do rio Amazonas, quando as massas de ar encontram a Cordilheira dos Andes e ganham magnitude a jusante da bacia hidrográfica, gerando chuvas tropicais.

A **Figura III.10** representa a sazonalidade hídrica do rio Amazonas, lagos e seus afluentes entre os anos de 2016 e 2017 através de imagens SAR nas polarizações VH e VV. A primeira imagem temporal do mês de janeiro apresenta o menor volume de corpos d'água, mostrando a perenidade do rio Amazonas e lagos em períodos de estiagem. A segunda imagem de abril representa um período de transição. Após 4 meses, há uma mudança significativa no volume dos corpos d'água, onde áreas de menor altitude, várzeas e afluentes inundam. Na terceira imagem, mês de junho, ocorre o pulso máximo de inundação, transbordando os corpos d'água pela planície. As maiores planícies inundadas permanecem com praticamente o mesmo volume hídrico por um período de 3 meses (junho, julho e agosto). A área inundada permanece até meados de setembro, quando começa a diminuir o volume de água até atingir a menor área inundada no início de dezembro, conforme a quarta imagem.



**Figura III.10** - Mapa sazonal do pulso de inundação no rio Amazonas e afluentes, em janeiro do ano de 2016, abril, junho e dezembro de 2017.

A elevação mínima na régua fluviométrica foi de 43 cm referente à imagem de 02/11/2017, e a altura máxima foi de 902 cm na imagem de 17/06/2019. No entanto, a média geral foi de 551 cm, comprovando a perpetuidade regional e volume considerável de água (**Tabela III.5**). O menor valor de elevação registrado na régua não representou a menor área inundada na imagem SAR. Em contraste, o maior valor de elevação correspondeu à maior área de inundação.



**Tabela III.5** - Área inundada mensurada em km<sup>2</sup> por meio da série temporal das imagens Sentinel 1-SAR nas polarizações VH e VV.

Data da Imagem	Cota na Estação (cm)	Área inundada km <sup>2</sup> (VH)	Área inundada km <sup>2</sup> (VV)	Diferença km <sup>2</sup> (VH - VV)
26/09/2016	199	3.212,59	3.910,69	698,10
02/10/2016	170	4.129,09	3.422,44	306,56
14/10/2016	87	3.592,33	3.112,97	479,36
07/11/2016	78	3.701,88	3.266,90	434,98
19/11/2016	79	2.664,99	3.235,6	570,61
13/12/2016	47	3.401,88	3.000,81	401,07
25/12/2016	106	3.059,75	2.868,59	191,16
06/01/2017	260	3.197,43	3.359,09	361,69
30/01/2017	480	3.775,88	3.342,51	433,37
11/02/2017	576	4.225,88	3.759,72	466,16
19/03/2017	748	5.268,08	4.543,67	724,41
31/03/2017	788	5.066,78	4.678,20	388,58
12/04/2017	824	5.401,88	4.874,62	527,26
24/04/2017	850	5.896,42	5.824,30	72,12
18/05/2017	882	5.705,13	5.823,14	35,71
30/05/2017	869	6.103,67	5.861,76	251,91
11/06/2017	859	5.614,82	5.791,11	176,29
23/06/2017	833	6.106,08	6.070,37	118,01
05/07/2017	813	5.683,88	5.433,12	250,76
17/07/2017	780	5.307,53	5.960,31	652,78
10/08/2017	683	5.087,18	5.866,05	778,87
22/08/2017	602	5.311,51	5.791,85	480,34
03/09/2017	467	4.952,00	4.701,58	250,42
15/09/2017	290	4.692,09	5.077,95	385,86
09/10/2017	58	4.168,87	3.599,52	569,35
02/11/2017	43	3.891,61	3.300,61	591
14/11/2017	88	3.463,89	4.276,77	812,88
08/12/2017	175	3.601,09	3.425,46	175,63
20/12/2017	202	3.310,32	3.069,68	240,64
01/01/2018	267	3.655,50	3.220,09	435,41
13/01/2018	349	3.794,80	3.618,55	176,25
25/01/2018	411	3.773,86	3.221,76	552,1
06/02/2018	481	3.861,34	3.881,44	20,1
18/02/2018	551	3.837,37	3.481,74	355,63
02/03/2018	605	4.792,88	3.943,44	849,44

14/03/2018	629	4.588,23	4.001,19	587,04
26/03/2018	636	4.649,36	4.359,04	290,32
07/04/2018	663	5.104,47	4.414,60	689,87
19/04/2018	703	4.836,75	4.815,49	21,26
01/05/2018	743	5.246,10	5.051,08	195,02
13/05/2018	790	5.387,74	5.216,44	171,3
12/07/2018	862	5.193,88	5.291,67	97,79
17/08/2018	738	5.095,88	5.010,89	84,99
22/09/2018	379	4.601,88	4.801,89	200,01
16/10/2018	105	4.201,88	4.078,88	123
21/11/2018	82	3.801,64	3.548,88	252,76
15/12/2018	154	3.401,54	3.779,66	378,12
08/01/2019	353	3.849,88	3.755,65	56
01/02/2019	536	3543,13	3.771,54	228,41
09/03/2019	693	4.721,21	4.603,88	118
14/04/2019	760	5.201,78	5.287,76	85,98
08/05/2019	894	6.553,21	6.414,89	138,31
17/06/2019	902	6.611,86	6.443,19	158,67
07/07/2019	818	5.801,46	5.956,53	155,07
12/08/2019	674	5.331,24	5.655,79	324,55
29/09/2019	333	4.507,06	4.235,17	271,89
11/10/2019	105	4.203,9	4.101,9	102
16/11/2019	83	3.375,55	3.575,45	199,9
10/12/2019	137	3.424,12	3.260,83	163,29
15/01/2020	341	3.526,74	3.762,71	235,97
08/02/2020	536	3.902,81	3.813,67	89,14

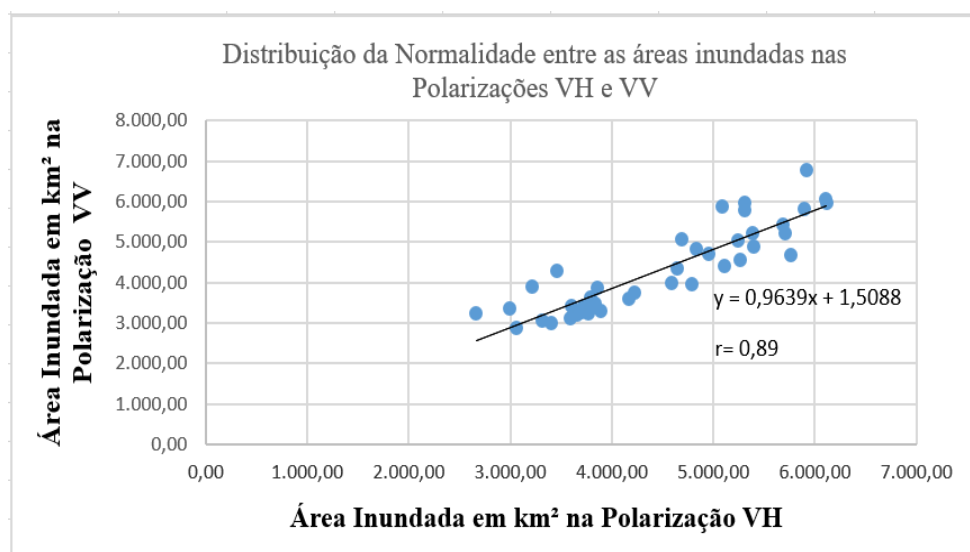
Alguns meses apresentaram aumento ou diminuição repentina no valor da cota da régua, mas pouca mudança ocorreu na área inundada, inferindo que a extensão das enchentes não está relacionada apenas ao rio Amazonas, mas também aos seus afluentes. Os valores medidos da área inundada através das polarizações VH e VV mostraram padrões temporais aproximados da água, e as menores diferenças aconteceram durante os períodos de inundação.

Na série histórica, as imagens de polarização VH obtiveram as maiores áreas inundadas no período de cheia. Clement et al. (2018), ao analisarem 13 cenas Sentinel-1 na região de Yorkshire, Reino Unido, também obtiveram maiores áreas inundáveis com a polarização VH. Conforme Frota (2019), a área inundada do rio Negro usando imagens Sentinel-1 na polarização VH (2016 a 2017) obteve valores superestimados.

Em geral, as duas polarizações apresentaram resultados compatíveis com o padrão hídrico, sendo um potencial para a definição de áreas inundadas. Da mesma forma, Hess et al. (2015) analisaram a dinâmica de inundação e obtiveram bons resultados na distinção de áreas úmidas através de imagens temporais de SAR.

### III.3.5 ANÁLISE ESTATÍSTICA DAS ÁREAS INUNDADAS

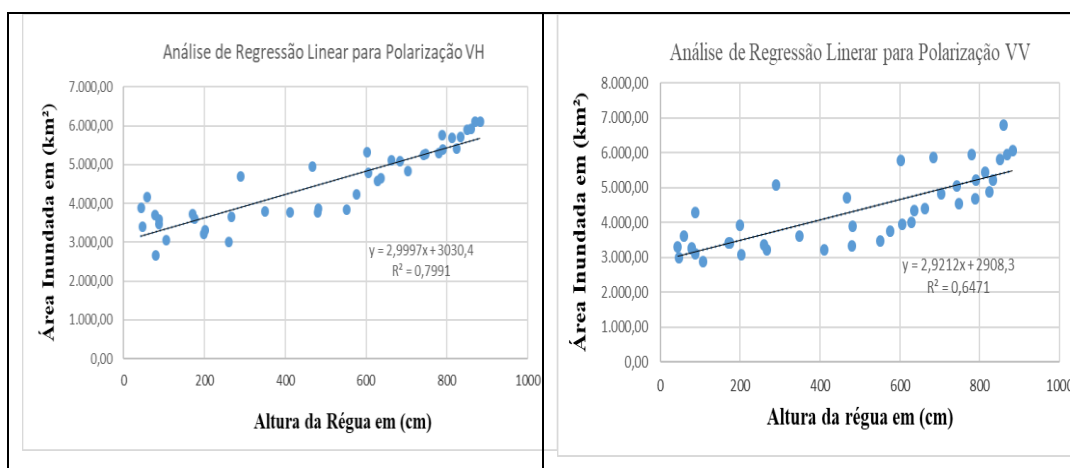
A correlação entre as áreas úmidas obtidas pelas imagens SAR nas polarizações VH e VV para o período estudado obteve um R de 0,89 (**Figura III.11**). No período seco, as áreas com água variando de 2 km<sup>2</sup> a 3 km<sup>2</sup> apresentaram maior divergência entre as duas polarizações. As áreas úmidas acima de 6 km<sup>2</sup> apresentam maior similaridade, posicionados próximos a uma linha reta. O teste t de Student indicou normalidade entre amostras independentes, confirmando a hipótese de similaridade estatística com valor t de 0,70 e t crítico bicaudal de 1,99.



**Figura III.11** - Regressão linear entre as áreas inundadas entre as polarizações VH e VV.

A **Figura III.12** apresenta as regressão entre o nível d'água na régua de Parintins (AM) e as áreas inundadas obtidas pelas imagens das duas polarizações. As retas de regressão de ambos os modelos são similares, obtendo, para a imagem VH, um R<sup>2</sup> de 0,79 e, para a imagem VV, um R<sup>2</sup> de 0,64. Barbosa et al. (2006) utilizaram modelos de regressão para estimar as áreas inundadas por meio da altura da régua fluviométrica, batimetria e imagens Landsat TM na várzea do Lago de Grande Curaí (AM), obtendo um R<sup>2</sup> de 0,99, valor superior que o obtido neste estudo provavelmente devido ao maior número de variáveis usadas no modelo.


A regressão entre os valores relativos da régua fluviométrica e as áreas alagadas apresentou as seguintes características: (a) as maiores diferenças absolutas ocorreram com alturas da régua entre 400 cm e 600 cm; (b) as áreas de inundação na polarização VV se ajustaram melhor entre as alturas de régua de 0 a 200 cm; e (c) as áreas de inundação na polarização VH melhor ajusta entre alturas de régua de 600 cm até 1000 cm.



**Figura III.12** - Modelo de regressão linear relacionado a área inundada nas polarizações VH e VV com a cota altimétrica da régua em Parintins, AM.

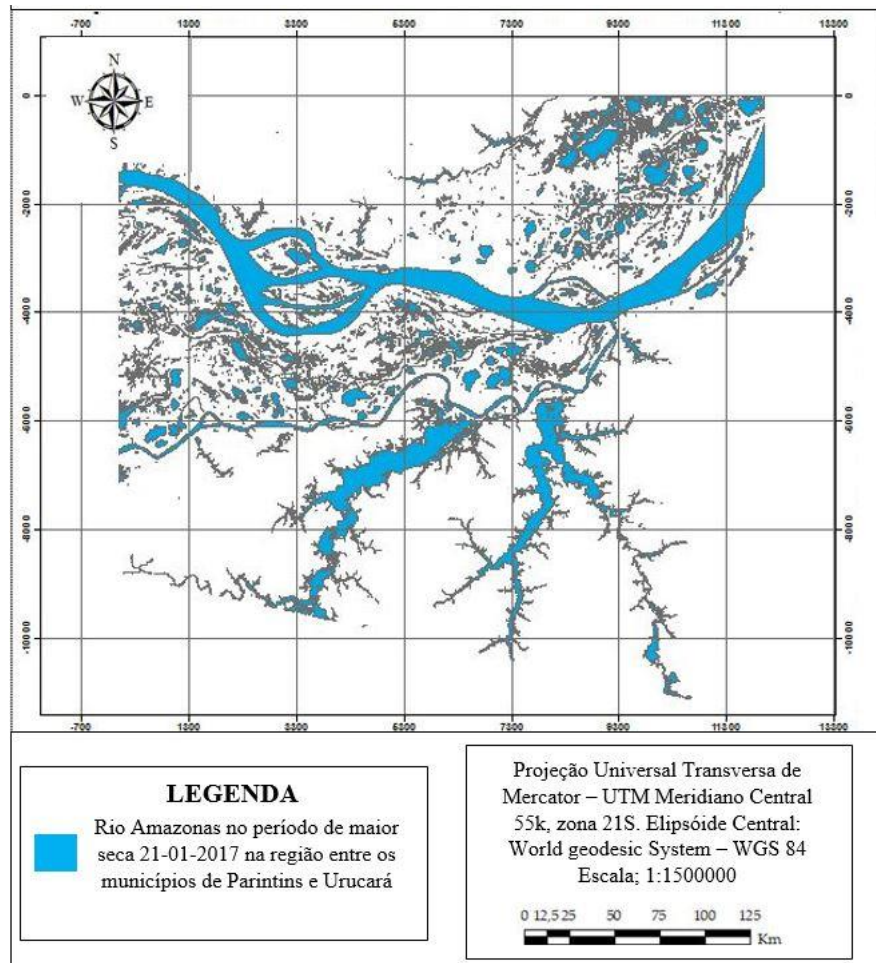
### III.3.6 ANÁLISE DA LINHA MÉDIA DE ENCHENTE ORDINÁRIA – LMEO

O valor relativo da LMEO observado na régua fluviométrica foi de 927,36 cm. Os eventos de chuvas fortes e inundações predominaram entre 1970 e 1988, com vários eventos com valores superiores a 927,36 cm. O maior valor medido foi de 1.079 cm em 1º de junho de 1971. Entre julho de 2014 e julho de 2020 (6 anos), as alturas relativas apresentaram os menores valores, consistentemente abaixo de 927,36 cm e com queda brusca em junho de 2016 (**Figura III.13**).

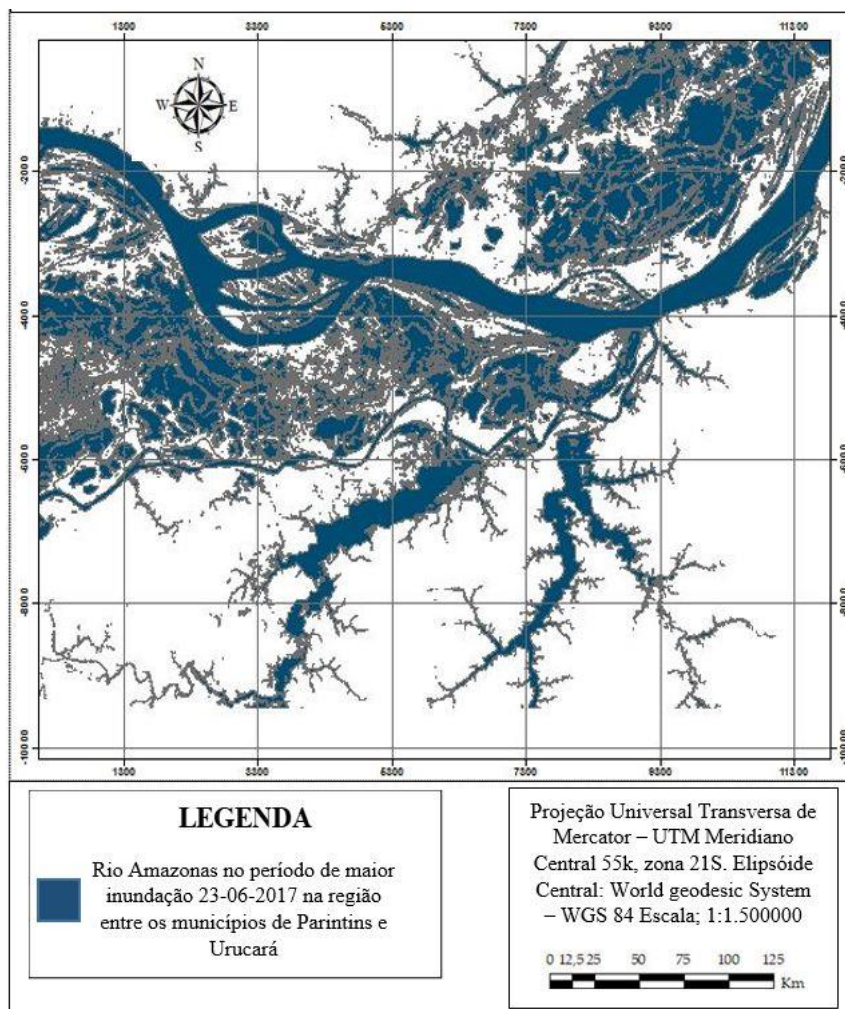


**Figura III.13** - Gráfico do regime fluviométrico no Rio Amazonas no período entre os nos 1967 a 2020 e o valor relativo da LIMEO.

Durante a série temporal Sentinel-1, a menor altura relativa na régua fluviométrica foi de 83 cm em novembro de 2019 (**Figura III.14**), e o maior valor foi de 902 cm, atingido em 26 de junho de 2019 (**Figura III.15**). A comparação dos dois períodos demonstra a significativa expansão do volume de água no rio Amazonas, afluentes e lagos vizinhos no período de cheia. A extensão da várzea apresentou dinâmica diferenciada no período de maior volume de água, com largura máxima de 30,48 km na margem esquerda e 47,74 km na margem direita do rio Amazonas.



**Figura III.14** – Mapa das áreas inundadas em trecho do rio Amazonas entre os municípios de Urucará e Parintins na Amazônia central no período de maior seca registrado por meio da série temporal das imagens Sentinel-1 SAR.



**Figura III.15** - Mapa das áreas inundadas em trecho do rio Amazonas entre os municípios de Urucará e Parintins na Amazônia Central no período de maior inundação registrado por meio da série temporal das imagens Sentinel-1 SAR.

### III.4 CONCLUSÃO

Esse estudo inova ao apresentar uma abordagem metodológica para o mapeamento de áreas inundáveis correlacionados com dados de estações meteorológicas, pois comprovou-se ser eficaz no mapeamento de áreas inundáveis provenientes de técnicas de sensoriamento remoto em série temporal de imagens Sentinel-1 SAR. A inexistência de imagens Sentinel-1 SAR anterior ao ano de 2016, quando os eventos de inundação foram superiores a LMEO (927,36 cm) impossibilitou a delimitação da área de inundação da LMEO por meio de dados SAR. Os modelos de regressão lineares obtidos por meio das polarizações VH e VV apresentaram resultados satisfatórios. Entretanto, as áreas inundáveis obtidas pelas imagens de polarização VH tiveram maior correlação com a cota fluviométrica (79%) do que pelas imagens de polarização VV (64%). As áreas de inundações mensuradas nas polarizações VH e VV apresentaram uma boa correlação e sem significância estatística entre as amostras, presumindo que se pode

utilizar tanto as duas polarizações para obtenção de volume hídrico, dinâmica e delimitação de áreas inundáveis na região.

## **REFERÊNCIAS**

ALMEIDA, F. C. Simulação de Resposta de Estruturas Simplificadas de Vegetação ao Radar de Abertura Sintética Interferométrico. Dissertação (Mestrado). São José dos Campos: Instituto Nacional de Pesquisas Espaciais – INPE, 2008.

BARBOSA, C. C. F.; NOVO, E. M. L. M.; MELACK, J. M.; FREITAS, R. M.; PEREIRA FILHO, W. Metodologia de análise da dinâmica de área e volume inundável: o exemplo da Várzea do Lago Grande de Curuai. *Revista Brasileira de Cartografia*, v. 1, p. 03-24, 2006.

BRASIL. Constituição da República Federativa do Brasil. Brasília, DF, 1998.

CARVALHO JÚNIOR, O. A.; SAMPAIO, C. S.; SILVA, N. C.; COUTO JÚNIOR, A. F.; GOMES, R. A. T.; CARVALHO, A. P. F.; SHIMABUKURO, Y. E. Classificação de padrões de savana usando assinaturas temporais NDVI do sensor MODIS no Parque Nacional Chapada dos Veadeiros. *Revista Brasileira de Geofísica*, v. 26, n. 4, p. 505-507, 2008.

CHANG, J.; HANSEN, M. C.; PITTMAN, K.; CARROLL, M.; DIMICELI, C. Corn and soybean mapping in the united states using MODIS time-series data sets. *Agronomy Journal*, v. 99, n. 6, p. 1654-1664. 2007.

CLEMENT, M. A.; KILSBY, C. G.; MOORE, P. Multi-temporal synthetic aperture radar flood mapping using change detection. *Journal of Flood Risk Management*, v. 11, p. 152-168, 2018.

DALLEMAND, J. F.; LICHTENEGGER, J.; RANEY, R. K.; SCHUMANN, R. Radar Imagery. Theory and Interpretation (Lecture Notes). Roma: FAO, 118 p. 1993.

DONG, Y. M.; MILNE, A. K.; FORSTER, B.; C. Segmentation and Classification of Vegetated Areas Using Polarimetric SAR Image Data. *IEEE Transactions on Geoscience and Remote Sensing*, v. 39, n. 2, p. 321-329, 2001.

EUROPEAN SPACE AGENCY - ESA. Disponível em:  
< <https://sentinel.esa.int/web/sentinel/home>>. Acesso em: 07 de Jan. 2019.

FERREIRA, G. H. S. Identificação de áreas inundáveis na porção sul de Roraima com auxílio de imagens de Radar. Dissertação (Mestrado). Brasília: Universidade de Brasília - UnB, 2018.

FORKUOR, G.; CORAND, C.; THIEL, M.; ULMANN, T.; ZOUNGRANA, E. Integration of Optical and Synthetic Aperture Radar Imagery for Improving Crop Mapping in Northwestern Benin, West Africa. *Remote Sensing*, v. 6, n. 7, p. 6472-6499, 2014.



FROTA, S. M. N. Relação entre área de inundação e cota fluviométrica na sub-bacia do Alto rio Negro: uma análise baseada em dados de radar (Sentinel-1A). Dissertação (Mestrado). Brasília: Universidade de Brasília - UNB, 2019.

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, p. 212-222, 2016.

GARDIMAN JÚNIOR. B. S; MAGALHÃES, I. A. L; FREITAS, C. A. A; CECÍLIO, R. A. Análise de técnicas de interpolação para espacialização da fusão pluvial na bacia do rio Itapemirim (ES). *Ambiência*, v. 8, n.1, p. 61-71, 2012.

HESS, L. L.; MELACK, J. M.; AFFONSO, A. G.; BARBOSA, C.; GASTIL-BUHL, M.; NOVO, E. M. L. M. Wetlands of the Lowland Amazon Basin: Extent, Vegetative Cover, and Dual-season Inundated Area as Mapped with JERS-1 Synthetic Aperture Radar. *Wetlands*, v. 35, p. 745-756, 2015.

INSTITUTO NACIONAL DE METEOROLOGIA - INMET. BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa. Disponível em: <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acesso em: 25 abr. 2020.

JUNK, W. J. *The Central Amazon Floodplain - Ecology of a Pulsing System*. New York: Springer, 1997. 525 p.

LEE, J. S. Digital image enhancement and noise filtering by use of local statistics. *IEEE Trans. Pattern Analysis and Machine Intelligence*, v. 2, n. 2, p. 165-168, 1980.

LEE, J. S.; POTTIER, E. *Polarimetric SAR Radar Imaging: From Basic to Applications*. Boca Raton: CRC Press, 2009. 422 p.

MANSOURPOUR, M.; RAJABI, M. A; BLAIS, J. A. R. Effects and performance of speckle noise reduction filters on active radar and SAR images. *ISPRS Journal of Photogrammetry & Remote Sensing*, v. 1, p. 1-9 2006.

MARINHO, R. R.; PARADELLA, W. R.; RENNO, C. D.; OLIVEIRA, C. G. Aplicação de imagens SAR orbitais em desastres naturais: Mapeamento das inundações de 2008 no Vale do Itajaí, SC. *Revista Brasileira de Cartografia*, v. 64, p. 317-330, 2012.

MARQUES, J. B.; DE CARVALHO JUNIOR, O. A.; CAMPAGNOLI, F.; DE MESQUITA JÚNIOR, H. N.; GOMES, R. A. T.; GUIMARÃES, R. F. Classificação da cobertura da terra na região da ilha do Bananal usando imagens multitemporais PALSAR-2/ALOS-2. *Confins* [Online]. *Revue Franco-Brésilienne de Géographie/Revista Franco-Brasileira de Geografia*, 39, 2019.

MELACK, J. M.; HESS, L. L. Remote Sensing of the Distribution and Extent of Wetlands in the Amazon Basin. *Amazonian Floodplain Forests. Ecological Studies (Analysis and Synthesis)*. Dordrecht Springer, v. 210, p. 43-59, 2010.

PAPA, F.; PRIGENT, C.; AIRES, F.; JIMENEZ, C.; ROSSOW, W. B.; MATTHEWS, E. Interannual variability of surface water extent at global scale. *Journal of Geophysical Research*, v. 115, n. 112, p. 1-17, 2010.

SANTOSO, A. W.; BAYUAJI, L.; TIEN SZE. L.; LATEH, H.; ZAI, J. M. Comparison of Various Speckle Noise Reduction Filters on Synthetic Aperture Radar Image. *International Journal of Applied Engineering Research*, v. 11, p. 8760-8767, 2016.

RAMALHO, E. E.; MACEDO, J.; VIEIRA, T. M.; VALSECCHI, J.; CALVIMONTES, J.; MARMONTEL, M.; QUEIROZ, H. L. Ciclo hidrológico nos ambientes de várzea da reserva de desenvolvimento sustentável Mamirauá – Médio rio Solimões, período de 1990 A 2008. *Uakari*, v. 5, n.1, p. 61-87, 2009.

SECRETARIA DO PATRIMÔNIO DA UNIÃO - SPU. Orientação Normativa que disciplina a demarcação de terrenos marginais e seus acréscidos (ON-GEADE-03). Relatório, 2001. Disponível em: <<http://www.planejamento.gov.br/assuntos/patrimonio-dauniaio/legislacao/orientacoes.pdf>>. Acesso em: jun. 2018.

TELLO, M.; LOPEZ-MARTINEZ, C.; MALLORQUI, J. J. Automatic vessel monitoring with single and multidimensional SAR images in the wavelet domain. *ISPRS Journal of Photogrammetry & Remote Sensing*, v. 61, p. 260-278, 2006.

## CAPÍTULO IV

### COMPARING MACHINE AND DEEP LEARNING METHODS FOR THE PHENOLOGY-BASED CLASSIFICATION OF LAND COVER TYPES IN THE AMAZON BIOME ECOSYSTEM USING SENTINEL-1 TIME SERIES

#### Resumo

O estado do Amapá no bioma Amazônia possui uma alta complexidade de ecossistemas formados por florestas, savanas, vegetação sazonalmente alagada, manguezais e diferentes usos da terra. A presente pesquisa teve como objetivo mapear a vegetação a partir do comportamento fenológico da série temporal Sentinel-1, que tem a vantagem de não apresentar interferência atmosférica e cobertura de nuvens. Além disso, o estudo comparou três conjuntos diferentes de imagens (copolarização vertical-vertical (VV) apenas, apenas polarização cruzada vertical-horizontal (VH), tanto VV quanto VH) e diferentes classificadores baseados em aprendizado profundo ( Memória de curto prazo longa (LSTM), LSTM bidirecional (BiLSTM), Unidades recorrentes fechadas (GRU), GRU bidirecional (Bi-GRU)) e aprendizado de máquina (Random For-est, Extreme Gradient Boosting (XGBoost), k-Nearest Neighbors , Support Vector Machines (SVM) e Multilayer Perceptron). A série temporal englobou quatro anos (2017-2020) com 12 dias de revisita, totalizando 122 imagens para cada polarização VV e VH. A metodologia apresentou as seguintes etapas: pré-processamento das imagens, filtragem temporal pelo método de suavização de Savitsky-Golay, coleta de amostras considerando 17 classes, classificação por diferentes métodos e conjuntos de dados de polarização e análise de acurácia. Os melhores escores de F1 utilizaram o conjunto de dados VV e VH e as Redes de Neurônios Recorrentes bidirecionais, considerando o Bi-GRU (93,53) e o Bi-LSTM (93,29), seguidos pelos outros métodos de aprendizado profundo, GRU (93,30) e LSTM (93,15). . Entre o aprendizado de máquina, os dois métodos com os maiores valores de F1-score foram SVM (92,18) e XGBoost (91,98). Portanto, variações fenológicas baseadas em longas séries temporais do Synthetic Aperture Radar (SAR) permitem a representação detalhada da cobertura/uso da terra e da dinâmica da água.

Palavras-Chave: Radar de abertura sintética; multitemporal; séries temporais; *deep learning*; memória longa de curto prazo; unidade fechada recorrente; redes de neurônios

recorrentes, fenologia da vegetação; fenologia da superfície terrestre; mapeamento da cobertura do solo.

### **Abstract**

The state of Amapá within the Amazon biome has a high complexity of ecosystems formed by forests, savannas, seasonally flooded vegetation, mangroves, and different land uses. The present research aimed to map the vegetation from the phenological behavior of the Sentinel-1 time series, which has the advantage of not having atmospheric interference and cloud cover. Furthermore, the study compared three different sets of images (vertical-vertical co-polarization (VV) only, vertical-horizontal cross-polarization (VH) only, both VV and VH) and different classifiers based on deep learning (Long short-term memory (LSTM), Bidirectional LSTM (BiLSTM), Gated Recurrent Units (GRU), bidirectional GRU (Bi-GRU)) and machine learning (Random Forest, Extreme Gradient Boosting (XGBoost), k-Nearest Neighbors, Support Vector Machines (SVM), and Multilayer Perceptron). The time series englobed four years (2017-2020) with a 12-day revisit, totaling 122 images for each VV and VH polarization. The methodology presented the following steps: image pre-processing, temporal filtering using the Savitsky-Golay smoothing method, collection of samples considering 17 classes, classification using different methods and polarization datasets, and accuracy analysis. The best F1 scores used the VV and VH dataset and the bidirectional Recurrent Neuron Networks, considering the Bi-GRU (93.53) and Bi-LSTM (93.29), followed by the other deep learning methods, GRU (93.30) and LSTM (93.15). Among machine learning, the two methods with the highest F1-score values were SVM (92.18) and XGBoost (91.98). Therefore, phenological variations based on long Synthetic Aperture Radar (SAR) time series allow the detailed representation of land cover/land use and water dynamics.

Keywords: Synthetic aperture radar; multi-temporal; time series, deep learning, long short-term memory, gated recurrent unit, recurrent neuron networks, vegetation phenology, land surface phenology, land cover mapping.

### **IV.1 Introduction**

Understanding the spatial heterogeneity of the Amazonian landscape is crucial for developing and planning efficient conservation actions in one of the world's most diverse regions [1,2]. The mapping of the diversity of forests and vegetation is the basis

for research and knowledge of the dynamics and management of forest resources, where changes in vegetation cover driven by human activities profoundly affect ecosystem functioning [3,4]. Although Amazonian landscapes are often associated with forests, they comprise a wider array of ecosystems developing along climatic, edaphic, and hydrologic gradients. This biome contains “Amazonian savannas” that constitute isolated patches of open formations consisting of grassland and shrub vegetation, covering an area of 267,000 km<sup>2</sup>, mainly in Brazilian and Bolivian territory (90% of the area) [5]. Within the domain, the forest covers 80% of the biome area, and the “Amazonian savannas” occupy only < 5% [6]. In this context, the state of Amapá, located in the extreme northeast of the Amazon region, has incomparable vegetation in the Amazon biome, formed by a fragmented and complex environment with intercalation of forests, flooded forests, floodplains, savannas, and mangroves [5]. Amapá has a high percentage of well-preserved original vegetation (> 95%), containing 72% of its extension within protected areas [7]. However, the distribution of protected areas is not proportional to vegetation formations, requiring an adequate monitoring system to detect human activities.

In this sense, orbital remote sensing technology is an adequate tool to obtain periodic information about a large area practically and economically and to extract vegetation cover, ecosystem parameters, and vegetation changes. The provision of temporally continuous information by remote sensing orbital images has contributed to the development of phenological studies and phenology-based classification of land cover types, which reach exponential growth over time [8]. Seasonal variations describe the temporal signatures in vegetation (e.g., flowering, fruiting, leaf change, senescence, dormancy) [9–11]. Phenology provides environmental information covering numerous areas of knowledge, such as ecology [10,12,13], climate change [14–16], conservation biology [17–19], and land-use/land-cover change [20], and crop monitoring [21]. Therefore, several studies describe the phenological dynamics from remote sensing images to assess environmental changes at multiple spatial and temporal scales [22,23]. Satellite-derived phenology overcomes the limitations of monitoring at ground level, considering a wide spatial range, repeatable over time, normalized, and without the need for extensive and costly fieldwork [8].

A combination of diverse ecosystems and cloud conditions is challenging in the context of mapping heterogeneous landscapes in the Amapá region. The high presence of cloud cover in the Amazon region is a limiting factor for optical imaging [24–26].

Consequently, the time series of Synthetic Aperture Radar (SAR) becomes the primary alternative for being free of constant atmospheric interference in tropical areas and acquiring information without interruption. In addition to transposing climatic conditions, SAR signals are sensitive to vegetation structure and biomass, crop and vegetation height, and soil moisture, providing additional information on land cover types [27,28]. However, SAR time series have a lesser use than optical images due to the more significant presence of noise, pre-processing complexity, difficulty in interpretation, and scarcity of free data [8].

The advent of C-band Sentinel-1 (S-1) A and B sensors belonging to the European Space Agency (ESA) mission has intensified the use of SAR time series in phenological studies due to the short revisit time interval of 6 (using both sensors) or 12 days (using a sensor) and free data distribution [29,30]. The high temporal resolution of the S-1 images causes a significant increase in the number of studies to map different vegetation contexts: forests [31–34], temporarily flooded vegetation [35,36], salt marshes [37], urban vegetation [38], cultivated landscape with different crop types [39–44], rural and natural landscapes [45], early crop [46], and single cultivation cycle during a year such as rice [47–49] and wheat [50–52]. Besides, a large amount of research uses a combination of radar and optical sensor images for vegetation classification [53]. Thus, numerous studies integrate S-1 data with optical images, mainly from Sentinel-2 (S-2) [54–56] and Landsat images [57–59].

Time series classification algorithms use seasonal backscatter differences to individualize and detect targets. Many methods for classifying crops and vegetation based on S-1 time series have been evaluated considering traditional methods, Machine Learning (ML), and Deep Learning (DL). Among the traditional methods, the predominant studies use techniques based on distance and similarity measures [31,32,39,43,60] and phenology metrics [33]. Several ML techniques have been applied in the phenology-based classification of land cover types: Random Forest (RF), Support Vector Machines (SVM), Decision Tree (DT), K-Nearest Neighbor (KNN) and Quadratic Discriminant Analysis (QDA), Extreme Gradient Boosting (XGB), Multilayer Perceptron (MLP), Adaptive Boosting (AdaBoost), Extreme Learning Machine (ELM). Among ML models, RF is the most used in temporal classification [34,48,61,62]. Furthermore, many studies compare the different ML methods, such as SVM and RF [45]; RF, SVM, XGBoost, MLP, AdaBoost, and ELM [38]; and DT, SVM, KNN, and QDA [49].

The DL models have recently reached state-of-the-art computer vision, with wide application in remote sensing [63,64]. DL models based on the Recurrent Neural Network (RNN) are the most hopeful in classifying temporal and hyperspectral data due to their ability to detect sequential data [65–67]. The distinction of RNN methods compared to other approaches is to incorporate “memory” information, where data from previous inputs influence subsequent inputs and outputs. The inputs and outputs of traditional deep neural networks are independent, while in RNNs, there is a dependence along an ordinal sequence. Among the RNN methods, the primary methods in temporal correlation analysis are Long Short-Term Memory (LSTM) [68] and Gated Recurrent Units (GRU)[69].

In optical remote sensing, RNN methods have been applied in time series to distinguish crops and vegetation dynamics using different types of sensors: Moderate Resolution Imaging Spectroradiometer (MODIS) [70,71], Sentinel 2 [72], Landsat [73,74], Pleiades VHSR images [75], and [71]. In the SAR time series, studies compare the RNN method with other approaches: RF and LSTM [41]; LSTM, Bi-LSTM, SVM, k-NN, and Normal Bayes [47]; 1D Convolutional Neural Networks (CNN), GRUs, LSTMs, and RF [46]; GRUs and LSTMs [76].

A confluence of coastal, riverine, and terrestrial environments in the Amapá region of eastern Amazon of Brazil results in a very diverse and dynamical landscape that has been poorly characterized. Using the high spatial and temporal Sentinel-1 time series (C band) in the VH and VV for the years 2017-2020, this research aimed to:

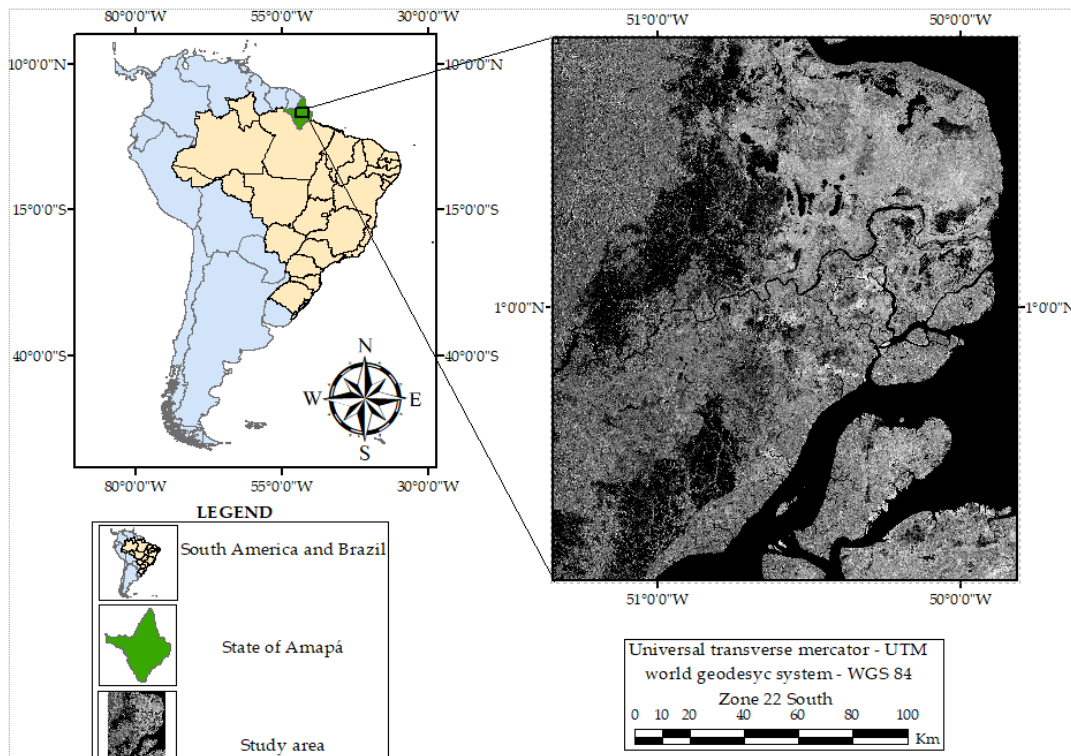
- characterize phenological patterns of land cover/land use,
- characterize erosion/accretion changes in coastal and fluvial environments,
- evaluate the behavior of vertical-vertical (VV) co-polarization, vertical-horizontal (VH) cross-polarization, and both VV and VH (VV&VH) in the differentiation of land cover/land use features,
- compare the behavior of five traditional machine learning models (RF, XGBoost, SVM, k-NN, and MLP) and four RNN models (LSTM, Bi-LSTM, GRU, and bidirectional GRU (Bi-GRU)) in time-series classification, and
- produce a land cover/land use map for the Amapá region.

## IV.2 Study Area

The study area is located in the state of Amapá, northern Brazil (**Figure IV.1**). The climate is of type 'Am' in the Koppen classification, being hot and super humid with temperatures ranging from 25°C to 27°C, average monthly rainfall of 50 mm to 250 mm, and annual incidence above 2,400 mm. It has two well-defined seasons: the rainy season between December and June and the dry season between July and November [77]. The vegetation of Amapá presents a significant variation from the coastal region to its interior, demarcating three primary environments: coastal plain with pioneer vegetation, low plateaus with the presence of savannas, and plateau regions with rainforest cover.

The coastal plain of Amapá, with a low topographic gradient and altitude (up to 10 meters), has a varied landscape composed of fluvial, fluvial-lacustrine, and fluvial-marine processes. The three predominant types of mangroves are *Avicennia germinans*, *Rhizophora mangle*, and *Laguncularia racemose* [78]. The *Avicennia germinans* is dominant in extensive areas, with more frequent in elevated, less inundated areas and under more saline conditions [79], containing the highest mangroves on the Amapá coast and forming mature and open forests [78]. Mangroves (*Rhizophora spp.*) are dominant in estuaries and on the inner edges of the coastal fringes, associated with rainwater [78,80]. The mangroves are interrupted by floodplain vegetation characterized by influenced by the fluvial water discharge [81].





**Figure IV.1.** Location study area in the state of Amapá in Brazil and the South American continent. The image of the study area corresponds to the first component of the Minimum Fraction of Noise transformation considering the Sentinel 1 VH polarization time series in the period 2017-2020.

In addition, the coastal plain of Amapá contains lakes of varying sizes and extensive seasonally flooded areas. The lakes are ox-bow-shaped, showing their evolution from abandoned meanders and past river systems [82,83]. The plain has many paleochannels, whose scars show this environment's high dynamics and reworking [84]. Therefore, the vegetation develops in pedologically unstable areas, subjected to fluvial, lacustrine, marine, and fluvio-marine accumulation processes, formed by plants adapted to local ecological conditions. The vegetation types are seasonally flooded grasses and pioneer herbaceous, shrub, and forest formations. Floodplains, along with grasslands, are the most fire-sensitive phytophysiognomies.

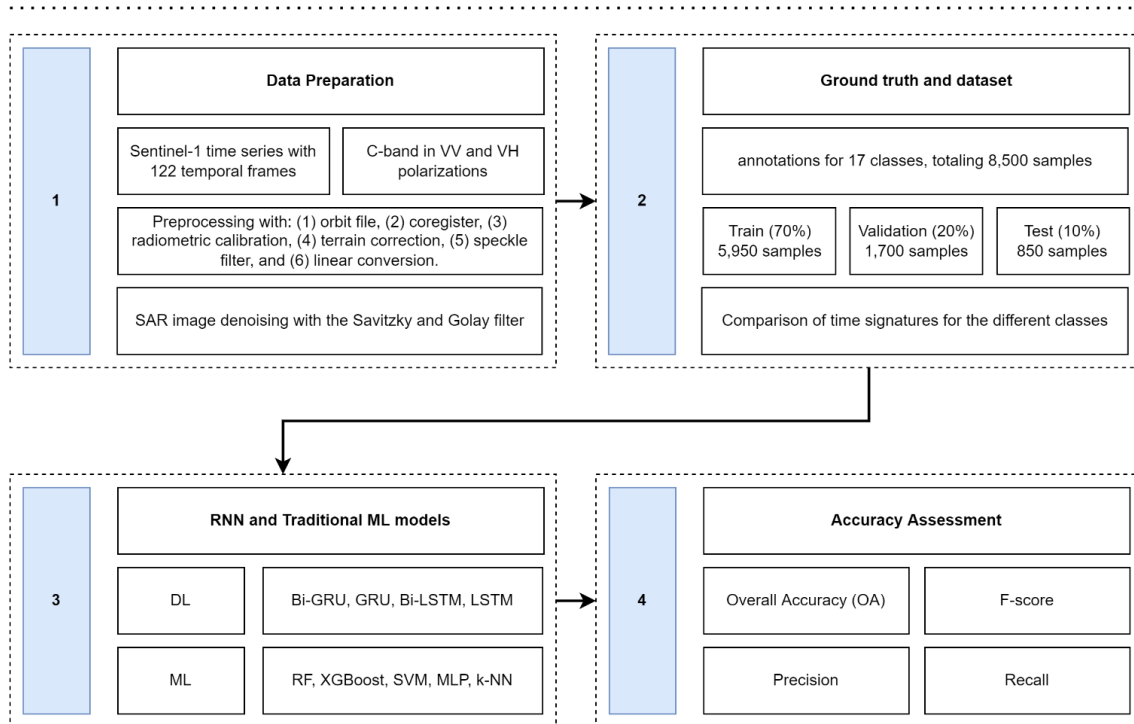
Savannas are present in slightly higher areas in the low plateaus of Amapá. Compared with other Amazon savannas, the savannas of Amapá showed a greater richness of genera and species with a reduced number of threatened, invasive, and exotic species [85]. The herbaceous/subshrub layer corresponded to 62% of the surveyed species [85]. The high variation in the proportions of woody and grassy plant strata provided different nomenclatures and classifications for the savannas [78,86–88], including the main classes: typical savanna/shrub savanna, shrub grassland (savanna parkland), and floodplain grassland (*várzea*). Moreover, this region is under increasing pressure from large-scale economic projects, mainly from planted forests (Eucalyptus

and Acacia) [89] and soy crops using mechanized technology [90]. The savanna region (10,021 km<sup>2</sup>) contains only 917.69 km<sup>2</sup> (9.2%) of legally protected areas and 40.24 km<sup>2</sup> (0.4%) of "strictly protected" areas [91]. Nevertheless, the protected areas are predominantly "multiple uses," allowing for various activities such as small-scale livestock farming. The region has increased the frequency of anthropic fires that threaten the quality of habitats [91,92]. Therefore, the Amazon savannas need greater surveillance and conservation plans, as they are little known, have high exposure to human occupation, and are unprotected [5].

The ecological regions of dense ombrophylous forest are predominant in the state of Amapá, occurring in the plateau regions. In the study area, forests can be lowland or submontane (less than 600m high) with uniform canopy or emergent species (e.g., *Minuartia sp.*, *Eschweilera sp.*, *Couma sp.* and *Iryanthera sp.*) [88].

### **IV.3 Materials and Methods**

Image processing included the following steps (**Figure IV.2**): (a) acquisition of the Sentinel-1 time series (10 meters resolution); (b) data pre-processing; (d) noise minimization using the Savitsky-Golay smoothing filter; (e) analysis of the phenological behavior of Amazonian vegetation and human use (forest, savannah, mangrove, lowland vegetation, eucalyptus reforestation, and plantation areas); (f) comparison of classification methods (LSTM, Bi-LSTM, GRU, Bi-GRU, SVM, RF, k-NN and MLP) and; (g) accuracy analysis



**Figure IV.2.** Methodological flowchart.


### IV.3.1 Data Preparation

The present study used a Sentinel-1 time series (C band - 5.4 GHz) in the VH and VV polarizations over four years (2017 and 2020) provided by the European Space Agency (ESA) (<https://scihub.copernicus.eu/dhus/#/home>). The study area covers the eastern part of the state of Amapá, requiring the mosaic of two Sentinel-1 scenes from the Ground Range Detected (GRD) product in Interferometric Wide mode, with a resolution of 10 m, a scene width of 250 km, and a 12-day revisit cycle [95].

The research considered 122 temporal mosaics for each polarization from January 3, 2017, to December 25, 2020, totaling four years of vegetation observation with a revisit period of twelve days. The broad temporal interval allows the detection of natural vegetation phenological cycles, flood areas, or land-use changes [96]. The image pre-processing had five steps using the Sentinel Application Platform (SNAP) software [97]: (a) apply orbital file; (b) calibration by converting digital pixel values into radiometrically calibrated SAR backscatter; (d) range-Doppler terrain correction from the SRTM digital terrain model; (e) linear conversion to decibels (dB), and (f) stacking of pre-processed images into a single-time cube used in the temporal signature classification. Stacking the Sentinel-1 SAR images generates a time cube containing the

first image from 2017 to the last image from 2020. The geographic coordinates of the temporal cube are on the “x” (lines) and “y” (columns) axes. At the same time, the “z” axis represents the time signature of the backscattering considering a sequence of days of the year in ascending order.

SAR images inherently have Speckle noise which causes a grainy texture of light and dark pixels, making it difficult to detect targets, especially in low contrast areas. Noise filtering in radar images is a standard requirement, and different methods have been proposed, considering the spatial and temporal attributes of the images. In filtering time series of satellite images, a widely used method is the Savitzky and Golay (S-G) method [98], applied to optical [99,100] and radar images [47,101,102]. The S-G filtering used a one-dimensional window size of 13 over time, allowing a smoothing of the temporal trajectory and conserving the maximum and minimum values, which are crucial for the phenological analysis. **Figure IV.3** demonstrates the effect of the S-G filter in eliminating speckles in the S-1 time series. An advantage of the S-G filter for areas with vegetation and periodic flooding is its ability to combine noise elimination and preserve phenological attributes (height, shape, and asymmetry) [103,104]. Geng et al. [105] compared eight filtering techniques for reconstructing NDVI time series from multi-satellite sensors and showed that the S-G filter performs best in most situations. This method establishes a temporal signature that eliminates small interferences but maintains the characteristics of low and high values coming from the flood events and present in the phenology of vegetation and crops.



**Figure IV.3.** Sentinel-1 time series denoising using the Savitzky and Golay (S-G) method in the Amazon savanna. The original data is the gray line, and the data smoothed with the S-G filter is the purple line. C-band backscattering differences in VH polarization correspond to seasonal biomass variations during the wet (high values) and dry (low values) seasons.


### IV.3.2 Ground Truth and Sample Dataset

The selections of the sample sets of temporal signatures considered the following information: (a) visual interpretation of points with a similar pattern from high-resolution Google Earth images, (b) spatial analysis of the distribution of similar temporal signatures employing the Minimum Noise Fraction transformation and end-member analysis, (c) previous information from the vegetation and land-use maps at 1:250,000 scale developed by Brazilian Institute of Geography and Statistics (IBGE) in 2004 [104,105], and (d) specific surveys for soybean plantations and forest plantations currently limited to certain regions of our study area [89,90]. The IBGE mapping has a regional scale, and the land use information referring to 2004 is outdated due to recent agricultural growth. Therefore, regional information from the IBGE mapping was a guide for the manual interpretation of the sampling points. The study disregarded areas of the city due to the use of masks.

The present time-series mapping considered the water bodies, erosion/accretion changes in coastal and river environment, and phenological patterns of land cover/land use. Therefore, seven large land use/cover classes were subdivided into 17 subclasses according to the presence of temporal differences: water bodies (one class encompassing rivers, lakes, reservoirs, and ocean), hydrological changes (two classes including erosion and accretion areas), seasonally flooded grassland (four classes including sparse seasonally flooded grassland, dense seasonally flooded grassland 1 and 2, and floodplain areas), pioneer formations (three classes including herbaceous, shrub, and arboreal formations), savanna (two classes including shrub grassland, and savanna/shrub savanna), grassland, forest (two classes), and mangroves.

The sample selection totaled 8,500 pixels (time signatures), well distributed, systematic, and stratified [106,107] among the 17 classes, each with 500 samples (**Figure IV.4**). Therefore, the number of samples selected for each stratum (i.e., classes or categories) was 500. The training/validation/test split [108,109] had a total of 5,950-pixel samples for training (70%), 1,700-pixel samples for validation (20%), and 850-pixel samples for testing (10%).





**Figure IV.4.** Study area samples for training (cyan), validation (red) and test (orange).

### IV.3.3 Image classification

This study focused on comparing two broad sets of classification methods: traditional ML versus RNN. ML methods have historically played a valuable role in remote sensing image classification and segmentation studies. However, different DL methods have outperformed traditional models with considerable improvements, having a high potential for use in land-use/land-cover classification based on temporal data.

#### 3.1.1. Traditional Machine Learning Methods

This study tested traditional ML methods: RF [110], XGBoost [111], SVM [112], MLP [113], and k-NN [114]. The model optimization for ML and DL presents different peculiarities. The ML models usually present more easily adjustable parameters than robust models such as the LSTM or CNNs. Thus, a better way to adjust the parameters

is by using a grid search. To maintain cohesion with the DL models, we used the Grid Search performing tests in the validation set, aiming to optimize the F-score metric. **Table IV.1** lists the grid Search values used for each model. All ML models used the scikit-learn library.

**Table IV.1.** Configuration of the Recurrent Neural Network (RNN) models, pertaining to Deep Learning (DL) procedures, and grid search values used for each Machine Learning (ML) models: Random Forest (RF), Extreme Gradient Boosting (XGBoost), Support Vector Machines (SVM), Multilayer Perceptron (MLP), and k-Nearest Neighbors (k-NN).

Model	Parameter	Values
RF	bootstrap	[True, False]
	oob_score	[True, False]
	max_depth	[3, 5, 7]
	n_estimators	[50, 100, 200, 400]
	min_samples_split	[2, 3, 5]
	max_leaf_nodes	[None, 2, 4]
XGBoost	Learning_rate	[0.01, 0.05, 0.1]
	Min_child_weight	[1, 3, 5, 7]
	gamma	[1, 3, 5, 7]
	Colsample_bytree	[0.4, 0.5, 0.6]
	Max_depth	[3, 5, 7]
ML	Reg_alpha	[0, 0.2, 0.3]
	Subsample	[0.6, 0.8]
SVM	C	[0.5, 1, 2, 3, 5]
	Degree	[2, 3, 4]
	Kernel	[linear, rbf, poly]
MLP	Hidden_layer_sizes	[(100,50), (200,100), (300,150)]
	activation	[logistic, relu, tanh]
	Learning_rate	[0.01, 0.001]
	Max_iter	[500, 1000]
k-NN	N_neighbors	[5, 10, 15, 20]
	Weights	[uniform, distance]
RNN models	Epochs	5,000
	Dropout	0.5
	Optimizer	Adam
	Learning rate	0.001
DL	Loss function	Categorical cross-entropy
	Batch size	1,024
	Hidden layers	2
	Hidden layer sizes	(366, 122)

### 3.1.2. Recurrent Neural Network architectures

The RNN architectures are artificial intelligence methods developed for processing order-dependent data and support the use of high-dimensional input data, having a growing application in different types of studies such as natural language, audio, and video processing [117–119]. The two most widespread RNN methods are the LSTM [68] and the GRU [69].

The LSTM is one of the most common RNN architectures with internal memory and multiplicative gates that allow high performance on sequential data by recursively connecting sequences of information and capturing long temporal dependencies [120].

The LSTM architecture contains an input vector ( $X_t$ ), current block memory ( $C_t$ ), and current block output ( $h_t$ ), where nonlinearities activation functions are Sigmoid ( $\sigma$ ) and hyperbolic tangent ( $\tanh$ ), and the vector operations are element-wise multiplication ( $\times$ ) and element-wise concatenation ( $+$ ). Finally, the memory and output from the previous block are  $C_{t-1}$  and  $h_{t-1}$ . Among the proposed improvements to the LSTM architecture, the Bidirectional LSTM (Bi-LSTM) [121] stands out for overcoming the traditional LSTM problem of having a unidirectional strategy capable of capturing only information from previous time steps. Bi-LSTM models consider a backward layer (moving in the left-back direction) and forward layer (moving in the right-forward direction) in ordered data to capture past and future information, which makes the method more robust and contrasting with unidirectional LSTM models [122].

The GRU present a similar structure to the LSTM models. Nonetheless, it only shows two gates in its structure, the reset and update gates. Therefore, GRU achieves a performance equivalent to LSTM but with a reduced number of ports and, consequently, fewer parameters [123]. Table 1 lists the configuration of the Recurrent Neural Network (RNN) models.

### 3.4. Accuracy Assessment

The accuracy comparison of the ML and DL methods considered pixel-based metrics from the confusion matrix, which yields four possibilities: true positives, true negatives, false positives, and false negatives. The accuracy analysis considered the following metrics:

$$Overall\ Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F - score = \frac{2 \times (Precision \times Recall)}{Precision + Recall}$$



Besides, we used McNemar's test [124] to compare the statistical differences between the two classifiers. This paired nonparametric test considers a 2x2 contingency table and a Chi-Squared distribution of 1 degree of freedom. The method checks whether the proportion of errors between two classifiers coincides [125].

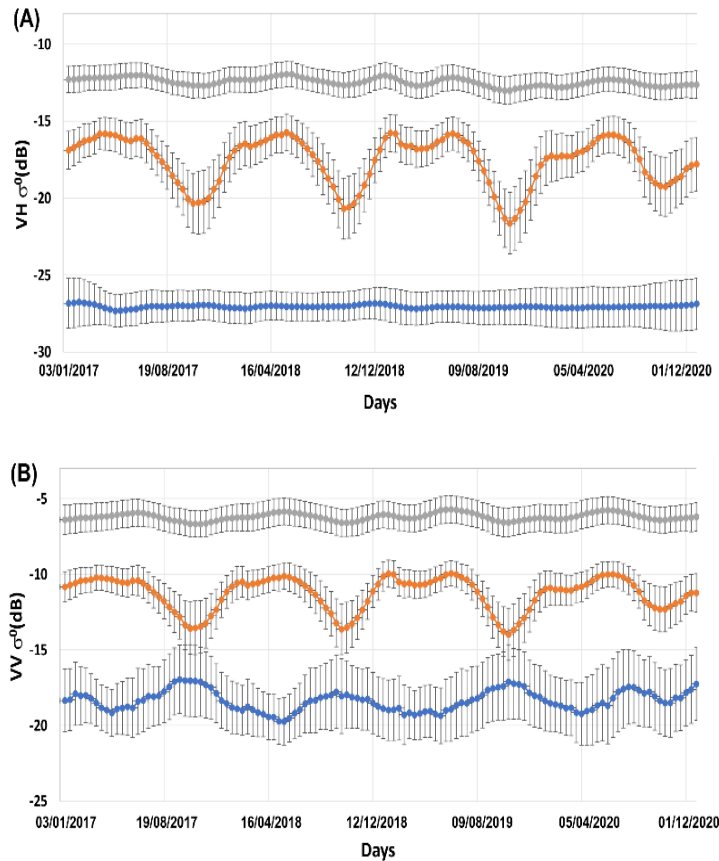
## **IV.4 Results**

### **IV.4.1 Multitemporal Backscattering Signatures**

This section describes the temporal signatures of water bodies, erosion/accretion changes in the coastal and river environment, and vegetation phenological patterns. The temporal signature graphs consist of the mean value of the 500 samples selected for each target with their respective standard deviation bars. The extreme backscattering values refer to the water class with the lowest values over the period and the forest with the highest values (**Figure IV.5**). Among the intermediate values, the savannas present temporal signatures with high variation and seasonal amplitude among the natural vegetation (**Figure IV.5**).

#### *4.1.1. Water Bodies and Accretion/Erosion Changes due to Coastal and River Dynamics*

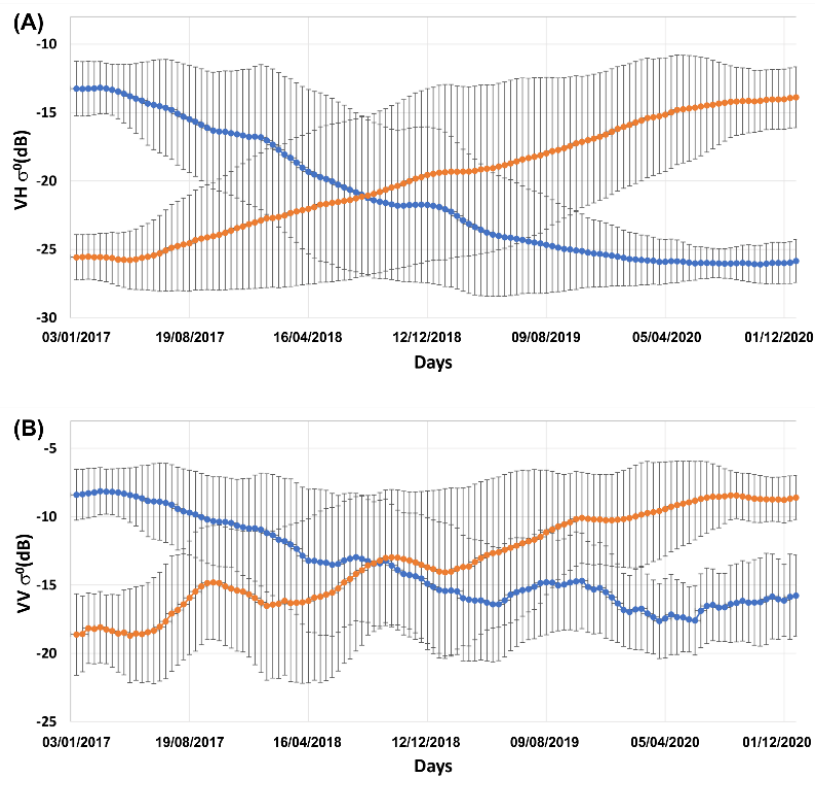
The water bodies (areas with a permanent presence of water, including oceans, seas, lakes, rivers, and reservoirs) show backscattering differences between the VV and VH polarizations due to environmental conditions and wave interference from winds and rain (**Figure IV.5**). The VV polarization is more sensitive to roughening of the water surface than VH polarization, increasing the backscatter return to the satellite. Therefore, lower VV backscatter values occur in environments under calm wind conditions (e.g., tank water and oxbow lake), while in areas with flowing water (e.g., flood water, river water, and oceans), they have higher values [124,125].



**Figure IV.5.** Mean temporal signatures of the 500 samples selected for water bodies (blue line), Ombrophilous Forest (gray line), and savannah (yellow line) considering VH (A) and VV (B) polarizations of Sentinel-1A. The curves display the standard deviation bars.


Some areas along the coast and rivers show temporal backscattering signatures that evidence transitions between terrestrial environments and areas covered by water. The temporal variation of backscatter from higher to lower values indicates erosion and progressive flooding, while the inverse indicates terrestrial accretion (**Figure IV.6**).

The massive discharge of fine grains at the mouth of the Amazon River intensely influences the coastal region of the State of Amapá, presenting a high dynamic of hydrodynamic and sedimentary processes that cause a constant alteration of the coast. In the short period of analysis, the migration of mud banks from the Amazon River along the coast presented successive and recurrent phases of erosion (**Figure IV.7A**) and accretion (**Figure IV.7B**) that marked apparent changes in a few years. In addition to changes in coastline, the time series show the fluvial dynamics of active meandering rivers, evidencing the process of erosion and deposition on the banks (**Figure IV.7C**). Changes in river morphology show a progressive development over time, and it is possible to observe channels in different phases of migration and sinuosity through Sentinel-1 images.



**Figure IV.6.** Mean temporal trajectory of the 500 samples selected considering Sentinel-1 data with VH (A) and VV polarization (B) for the classes: land accretion areas with water to land conversion (or-ange line), and land erosion areas with land to water conversion (blue line). The curves display the standard deviation bars.

The behavior of microwave energy in wetlands presents substantial spatial variability in backscattering according to vegetation cover. Thus, we detected four-time series describing microwave energy's interaction with water-vegetation patterns (**Figure IV.10**). The rise in water level gradually eliminates dispersions from the soil surface and the herbaceous stratum canopy, and the microwave energy acquires specular reflection (mirror-like reflection) from the water surfaces, causing a drop in backscatter values in the time series. The mean values and amplitude of the backscatter values vary with the density of herbaceous vegetation (dense, medium, or spaced) and the presence of woody wetlands (shrubs and trees).



**Figure IV.7.** Time series image sequences that show in the state of Amapá: (A) coastal erosion process, (B) coastal land accretion process, and (C) fluvial dynamic. The last image represents an RGB color composite (CC) composed of the images from January 2017, January 2019, and December 2020. The red colors in the images represent areas of land erosion and the blue ones of accretion.

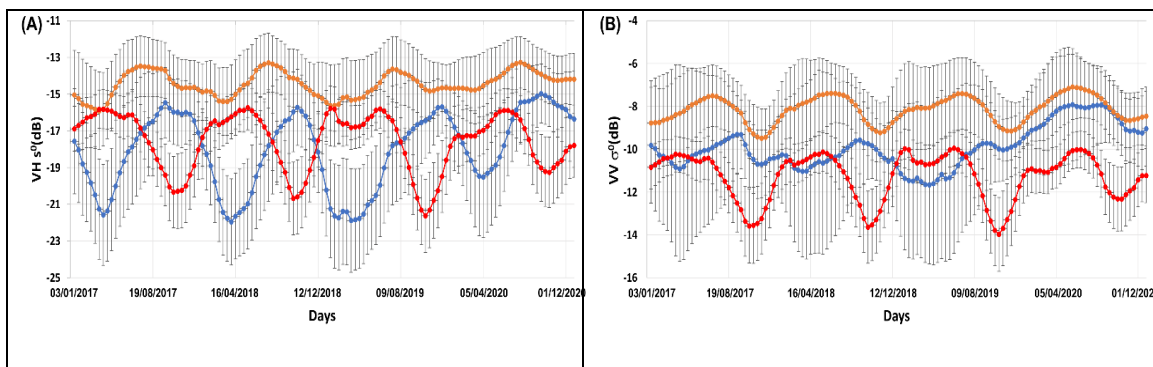
#### 4.1.2. Phenological Patterns

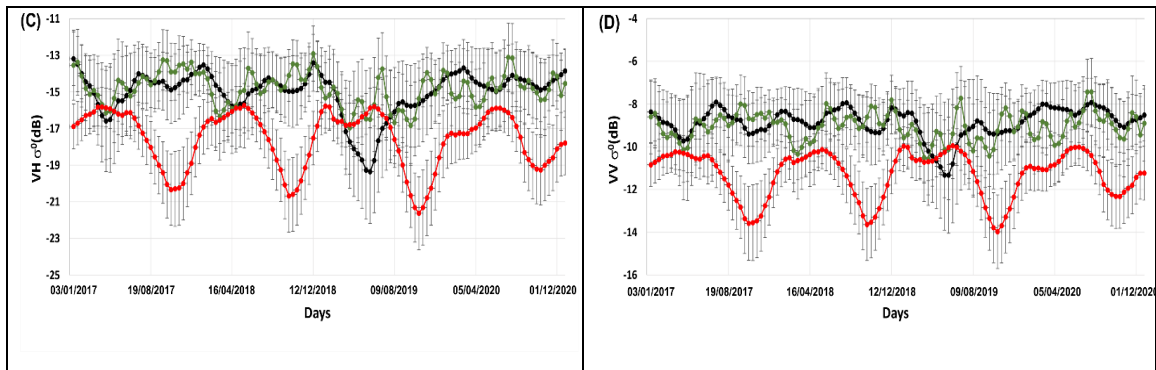
The different vegetation covers show temporal variations of backscattering (VV and VH) in the period 2017–2020, which are diagnostics for their individualization. The temporal signatures vary in floodable and non-flooded environments and different proportions of herbaceous and woody vegetation.

The interaction of C-band microwave energy in herbaceous wetlands depends on biophysical characteristics such as height, density, and canopy cover. In seasonally flooded areas, the rise in water level gradually eliminates dispersions from the soil surface and the herbaceous stratum canopy, causing microwave energy to acquire specular reflection (mirror-like reflection) from the water surfaces and decrease the backscatter

values. Figure 8A,C show the seasonally flooded grassland (blue line) consisting of open areas formed predominantly by sparse herbaceous formations with periodic flooding and moist soils. Flooding over short grasslands causes the lowest backscatter values, providing the SAR time series with greater amplitudes. The grasslands covered by water during the flood season cause a specular behavior that results in a drop in backscatter values (Figure 8A,C, blue line). With the retreat of the hydrological pulse, the interaction of microwaves with the vegetation cover gradually increases and, consequently, the value of sigma naught ( $\sigma^0$ ). These flooded vegetation time series differ from non-floodable grassland (Figure 8A,C, red line), which present maximum backscatter values in the rainy season due to increased biomass. Therefore, there is an entirely antagonistic behavior between non-floodable savanna areas and seasonally flooded grasslands, where the peak of the backscatter values occurs at the lowest values of the other.

Seasonally flooded vegetation composed of medium and dense herbaceous vegetation causes multiple-path scattering with higher backscatter values and lower amplitude in the time series (Figure 8B,D, green and black lines). However, these grasslands show the exact dates of relative minimums during the flood period. In contrast, dense herbaceous vegetation with a sparse presence of woody vegetation (shrubs and trees) (Figure 8A, orange line) shows a change in VV polarization, which tends to have more significant canopy scattering, and the water surface portion leads to double-bounce scattering with the trunks. This behavior changes the dates with minimum values for VV polarization that tend to place them near the savanna vegetation (red line). This vegetation (Figure 8A, orange line) occurs in floodplain areas (várzea) following the drainages and intertwining with riparian forests in savannah areas, along humid dense grassland, and lake margins in the coastal plain.

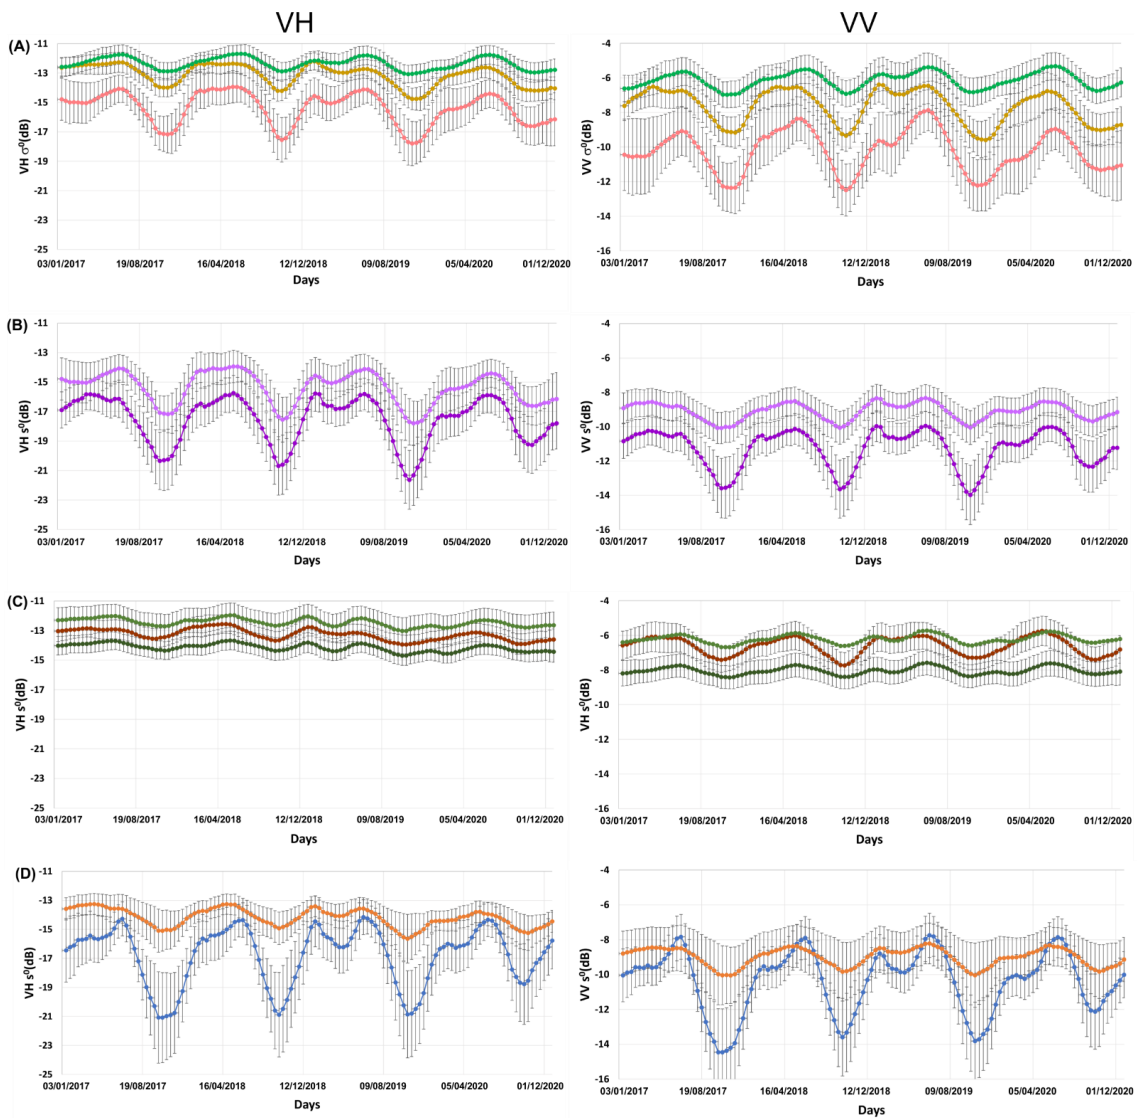




**Figure IV.8.** Average temporal signatures of the 500 samples selected for each seasonally flooded grasslands: sparse herbaceous (blue line) and grasslands with the presence of sparse woody (orange line) with VH (A) and VV (B) polarizations. In addition, grassland with a medium and dense herbaceous (black and sea green lines) with VH (C) and VV (D) polarizations. All graphs present the non-floodable shrub grassland time series (red line) compared with seasonally flooded areas. The curves display the standard deviation bars.

The non-floodable grasslands and savannas present backscatter time series with similar formats that differ in absolute values and relative amplitude. As the tree-shrub components increase, the backscatter values increase, and the relative amplitude decreases. Figure 9A,E exemplify the increase in the proportion of arboreal vegetation in the pioneer formations: herbaceous (magenta line), shrub (yellow line), and arboreal (green line). In addition, Figure 9B,F present the time series of the shrub grassland (dark purple line) and savanna/shrub savanna (light purple line). The lowest features in the time series reflect the period of lowest precipitation, while the highest values reflect the rainy season.





**Figure IV.9.** Average temporal signatures (Sentinel 1 VV and VH radar signals) of 500 samples with their respective standard deviation bars for the following classes: (A) pioneer formations with the increase of the tree-shrub stratum (herbaceous (magenta line) > shrub (yellow line) > arboreal (green line)); (B) shrub grassland (dark purple line) and savanna/shrub savanna curve (light purple line); (C) two time series of ombrophilous forest (green lines) and mangroves (brown line) with the insertion of the savanna time series (red line) for comparison; and (D) agricultural planting (blue line) and eucalyptus plantation (orange line).

Forest formations show the highest values of backscattering and low seasonal variations between the time series (Figure 9C,G), represented by ombrophilous forests in plateaus (sea-green lines) and mangroves in the coastal plain (forehead line). The representations of the ombrophilous forests considered two curves, one predominant in the study area (sea green line) and another restricted to places with the topographic effect that generate high values of backscatter (green line).

Finally, Figure 9D,H present the time series of anthropic use referring to agricultural cultivation areas (predominantly soy plantations) (blue line) and eucalyptus plantations (green line). The time series of soybean planting areas present similar shapes to

savanna areas but with more accentuated minimum and maximum values of backscattering provided by anthropic activities.

#### 4.1.3. Comparison between RNN and others Machine Learning methods

Table IV.2 lists the accuracy metrics for different datasets (VV-only, VH-only, and VV&VH polarizations) and classification methods. Among the datasets, the accuracy metrics show a marked difference with the following ordering VV&VH > VH-only > VV-only. The differences in accuracy metrics between VV-only and VH-only are more remarkable than between VH-only and VV&VH. The k-NN model that obtained the worst accuracy values in the VH-only dataset corresponded to the Bi-GRU accuracy, with the most elevated values in the VV-only dataset.

The Bi-GRU model presented the highest overall accuracy, precision, recall, and F-score for all three data sets (Table IV.2). Despite Bi-GRU being the most accurate model, the differences were not prominent with the other RNN methods, being less than 1% in the F-score. The general behavior was Bi-GRU > Bi-LSTM > GRU > LSTM, where bidirectional layers benefit the results. Among the ML models, the SVM and the MLP obtained the highest accuracies. Specifically, for the VH and VV&VH datasets, the SVM obtained values slightly over 1% worse than the Bi-GRU. The k-NN model obtained minor accurate results for all datasets, followed by the RF. Differences in accuracy metrics among models decrease considerably within the VV&VH dataset compared to VH-only and VV-only. Therefore, the VV&VH dataset achieves more accurate results across all models and approximates their values.

**Table IV.2.** Overall Accuracy (OA), precision (P), recall (R), and F-score (F1) metrics for the following methods: Deep Learning (DL), Machine Learning (ML), Long Short-Term Memory (LSTM), Bidirectional LSTM (Bi-LSTM), Gated Recurrent Unit (GRU), Bidirectional GRU (Bi-GRU), Multilayer Perceptron (MLP), Extreme Gradient Boosting (XGBoost), Random Forest (RF), Support Vector Machines (SVM), and k-Nearest Neighbors(k-NN).

Model	VV				VH				VV&VH			
	AO	P	R	F1	AO	P	R	F1	AO	P	R	F1
Bi-LSTM	<b>85.57*</b>	85.79	<b>85.57</b>	85.68	90.98	91.19	90.98	91.08	93.26	93.33	93.26	93.29
LSTM	85.02	85.23	85.02	85.12	90.59	90.63	90.59	90.61	93.1	93.19	93.1	93.15
Bi-GRU	<b>85.57*</b>	<b>85.88</b>	<b>85.57</b>	<b>85.72</b>	<b>91.61</b>	<b>91.64</b>	<b>91.61</b>	<b>91.63</b>	<b>93.49</b>	<b>93.58</b>	<b>93.49</b>	<b>93.53</b>
GRU	85.1	85.21	85.1	85.15	90.51	90.73	90.51	90.62	93.18	93.34	93.18	93.3
MLP	83.77	84.1	83.77	83.93	88.78	89.81	88.78	89.29	90.82	91.2	90.82	91.01
XGBoost	83.14	83.99	83.14	83.56	88.39	88.63	88.39	88.51	91.92	92.04	91.92	91.98
RF	81.33	82.26	81.33	81.79	87.53	87.79	87.23	87.66	90.67	90.94	90.67	90.8
SVM	82.59	83.21	82.59	82.9	90.19	90.31	90.2	90.25	92.16	92.21	92.16	92.18
k-NN	78.75	80.43	78.75	79.58	85.33	86.22	85.33	85.77	88.94	88.25	88.94	89.37



**Table IV.3** shows the Bi-GRU model's accuracy metrics per land-cover/land-use category. Most classes obtained greater accuracy using the VV&VH dataset, where all categories had an F-score above 80% and thirteen above 90%. In contrast, the VH dataset had eleven categories with an F-score >90%, while the VV dataset had only six categories. This result demonstrates the complementarity of the two polarizations in the classification process. The water bodies class presented 100% accuracy, the target with the best accuracy in all data sets. Mangroves were the only class that obtained accuracy metrics lower than 80% for the VH-only dataset, which contrasted with the values above 90% obtained with the VV-only dataset. Additionally, mangrove precision was the only metric in which the VV-only data outperformed the other datasets. The lowest F-score with the VV&VH dataset was the shrub grassland class (84.93%) due to confusion with other grasslands.


**Table IV.3.** Per category metrics for the most accurate model Bidirectional Gated Recurrent Units (Bi-GRU) considering precision, recall, and F-score. The land-cover/land-use classes are: (1) water bodies, (2) land erosion, (3) land accretion, (4) sparse seasonally flooded grassland, (5) dense seasonally flooded grassland 1, (6) dense seasonally flooded grassland 2, (7) dense humid grassland and floodplain areas, (8) pioneer herbaceous formation, (9) pioneer shrub formation, (10) pioneer arboreal formation, (11) shrub grassland, (12) savanna/shrub savanna, (13) mangroves, (14) forest 1, (15) forest 2, (16) agriculture plantations (soybean), and (17) planted forest.

Class	VV			VH			VV+VH		
	P	R	F-score	P	R	F-score	P	R	F-score
1 - water bodies	<b>100*</b>	94.67	97.26	<b>100*</b>	96	97.96	<b>100*</b>	<b>97.33</b>	<b>98.65</b>
2 - land erosion	91.14	96	93.51	92.41	97.33	94.81	<b>92.5</b>	<b>98.67</b>	<b>95.48</b>
3 - land accretion	95.95	94.67	95.3	<b>98.65</b>	<b>97.33</b>	<b>97.99</b>	98.63	96.00	97.30
4 - sparse seasonally flooded grassland	78.16	90.67	83.95	93.51	<b>96.00*</b>	94.74	<b>96.00</b>	<b>96.00*</b>	<b>96.00</b>
5 - dense seasonally flooded grassland 1	87.5	84.00	85.71	94.81	<b>97.33*</b>	96.05	<b>97.33</b>	<b>97.33*</b>	<b>97.33</b>
6 - dense seasonally flooded grassland 2	95.89	93.33	94.59	<b>97.30</b>	<b>96.00</b>	<b>96.64</b>	<b>97.30</b>	<b>96.00</b>	<b>96.64</b>
7 - dense humid grassland and floodplain areas	86.44	68.00	76.12	93.33	93.33	93.33	<b>93.59</b>	<b>97.33</b>	<b>95.42</b>
8 - pioneer herbaceous formation	85.9	89.33	87.58	<b>97.22</b>	93.33	95.24	96.00	<b>96.00</b>	<b>96.00</b>
9 - pioneer shrub formation	84.42	86.67	85.53	<b>97.26</b>	<b>94.67</b>	<b>95.95</b>	94.44	90.67	92.52
10 - pioneer arboreal formation	71.25	76.00	73.55	85.9	89.33	87.58	<b>91.55</b>	86.67	<b>89.04</b>
11 - shrub grassland	75.68	74.67	75.17	83.75	<b>89.33</b>	<b>86.45</b>	<b>87.32</b>	82.67	84.93
12 - savanna/shrub savanna	88.31	90.67	89.47	<b>93.67</b>	98.67	96.1	92.59	<b>100</b>	<b>96.15</b>
13 - mangroves	<b>92.00</b>	92.00	92.00	76.71	74.67	75.68	91.03	<b>94.67</b>	<b>92.81</b>
14 - forest 1	78.48	82.67	80.52	88.31	<b>90.67</b>	89.47	<b>95.65</b>	88.00	<b>91.67</b>
15 - forest 2	72.41	84.00	77.78	83.56	81.33	82.43	<b>84.81</b>	<b>89.33</b>	<b>87.01</b>
16 - agriculture plantations (soybean)	94.44	90.67	92.52	95.83	92.00	93.88	<b>97.22</b>	<b>93.33</b>	<b>95.24</b>
17 - planted forest	81.97	66.67	73.53	<b>85.71</b>	80.00	82.76	84.81	<b>89.33</b>	<b>87.01</b>

Figure IV.10 shows McNemar's test results with a significance level of 0.05. The results demonstrate that the deep learning models are equivalent to each other within the same dataset (VV-only, VH-only, and VV&VH), given that the differences are tight. Among ML methods, the SVM presented similarities to the RNN models within all

datasets. In addition, two other ML methods were statistically equivalent to RNN methods within the same dataset: (a) MLP with the VV-only dataset and (b) XGBoost with the VV&VH dataset.

Comparing the McNemar test between the methods with different datasets, the k-NN with the VH-only dataset had a similar result to the RNN methods using the VV-only dataset. Therefore, the least accurate method of the VH-only dataset presents statistical similarity with the best methods with the VV-only dataset. Accuracy measurements also corroborate this result. Among the VH-only and VV&VH datasets, many machine learning methods are statistically related to RNNs with VH-only.



**Figure IV.10.** McNemar's statistical test at a significance level of 0.05 containing red cells represent paired methods significantly different from each other, and green cells describe similar results. The models are shown in numbered order: (1) Bidirectional Gated Recurrent Unit (Bi-GRU), (2) GRU, (3) Bidirectional Long Short-Term Memory (Bi-LSTM), (4) LSTM, (5) Random Forest, (6) XGBoost, (7) Support Vector Machine, (8) k-Nearest Neighbor, and (9) Multilayer perceptron.

#### 4.1.4. Land-Cover/Land-Use Map

Figure IV.11 presents the detailed classification of an area with the highest and lowest accuracy metrics between the RNN (Bi-GRU and LSTM) and ML (SVM and k-NN) methods using the different datasets (VV only, VH only, and VV&VH). The results demonstrate a high similarity between the methods with small punctual changes, which explains the values close to the accuracy metrics.


Figure IV.12 presents the vegetation map of the southeastern region of the State of Amapá using the most accurate model, assuming the Bi-GRU method and the VV&VH dataset. The map shows the variation from the coastal zone to the interior with a progressive change according to topographic altitude. Along the maritime coast, the coastline has high dynamics with the presence of eroded and accretion areas. In the northeastern part of the study area, significant areas of mangroves develop along the coastal zones. The high fluvial dynamics in the coastal plain describe extensive areas

with periodic flooding characterized by phenological behaviors, with minimum points in the rainy seasons and elevation of the water level (marked in cyan on the map). In the coastal plains, the high dynamics of the fluvial, fluvial-lacustrine, and fluvial-marine processes establish the formation of large lagoons and pedologically unstable areas covered by pioneer vegetation (first occupation of edaphic character with adaptation to environmental conditions). These pioneer vegetations in the northeast of the area present zoning of herbaceous, shrub, and forest formations intensely related to the altitude.









**Figure IV.12.** Land-cover map of the southeastern region of the State of Amapá using the Bi-directional Gated Recurrent Unit (Bi-GRU) method, which obtained the best accuracy measures. The dashed square corresponds to the area in Figure 11.

The savanna region, located in the low plateaus, has extensive areas in the western portion of the study area. The rivers in the savannah areas contain areas of floodplain fields with periodic flooding and gallery forests. The savannah areas present a significant advance of anthropic use, mainly planted forests and soybean cultivation. In the western part of the study area, the ombrophilous forests predominate, characterized by higher values of backscattering.

#### IV.5 Discussion

The increasing availability of time series data from radar images and new deep learning algorithms establish novel perspectives for land-cover/land-use mapping in the Amazon region. Therefore, this research contributes to establishing and describing the main S-1 temporal signatures of land-use/land-cover and hydrological changes for the Amazon region (Amapá) and evaluating different datasets and machine and deep learning methods in time-series classification.

##### *5.1. Temporal signatures of water bodies and alterations by land accretion and erosion processes in coastal and river environments*

Due to specular reflection, water bodies have the lowest backscatter values over the entire period. The tests with the VH dataset achieved more accuracy in water detection

than the VV dataset under the presence of waves or running water, corroborating with other studies [127,128]. However, VV polarization may perform slightly more accurately in mapping water bodies under calm wind conditions [126,129] and in oil spill detection [130,131]. The study area, being at the mouth of the Amazon River, has high coastal and fluvial dynamics providing significant changes over the four years evaluated. Localities with land accretion and erosion due to coastal and fluvial dynamics present a typical temporal signature with increasing and decreasing backscatter values, respectively.

### *5.2. Temporal signatures of water bodies and alterations by land accretion and erosion processes in coastal and river environments*

The S-1 time series are suitable for analyzing the dynamics of floods due to the short period of revisits with data acquisition independent of any temporal condition [132]. Periodically flooded grasslands have the lowest backscattering values in the rainy season due to water cover, unlike other non-flooded vegetations that acquire higher values during this period due to biomass growth. The increase in the biophysical characteristics of the herbaceous wetlands (height, density, and canopy covers) causes an increase in backscatter values. Lowland regions in savannah areas with dense and tall graminoid and sparse shrub vegetation show differences between the minimum seasonal features in the VH and VV polarizations. The C-band with VV polarization (C-VV) presents a more significant behavior of double-bounce scattering, where the SAR electromagnetic energy interacts once on the water surface and once on the stalk or trunks, providing higher backscatter values in the flood season [133–135]. Zhang et al. [135] describe the existence of a clear positive correlation between the water level and the C-VV backscatter coefficient for areas with medium and high-density graminoids, which is not so evident for C-band with VH polarization (C-VH). Therefore, double-bounce scattering in herbaceous wetlands is dependent and correlated with biophysical characteristics, being more pronounced in co-polarizations than in cross-polarizations [136–138].

The presence of topographical alterations in the terrain allows the establishment of a non-floodable environment of savannas formed by an herbaceous stratum with different proportions from the arboreal-shrubby vegetation. The non-floodable savanna vegetations have time series with similar shapes that differ in intensity and amplitude according to the proportion of woody vegetation. As the proportion of woody vegetation

increases, the backscatter values increase, and the time-series amplitude decreases. Forest formations have the highest backscattering values due to ground-trunk or soil-canopy scattering. The mangrove class is the only one among the different classes that present better results using the C-VV, probably due to double-bounce scattering. However, this effect dissipates in dense mangrove forests due to the inability of the C band to penetrate the canopy [139].

### *5.3 Classifier Comparison*

In the classification process, the present research compared three different datasets (VV-only, VH-only, and VV&VH) and methods, considering RNN (Bi-GRU, Bi-LSTM, GRU, and LSTM) and ML (SVM, XGBoost, MLP, and k-NN) algorithms. Although RNN methods are revolutionizing time-series classification, few studies still explore the combination of SAR data with these algorithms in the classification of natural vegetation. Most studies focus on mapping agricultural plantations. Among the tests performed, the model with the best accuracy metrics was the Bi-GRU method with the VV&VH dataset. Different studies show that VV and VH polarizations together have greater accuracies than using a single polarization, such as detecting crops [60,140,141]. Bi-directional RNN models got more accurate results than the ML models, where Bi-GRU led to the most remarkable accuracies for all the datasets, followed closely by Bi-LSTM. The GRU and LSTM models were in third and fourth positions. Among the ML models, the SVM had the best result for the VH-only and VH&VV datasets, while the MLP had the highest accuracies for the VV-only dataset.

Some phenology-based classification studies using S-1 time series and RNN methods were consistent with the present research. Ndikumana et al. [42] classified agricultural plantation classes from the S-1 time series considering RNN (LSTM and GRU) and ML (k-NN, RF, and SVM), where RNN-based methods outperformed traditional methods, and the GRU was slightly superior to the LSTM method. Crisóstomo de Castro Filho [47] obtained better results with Bi-LSTM than with LSTM and other traditional methods (SVM, RF, k-NN, and Normal Bayes) in detecting rice with S-1 time series. Other studies do not compare many methods but demonstrate better performance using DL models. Reuß et al. [41] found that LSTM networks outperform RF in the large-scale crop classification using Sentinel -1 time series. Zhao et al. [46] obtained better Kappa values with the one-dimensional convolutional neural



networks (1D CNN) compared to the GRU, LSTM, and RF methods for early crop classification. Finally, Minh et al. [76] obtained better results for mapping winter vegetation with the GRU model, which was slightly superior to LSTMs and notably better than RF and SVM.

McNemar's test demonstrates that the RNN methods (Bi-GRU, Bi-LSTM, GRU, and LSTM), SVM, and XGBoost for the VV&VH datasets (with higher accuracy results) have a similar proportion of errors (marginal probabilities). These results demonstrate that the constant advances in artificial intelligence techniques have increasingly narrowed the differences between the methods. Thus, some studies focus only on increasing the predictive performance; for example, a 1% improvement in the average accuracy score of the COCO dataset could be considered relevant [142,143].

## **IV.6 Conclusions**

The different phenology of the terrestrial surface in the state of Amapá contributes remarkably to the characteristics of its diverse ecosystems and biodiversity, which describes the distribution of animal species and the appropriation of anthropic use. Therefore, understanding the spatiotemporal patterns of vegetation is essential to establishing environmental conservation and management guidelines. The Amazon region of the state of Amapá has a high diversity and complexity of landscapes with the presence of forests, savannas, grasslands, flooded vegetation, and mangroves. The present study performs a phenology-based classification of land cover types in the Amazon using the time series of S-1 data with a periodicity of 12 days over four years. The results demonstrate that the seasonal behavior of Sentinel-1 backscatter provides a potential basis for identifying different vegetation classes. Employing VV and VH polarizations together improves accuracy metrics compared to simple polarizations (VV-only and VH-only). In the case of using only a single polarization, the best accuracy metrics were the VH polarization. The Bi-GRU model obtained the best accuracy metrics, with values slightly higher than the Bi-LSTM in all datasets. However, McNemar's test shows that the RNN methods, SVM, and XGBoost are statistically equivalent using the VV&VH dataset that obtained the best accuracies. The results of the phenology-based classification allow a detailing of the spatial distribution of land/use and land/cover classes and of the changes arising from coastal and river dynamics in an environmentally sensitive region.

## References

1. Devecchi, M.F.; Lovo, J.; Moro, M.F.; Andrino, C.O.; Barbosa-Silva, R.G.; Viana, P.L.; Giulietti, A.M.; Antar, G.; Watanabe, M.T.C.; Zappi, D.C. Beyond forests in the Amazon: Biogeography and floristic relationships of the Amazonian savannas. *Bot. J. Linn. Soc.* **2021**, *193*, 478–503, doi:10.1093/BOTLINNEAN/BOAA025.
2. Antonelli, A.; Zizka, A.; Carvalho, F.A.; Scharn, R.; Bacon, C.D.; Silvestro, D.; Condamine, F.L. Amazonia is the primary source of Neotropical biodiversity. *Proc. Natl. Acad. Sci. U. S. A.* **2018**, *115*, 6034–6039, doi:10.1073/pnas.1713819115.
3. De Carvalho, W.D.; Mustin, K. The highly threatened and little known Amazonian savannas. *Nat. Ecol. Evol.* **2017**, *1*, 1–3, doi:10.1038/s41559-017-0100.
4. Pires, J.M.; Prance, G.T. The vegetation types of the Brazilian Amazon. In *Amazonia: key environments*; Prance, G.T., Lovejoy, T.E., Eds.; Pergamon Press: New York, NY, USA, 1985; pp. 109–145 ISBN 9780080307763.
5. Dias, T.C.A. de C.; Cunha, A.C. da; Silva, J.M.C. da Return on investment of the ecological infrastructure in a new forest frontier in Brazilian Amazonia. *Biol. Conserv.* **2016**, *194*, 184–193, doi:10.1016/j.biocon.2015.12.016.
6. Xie, Y.; Sha, Z.; Yu, M. Remote sensing imagery in vegetation mapping: a review. *J. Plant Ecol.* **2008**, *1*, 9–23, doi:10.1093/jpe/rtm005.
7. Lechner, A.M.; Foody, G.M.; Boyd, D.S. Applications in Remote Sensing to Forest Ecology and Management. *One Earth* **2020**, *2*, 405–412, doi:10.1016/j.oneear.2020.05.001.
8. Bajocco; Raparelli; Teofili; Bascietto; Ricotta Text Mining in Remotely Sensed Phenology Studies: A Review on Research Development, Main Topics, and Emerging Issues. *Remote Sens.* **2019**, *11*, 2751, doi:10.3390/rs11232751.
9. Misra, G.; Cawkwell, F.; Wingler, A. Status of phenological research using sentinel-2 data: A review. *Remote Sens.* **2020**, *12*, 10–14, doi:10.3390/RS12172760.
10. Caparros-Santiago, J.A.; Rodriguez-Galiano, V.; Dash, J. Land surface phenology as indicator of global terrestrial ecosystem dynamics: A systematic review. *ISPRS J. Photogramm. Remote Sens.* **2021**, *171*, 330–347, doi:10.1016/j.isprsjprs.2020.11.019.
11. Gao, F.; Zhang, X. Mapping Crop Phenology in Near Real-Time Using Satellite Remote Sensing: Challenges and Opportunities. *J. Remote Sens.* **2021**, *2021*, 1–14, doi:10.34133/2021/8379391.
12. Broich, M.; Huete, A.; Paget, M.; Ma, X.; Tulbure, M.; Coupe, N.R.; Evans, B.; Beringer, J.; Devadas, R.; Davies, K.; et al. A spatially explicit land surface phenology data product for science, monitoring and natural resources management applications. *Environ. Model. Softw.* **2015**, *64*, 191–204, doi:10.1016/j.envsoft.2014.11.017.
13. D’Odorico, P.; Gonsamo, A.; Gough, C.M.; Bohrer, G.; Morison, J.; Wilkinson, M.; Hanson, P.J.; Gianelle, D.; Fuentes, J.D.; Buchmann, N. The match and mismatch between photosynthesis and land surface phenology of deciduous forests. *Agric. For. Meteorol.* **2015**, *214–215*, 25–38, doi:10.1016/j.agrformet.2015.07.005.
14. Richardson, A.D.; Keenan, T.F.; Migliavacca, M.; Ryu, Y.; Sonnentag, O.;

- Toomey, M. Climate change, phenology, and phenological control of vegetation feedbacks to the climate system. *Agric. For. Meteorol.* **2013**, *169*, 156–173, doi:10.1016/j.agrformet.2012.09.012.
15. Workie, T.G.; Debella, H.J. Climate change and its effects on vegetation phenology across ecoregions of Ethiopia. *Glob. Ecol. Conserv.* **2018**, *13*, e00366, doi:10.1016/j.gecco.2017.e00366.
  16. Piao, S.; Liu, Q.; Chen, A.; Janssens, I.A.; Fu, Y.; Dai, J.; Liu, L.; Lian, X.; Shen, M.; Zhu, X. Plant phenology and global climate change: Current progresses and challenges. *Glob. Chang. Biol.* **2019**, *25*, 1922–1940, doi:10.1111/gcb.14619.
  17. Morellato, L.P.C.; Alberton, B.; Alvarado, S.T.; Borges, B.; Buisson, E.; Camargo, M.G.G.; Cancian, L.F.; Carstensen, D.W.; Escobar, D.F.E.; Leite, P.T.P.; et al. Linking plant phenology to conservation biology. *Biol. Conserv.* **2016**, *195*, 60–72, doi:10.1016/j.biocon.2015.12.033.
  18. Rocchini, D.; Andreo, V.; Förster, M.; Garzon-Lopez, C.X.; Gutierrez, A.P.; Gillespie, T.W.; Hauffe, H.C.; He, K.S.; Kleinschmit, B.; Mairota, P.; et al. Potential of remote sensing to predict species invasions. *Prog. Phys. Geogr. Earth Environ.* **2015**, *39*, 283–309, doi:10.1177/0309133315574659.
  19. Evangelista, P.; Stohlgren, T.; Morissette, J.; Kumar, S. Mapping Invasive Tamarisk (Tamarix): A Comparison of Single-Scene and Time-Series Analyses of Remotely Sensed Data. *Remote Sens.* **2009**, *1*, 519–533, doi:10.3390/rs1030519.
  20. Nguyen, L.H.; Henebry, G.M. Characterizing Land Use/Land Cover Using Multi-Sensor Time Series from the Perspective of Land Surface Phenology. *Remote Sens.* **2019**, *11*, 1677, doi:10.3390/rs11141677.
  21. Potgieter, A.B.; Zhao, Y.; Zarco-Tejada, P.J.; Chenu, K.; Zhang, Y.; Porker, K.; Biddulph, B.; Dang, Y.P.; Neale, T.; Roosta, F.; et al. Evolution and application of digital technologies to predict crop type and crop phenology in agriculture. *in silico Plants* **2021**, *3*, doi:10.1093/insilicoplants/diab017.
  22. Wolkovich, E.M.; Cook, B.I.; Davies, T.J. Progress towards an interdisciplinary science of plant phenology: Building predictions across space, time and species diversity. *New Phytol.* **2014**, *201*, 1156–1162, doi:10.1111/nph.12599.
  23. Park, D.S.; Newman, E.A.; Breckheimer, I.K. Scale gaps in landscape phenology: challenges and opportunities. *Trends Ecol. Evol.* **2021**, *36*, 709–721, doi:10.1016/j.tree.2021.04.008.
  24. Asner, G.P. Cloud cover in Landsat observations of the Brazilian Amazon. *Int. J. Remote Sens.* **2001**, *22*, 3855–3862, doi:10.1080/01431160010006926.
  25. Martins, V.S.; Novo, E.M.L.M.; Lyapustin, A.; Aragão, L.E.O.C.; Freitas, S.R.; Barbosa, C.C.F. Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): Insights for remote sensing and climate analysis. *ISPRS J. Photogramm. Remote Sens.* **2018**, *145*, 309–327, doi:10.1016/j.isprsjprs.2018.05.013.
  26. Batista Salgado, C.; Abílio de Carvalho, O.; Trancoso Gomes, R.A.; Fontes Guimarães, R. Cloud interference analysis in the classification of MODIS-NDVI temporal series in the Amazon region, municipality of Capixaba, Acre - Brazil. *Soc. Nat.* **2019**, *31*, 1–19.
  27. Liu, C. an; Chen, Z. xin; Shao, Y.; Chen, J. song; Hasi, T.; Pan, H. zhu Research advances of SAR remote sensing for agriculture applications: A review. *J. Integr. Agric.* **2019**, *18*, 506–525, doi:10.1016/S2095-3119(18)62016-7.
  28. Jin, X.; Kumar, L.; Li, Z.; Feng, H.; Xu, X.; Yang, G.; Wang, J. A review of data assimilation of remote sensing and crop models. *Eur. J. Agron.* **2018**, *92*, 141–

- 152, doi:10.1016/j.eja.2017.11.002.
29. David, R.M.; Rosser, N.J.; Donoghue, D.N.M. Remote sensing for monitoring tropical dryland forests: a review of current research, knowledge gaps and future directions for Southern Africa. *Environ. Res. Commun.* **2022**, *4*, 042001, doi:10.1088/2515-7620/ac5b84.
  30. Tsyganskaya, V.; Martinis, S.; Marzahn, P.; Ludwig, R. SAR-based detection of flooded vegetation—a review of characteristics and approaches. *Int. J. Remote Sens.* **2018**, *39*, 2255–2293, doi:10.1080/01431161.2017.1420938.
  31. Dostálová, A.; Lang, M.; Ivanovs, J.; Waser, L.T.; Wagner, W. European wide forest classification based on sentinel-1 data. *Remote Sens.* **2021**, *13*, 1–27, doi:10.3390/rs13030337.
  32. Dostálová, A.; Wagner, W.; Milenković, M.; Hollaus, M. Annual seasonality in Sentinel-1 signal for forest mapping and forest type classification. *Int. J. Remote Sens.* **2018**, *39*, 7738–7760, doi:10.1080/01431161.2018.1479788.
  33. Ling, Y.; Teng, S.; Liu, C.; Dash, J.; Morris, H.; Pastor-Guzman, J. Assessing the Accuracy of Forest Phenological Extraction from Sentinel-1 C-Band Backscatter Measurements in Deciduous and Coniferous Forests. *Remote Sens.* **2022**, *14*, 1–14, doi:10.3390/rs14030674.
  34. Rüetschi, M.; Schaepman, M.E.; Small, D. Using multitemporal Sentinel-1 C-band backscatter to monitor phenology and classify deciduous and coniferous forests in Northern Switzerland. *Remote Sens.* **2018**, *10*, 1–30, doi:10.3390/rs10010055.
  35. Tsyganskaya, V.; Martinis, S.; Marzahn, P. Flood Monitoring in Vegetated Areas Using Multitemporal Sentinel-1 Data: Impact of Time Series Features. *Water* **2019**, *11*, 1938, doi:10.3390/w11091938.
  36. Tsyganskaya, V.; Martinis, S.; Marzahn, P.; Ludwig, R. Detection of temporary flooded vegetation using Sentinel-1 time series data. *Remote Sens.* **2018**, *10*, doi:10.3390/rs10081286.
  37. Hu, Y.; Tian, B.; Yuan, L.; Li, X.; Huang, Y.; Shi, R.; Jiang, X.; Wang, L.; Sun, C. Mapping coastal salt marshes in China using time series of Sentinel-1 SAR. *ISPRS J. Photogramm. Remote Sens.* **2021**, *173*, 122–134, doi:10.1016/j.isprsjprs.2021.01.003.
  38. Gašparović, M.; Dobrinić, D. Comparative assessment of machine learning methods for urban vegetation mapping using multitemporal Sentinel-1 imagery. *Remote Sens.* **2020**, *12*, doi:10.3390/rs12121952.
  39. Arias, M.; Campo-Bescós, M.Á.; Álvarez-Mozos, J. Crop classification based on temporal signatures of Sentinel-1 observations over Navarre province, Spain. *Remote Sens.* **2020**, *12*, doi:10.3390/rs12020278.
  40. Bargiel, D. A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sens. Environ.* **2017**, *198*, 369–383, doi:10.1016/j.rse.2017.06.022.
  41. Reuß, F.; Greimeister-Pfeil, I.; Vreugdenhil, M.; Wagner, W. Comparison of long short-term memory networks and random forest for sentinel-1 time series based large scale crop classification. *Remote Sens.* **2021**, *13*, 1–21, doi:10.3390/rs13245000.
  42. Ndikumana, E.; Minh, D.H.T.; Baghdadi, N.; Courault, D.; Hossard, L. Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue, France. *Remote Sens.* **2018**, *10*, 1–16, doi:10.3390/rs10081217.
  43. Xu, L.; Zhang, H.; Wang, C.; Zhang, B.; Liu, M. Crop classification based on

- temporal information using Sentinel-1 SAR time-series data. *Remote Sens.* **2019**, *11*, 1–18, doi:10.3390/rs11010053.
44. Planque, C.; Lucas, R.; Punalekar, S.; Chognard, S.; Hurford, C.; Owers, C.; Horton, C.; Guest, P.; King, S.; Williams, S.; et al. National Crop Mapping Using Sentinel-1 Time Series: A Knowledge-Based Descriptive Algorithm. *Remote Sens.* **2021**, *13*, 846, doi:10.3390/rs13050846.
  45. Nikaiein, T.; Iannini, L.; Molijn, R.A.; Lopez-Dekker, P. On the value of sentinel-1 insar coherence time-series for vegetation classification. *Remote Sens.* **2021**, *13*, 1–20, doi:10.3390/rs13163300.
  46. Zhao, H.; Chen, Z.; Jiang, H.; Jing, W.; Sun, L.; Feng, M. Evaluation of Three Deep Learning Models for Early Crop Classification Using Sentinel-1A Imagery Time Series—A Case Study in Zhanjiang, China. *Remote Sens.* **2019**, *11*, 2673, doi:10.3390/rs11222673.
  47. Crisóstomo de Castro Filho, H.; Abílio de Carvalho Júnior, O.; Ferreira de Carvalho, O.L.; Pozzobon de Bem, P.; dos Santos de Moura, R.; Olinio de Albuquerque, A.; Rosa Silva, C.; Guimarães Ferreira, P.H.; Fontes Guimarães, R.; Trancoso Gomes, R.A.; et al. Rice Crop Detection Using LSTM, Bi-LSTM, and Machine Learning Models from Sentinel-1 Time Series. *Remote Sens.* **2020**, *12*, 2655, doi:10.3390/rs12162655.
  48. Torbick, N.; Chowdhury, D.; Salas, W.; Qi, J. Monitoring Rice Agriculture across Myanmar Using Time Series Sentinel-1 Assisted by Landsat-8 and PALSAR-2. *Remote Sens.* **2017**, *9*, 119, doi:10.3390/rs9020119.
  49. Chang, L.; Chen, Y.; Wang, J.; Chang, Y. Rice-Field Mapping with Sentinel-1A SAR Time-Series Data. *Remote Sens.* **2020**, *13*, 103, doi:10.3390/rs13010103.
  50. Song, Y.; Wang, J. Mapping winter wheat planting area and monitoring its phenology using Sentinel-1 backscatter time series. *Remote Sens.* **2019**, *11*, doi:10.3390/rs11040449.
  51. Nasrallah, A.; Baghdadi, N.; El Hajj, M.; Darwish, T.; Belhouchette, H.; Faour, G.; Darwich, S.; Mhaweij, M. Sentinel-1 data for winter wheat phenology monitoring and mapping. *Remote Sens.* **2019**, *11*, doi:10.3390/rs11192228.
  52. Li, N.; Li, H.; Zhao, J.; Guo, Z.; Yang, H. Mapping winter wheat in Kaifeng, China using Sentinel-1A time-series images. *Remote Sens. Lett.* **2022**, *13*, 503–510, doi:10.1080/2150704X.2022.2046888.
  53. Orynbaikyzy, A.; Gessner, U.; Conrad, C. Crop type classification using a combination of optical and radar remote sensing data: a review. *Int. J. Remote Sens.* **2019**, *40*, 6553–6595, doi:10.1080/01431161.2019.1569791.
  54. Denize, J.; Hubert-Moy, L.; Betbeder, J.; Corgne, S.; Baudry, J.; Pottier, E. Evaluation of Using Sentinel-1 and -2 Time-Series to Identify Winter Land Use in Agricultural Landscapes. *Remote Sens.* **2018**, *11*, 37, doi:10.3390/rs11010037.
  55. Dobrinić, D.; Gašparović, M.; Medak, D. Sentinel-1 and 2 time-series for vegetation mapping using random forest classification: A case study of northern croatia. *Remote Sens.* **2021**, *13*, 1–18, doi:10.3390/rs13122321.
  56. Mercier, A.; Betbeder, J.; Rumiano, F.; Baudry, J.; Gond, V.; Blanc, L.; Bourgoin, 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, doi:10.3390/rs11080979.
  57. Arjasakusuma, S.; Kusuma, S.S.; Rafif, R.; Saringatin, S.; Wicaksono, P. Combination of Landsat 8 OLI and Sentinel-1 SAR time-series data for mapping paddy fields in parts of west and Central Java Provinces, Indonesia. *ISPRS Int. J.*

- Geo-Information* **2020**, *9*, doi:10.3390/ijgi9110663.
58. Demarez, V.; Helen, F.; Marais-Sicre, C.; Baup, F. In-season mapping of irrigated crops using Landsat 8 and Sentinel-1 time series. *Remote Sens.* **2019**, *11*, doi:10.3390/rs11020118.
  59. Wang, J.; Xiao, X.; Liu, L.; Wu, X.; Qin, Y.; Steiner, J.L.; Dong, J. Mapping sugarcane plantation dynamics in Guangxi, China, by time series Sentinel-1, Sentinel-2 and Landsat images. *Remote Sens. Environ.* **2020**, *247*, 111951, doi:10.1016/j.rse.2020.111951.
  60. Whelen, T.; Siqueira, P. Time-series classification of Sentinel-1 agricultural data over North Dakota. *Remote Sens. Lett.* **2018**, *9*, 411–420, doi:10.1080/2150704X.2018.1430393.
  61. Mestre-Quereda, A.; Lopez-Sanchez, J.M.; Vicente-Guijalba, F.; Jacob, A.W.; Engdahl, M.E. Time-Series of Sentinel-1 Interferometric Coherence and Backscatter for Crop-Type Mapping. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2020**, *13*, 4070–4084, doi:10.1109/JSTARS.2020.3008096.
  62. Amherdt, S.; Di Leo, N.C.; Balbarani, S.; Pereira, A.; Cornero, C.; Pacino, M.C. Exploiting Sentinel-1 data time-series for crop classification and harvest date detection. *Int. J. Remote Sens.* **2021**, *42*, 7313–7331, doi:10.1080/01431161.2021.1957176.
  63. Ma, L.; Liu, Y.; Zhang, X.; Ye, Y.; Yin, G.; Johnson, B.A. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS J. Photogramm. Remote Sens.* **2019**, *152*, 166–177, doi:10.1016/j.isprsjprs.2019.04.015.
  64. Zhu, X.X.; Tuia, D.; Mou, L.; Xia, G.; Zhang, L.; Xu, F.; Fraundorfer, F. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geosci. Remote Sens. Mag.* **2017**, *5*, 8–36, doi:10.1109/MGRS.2017.2762307.
  65. Wu, H.; Prasad, S. Convolutional recurrent neural networks for hyperspectral data classification. *Remote Sens.* **2017**, *9*, doi:10.3390/rs9030298.
  66. Paoletti, M.E.; Haut, J.M.; Plaza, J.; Plaza, A. Scalable recurrent neural network for hyperspectral image classification. *J. Supercomput.* **2020**, *76*, 8866–8882, doi:10.1007/s11227-020-03187-0.
  67. Ma, A.; Filippi, A.M.; Wang, Z.; Yin, Z. Hyperspectral image classification using similarity measurements-based deep recurrent neural networks. *Remote Sens.* **2019**, *11*, 1–19, doi:10.3390/rs11020194.
  68. Hochreiter, S.; Schmidhuber, J. Long Short-Term Memory. *Neural Comput.* **1997**, *9*, 1735–1780, doi:10.1162/neco.1997.9.8.1735.
  69. Cho, K.; Van Merriënboer, B.; Gulcehre, C.; Bahdanau, D.; Bougares, F.; Schwenk, H.; Bengio, Y. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.* **2014**, 1724–1734, doi:10.3115/v1/d14-1179.
  70. He, T.; Xie, C.; Liu, Q.; Guan, S.; Liu, G. Evaluation and comparison of random forest and A-LSTM networks for large-scale winter wheat identification. *Remote Sens.* **2019**, *11*, doi:10.3390/rs11141665.
  71. Reddy, D.S.; Prasad, P.R.C. Prediction of vegetation dynamics using NDVI time series data and LSTM. *Model. Earth Syst. Environ.* **2018**, *4*, 409–419, doi:10.1007/s40808-018-0431-3.
  72. Rußwurm, M.; Körner, M. Multi-temporal land cover classification with sequential recurrent encoders. *ISPRS Int. J. Geo-Information* **2018**, *7*, doi:10.3390/ijgi7040129.

73. Sun, Z.; Di, L.; Fang, H. Using long short-term memory recurrent neural network in land cover classification on Landsat and Cropland data layer time series. *Int. J. Remote Sens.* **2019**, *40*, 593–614, doi:10.1080/01431161.2018.1516313.
74. Zhong, L.; Hu, L.; Zhou, H. Deep learning based multi-temporal crop classification. *Remote Sens. Environ.* **2019**, *221*, 430–443, doi:10.1016/j.rse.2018.11.032.
75. Ienco, D.; Gaetano, R.; Dupaquier, C.; Maurel, P. Land Cover Classification via Multitemporal Spatial Data by Deep Recurrent Neural Networks. *IEEE Geosci. Remote Sens. Lett.* **2017**, *14*, 1685–1689, doi:10.1109/LGRS.2017.2728698.
76. Minh, D.H.T.; Ienco, D.; Gaetano, R.; Lalande, N.; Ndikumana, E.; Osman, F.; Maurel, P. Deep Recurrent Neural Networks for mapping winter vegetation quality coverage via multi-temporal SAR Sentinel-1. *arXiv* **2017**, *15*, 464–468.
77. Dubreuil, V.; Fante, K.P.; Planchon, O.; Neto, J.L.S. Os tipos de climas anuais no Brasil : uma aplicação da classificação de Köppen de 1961 a 2015. *Confins* **2018**, doi:10.4000/confins.15738.
78. Cohen, M.C.L.; Lara, R.J.; Smith, C.B.; Angélica, R.S.; Dias, B.S.; Pequeno, T. Wetland dynamics of Marajó Island, northern Brazil, during the last 1000 years. *CATENA* **2008**, *76*, 70–77, doi:10.1016/j.catena.2008.09.009.
79. Diniz, C.; Cortinhas, L.; Nerino, G.; Rodrigues, J.; Sadeck, L.; Adami, M.; Souza-Filho, P.W.M. Brazilian Mangrove Status: Three Decades of Satellite Data Analysis. *Remote Sens.* **2019**, *11*, 808, doi:10.3390/rs11070808.
80. Rabelo, B.V.; Pinto, A. do C.; Simas, A.P. do S.C.; Tardin, A.T.; Fernandes, A.V.; Souza, C.B. de; Monteiro, E.M.P.B.; Facundes, F. da S.; Ávila, J.E. de S.; Souza, J.S.A. de; et al. *Macrodiagnóstico do Estado do Amapá: primeira aproximação do ZEE*; Instituto de Pesquisas Científicas e Tecnológicas do Estado do Amapá (IPEA): Macapá, 2008; Vol. 1;.
81. De Menezes, M.P.M.; Berger, U.; Mehlig, U. Mangrove vegetation in Amazonia: A review of studies from the coast of Pará and Maranhão States, north Brazil. *Acta Amaz.* **2008**, *38*, 403–419, doi:10.1590/S0044-59672008000300004.
82. De Almeida, P.M.M.; Madureira Cruz, C.B.; Amaral, F.G.; Almeida Furtado, L.F.; Dos Santos Duarte, G.; Da Silva, G.F.; Silva De Barros, R.; Pereira Abrantes Marques, J.V.F.; Cupertino Bastos, R.M.; Dos Santos Rosario, E.; et al. Mangrove Typology: A Proposal for Mapping based on High Spatial Resolution Orbital Remote Sensing. *J. Coast. Res.* **2020**, *95*, 1–5, doi:10.2112/SI95-001.1.
83. Cohen, M.C.L.; Pessenda, L.C.R.; Behling, H.; de Fátima Rossetti, D.; França, M.C.; Guimarães, J.T.F.; Friaes, Y.; Smith, C.B. Holocene palaeoenvironmental history of the Amazonian mangrove belt. *Quat. Sci. Rev.* **2012**, *55*, 50–58, doi:10.1016/j.quascirev.2012.08.019.
84. Guimarães, J.T.F.; Cohen, M.C.L.; França, M.C.; Lara, R.J.; Behling, H. Model of wetland development of the Amapá coast during the late Holocene. *An. Acad. Bras. Cienc.* **2010**, *82*, 451–465, doi:10.1590/S0001-37652010000200021.
85. Santana, L. de O. Uso de sensoriamento remoto para identificação e mapeamento do paleodelta do Macarry, Amapá, Federal University of Pará, 2011.
86. Silveira, O.F.M. da A planície costeira do Amapá: dinâmica de ambiente costeiro influenciado por grandes fontes fluviais quaternárias, Federal University of Pará, 1998.
87. Jardim, K.A.; Santos, V.F. dos; de Oliveira, U.R. Paleodrainage Systems and Connections to the Southern Lacustrine Belt applying Remote Sensing Data, Amazon Coast, Brazil. *J. Coast. Res.* **2018**, *85*, 671–675, doi:10.2112/SI85-135.1.

88. da Costa Neto, S.V. Fitofisionomia e florística de savanas do Amapá, Federal Rural University of the Amazon, 2014.
89. Hilário, R.R.; de Toledo, J.J.; Mustin, K.; Castro, I.J.; Costa-Neto, S. V.; Kauano, É.E.; Eilers, V.; Vasconcelos, I.M.; Mendes-Junior, R.N.; Funi, C.; et al. The Fate of an Amazonian Savanna: Government Land-Use Planning Endangers Sustainable Development in Amapá, the Most Protected Brazilian State. *Trop. Conserv. Sci.* **2017**, *10*, doi:10.1177/1940082917735416.
90. Azevedo, L.G. Tipos eco-fisionômicos de vegetação do Território Federal do Amapá. *Rev. Bras. Geogr.* **1967**, *2*, 25–51.
91. Veloso, H.P.; L.R.R.Filho, A.; Lima, J.C.A. *Classificação da Vegetação Brasileira, Adaptada a um Sistema Universal*; IBGE - Departamento de Recursos Naturais e Estudos Ambientais: Rio de Janeiro, 1991; ISBN 8524003847.
92. Brasil. Departamento Nacional da Produção Mineral. Projeto RADAM. *Folha NA/NB.22-Macapá; geologia, geomorfologia, solos, vegetação e uso potencial da terra*; Departamento Nacional da Produção Mineral: Rio de Janeiro, 1974;
93. Aguiar, A.; Barbosa, R.I.; Barbosa, J.B.F.; Mourão, M. Invasion of *Acacia mangium* in Amazonian savannas following planting for forestry. *Plant Ecol. Divers.* **2014**, *7*, 359–369, doi:10.1080/17550874.2013.771714.
94. Rauber, A.L. A dinâmica da paisagem no estado do Amapá: análise socioambiental para o eixo de influência das rodovias BR-156 e BR-210, Goiás Federal University, 2019.
95. Mustin, K.; Carvalho, W.D.; Hilário, R.R.; Costa-Neto, S. V.; Silva, C.R.; Vasconcelos, I.M.; Castro, I.J.; Eilers, V.; Kauano, É.E.; Mendes, R.N.G.; et al. Biodiversity, threats and conservation challenges in the Cerrado of Amapá, an Amazonian savanna. *Nat. Conserv.* **2017**, *22*, 107–127, doi:10.3897/natureconservation.22.13823.
96. Torres, R.; Snoeij, P.; Geudtner, D.; Bibby, D.; Davidson, M.; Attema, E.; Potin, P.; Rommen, B.Ö.; Floury, N.; Brown, M.; et al. GMES Sentinel-1 mission. *Remote Sens. Environ.* **2012**, *120*, 9–24, doi:10.1016/j.rse.2011.05.028.
97. Hüttich, C.; Gessner, U.; Herold, M.; Strohbach, B.J.; Schmidt, M.; Keil, M.; Dech, S. On the suitability of MODIS time series metrics to map vegetation types in dry savanna ecosystems: A case study in the Kalahari of NE Namibia. *Remote Sens.* **2009**, *1*, 620–643, doi:10.3390/rs1040620.
98. Filippini, F. Sentinel-1 GRD Preprocessing Workflow. *Proceedings* **2019**, *18*, 11, doi:10.3390/ecrs-3-06201.
99. Savitzky, A.; Golay, M.J.E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Anal. Chem.* **1964**, *36*, 1627–1639, doi:10.1021/ac60214a047.
100. Chen, J.; Jönsson, P.; Tamura, M.; Gu, Z.; Matsushita, B.; Eklundh, L. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky-Golay filter. *Remote Sens. Environ.* **2004**, *91*, 332–344, doi:10.1016/j.rse.2004.03.014.
101. Singh, R.; Sinha, V.; Joshi, P.; Kumar, M. Use of Savitzky - Golay Filters to Minimize Multi-temporal Data Anomaly in Land use Land cover mapping. *Indian J. For.* **2019**, *42*, 362–368, doi:10.54207/bsmps1000-2019-650st3.
102. Soudani, K.; Delpierre, N.; Berveiller, D.; Hmimina, G.; Vincent, G.; Morfin, A.; Dufrêne, É. Potential of C-band Synthetic Aperture Radar Sentinel-1 time-series for the monitoring of phenological cycles in a deciduous forest. *Int. J. Appl. Earth Obs. Geoinf.* **2021**, *104*, doi:10.1016/j.jag.2021.102505.
103. Pang, J.; Zhang, R.; Yu, B.; Liao, M.; Lv, J.; Xie, L.; Li, S.; Zhan, J. Pixel-level



- rice planting information monitoring in Fujin City based on time-series SAR imagery. *Int. J. Appl. Earth Obs. Geoinf.* **2021**, *104*, 102551, doi:10.1016/j.jag.2021.102551.
104. Abade, N.A.; Júnior, O.; Guimarães, R.F.; de Oliveira, S.N.; De Carvalho, O.A.; Guimarães, R.F.; de Oliveira, S.N. Comparative Analysis of MODIS Time-Series Classification Using Support Vector Machines and Methods Based upon Distance and Similarity Measures in the Brazilian Cerrado-Caatinga Boundary. *Remote Sens.* **2015**, *7*, 12160–12191, doi:10.3390/rs70912160.
  105. Ren, J.; Chen, Z.; Zhou, Q.; Tang, H. Regional yield estimation for winter wheat with MODIS-NDVI data in Shandong, China. *Int. J. Appl. Earth Obs. Geoinf.* **2008**, *10*, 403–413, doi:10.1016/j.jag.2007.11.003.
  106. Geng, L.; Ma, M.; Wang, X.; Yu, W.; Jia, S.; Wang, H. Comparison of Eight Techniques for Reconstructing Multi-Satellite Sensor Time-Series NDVI Data Sets in the Heihe River Basin, China. *Remote Sens.* **2014**, *6*, 2024–2049, doi:10.3390/rs6032024.
  107. Foody, G.M. Status of land cover classification accuracy assessment. *Remote Sens. Environ.* **2002**, *80*, 185–201, doi:10.1016/S0034-4257(01)00295-4.
  108. Estabrooks, A.; Jo, T.; Japkowicz, N. A multiple resampling method for learning from imbalanced data sets. *Comput. Intell.* **2004**, *20*, 18–36, doi:10.1111/j.0824-7935.2004.t01-1-00228.x.
  109. Zaremba, W.; Sutskever, I.; Vinyals, O. Recurrent Neural Network Regularization. *arXiv* **2014**, arXiv:1409.2329.
  110. Gao, L.; Guo, Z.; Zhang, H.; Xu, X.; Shen, H.T. Video Captioning with Attention-Based LSTM and Semantic Consistency. *IEEE Trans. Multimed.* **2017**, *19*, 2045–2055, doi:10.1109/TMM.2017.2729019.
  111. Deng, J.; Schuller, B.; Eyben, F.; Schuller, D.; Zhang, Z.; Francois, H.; Oh, E. Exploiting time-frequency patterns with LSTM-RNNs for low-bitrate audio restoration. *Neural Comput. Appl.* **2020**, *32*, 1095–1107, doi:10.1007/s00521-019-04158-0.
  112. Greff, K.; Srivastava, R.K.; Koutnik, J.; Steunebrink, B.R.; Schmidhuber, J. LSTM: A Search Space Odyssey. *IEEE Trans. Neural Networks Learn. Syst.* **2017**, *28*, 2222–2232, doi:10.1109/TNNLS.2016.2582924.
  113. Graves, A.; Schmidhuber, J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks* **2005**, *18*, 602–610, doi:10.1016/j.neunet.2005.06.042.
  114. Ma, X.; Hovy, E. End-to-end Sequence Labeling via Bi-directional LSTM-CNNs-CRF. In Proceedings of the Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers); Association for Computational Linguistics: Stroudsburg, PA, USA, 2016; Vol. 2, pp. 1064–1074.
  115. Siam, M.; Valipour, S.; Jagersand, M.; Ray, N. Convolutional gated recurrent networks for video segmentation. *Proc. - Int. Conf. Image Process. ICIP* **2018**, *2017-Sept*, 3090–3094, doi:10.1109/ICIP.2017.8296851.
  116. Breiman, L. Random Forests. *Mach. Learn.* **2001**, *45*, 5–32, doi:10.1023/A:1010933404324.
  117. Friedman, J.H. Greedy function approximation: A gradient boosting machine. *Ann. Stat.* **2001**, *29*, 1189–1232, doi:10.1214/aos/1013203451.
  118. Meng, Q.; Cieszewski, C.J.; Madden, M.; Borders, B.E. K Nearest Neighbor Method for Forest Inventory Using Remote Sensing Data. *GIScience Remote Sens.* **2007**, *44*, 149–165, doi:10.2747/1548-1603.44.2.149.

119. Fukunaga, K. *Introduction to Statistical Pattern Recognition*; Elsevier, 1990; ISBN 9780080478654.
120. Vapnik, V. *The nature of statistical learning theory*; Springer: New York, 1995; Vol. 148; ISBN 9781475724424.
121. Bishop, C.M. *Neural networks for pattern recognition*; 2nd ed.; Springer, 2011; ISBN 0387310738.
122. Anusha, N.; Bharathi, B. Flood detection and flood mapping using multi-temporal synthetic aperture radar and optical data. *Egypt. J. Remote Sens. Sp. Sci.* **2020**, *23*, 207–219, doi:10.1016/j.ejrs.2019.01.001.
123. Kasischke, E.S.; Smith, K.B.; Bourgeau-Chavez, L.L.; Romanowicz, E.A.; Brunzell, S.; Richardson, C.J. Effects of seasonal hydrologic patterns in south Florida wetlands on radar backscatter measured from ERS-2 SAR imagery. *Remote Sens. Environ.* **2003**, *88*, 423–441, doi:10.1016/j.rse.2003.08.016.
124. Kasischke, E.S.; Bourgeau-Chavez, L.L.; Rober, A.R.; Wyatt, K.H.; Waddington, J.M.; Turetsky, M.R. Effects of soil moisture and water depth on ERS SAR backscatter measurements from an Alaskan wetland complex. *Remote Sens. Environ.* **2009**, *113*, 1868–1873, doi:10.1016/j.rse.2009.04.006.
125. Lang, M.W.; Kasischke, E.S. Using C-Band Synthetic Aperture Radar Data to Monitor Forested Wetland Hydrology in Maryland's Coastal Plain, USA. *IEEE Trans. Geosci. Remote Sens.* **2008**, *46*, 535–546, doi:10.1109/TGRS.2007.909950.
126. Liao, H.; Wdowinski, S.; Li, S. Regional-scale hydrological monitoring of wetlands with Sentinel-1 InSAR observations: Case study of the South Florida Everglades. *Remote Sens. Environ.* **2020**, *251*, 112051, doi:10.1016/j.rse.2020.112051.
127. Sang-Hoon Hong; Wdowinski, S.; Sang-Wan Kim Evaluation of TerraSAR-X Observations for Wetland InSAR Application. *IEEE Trans. Geosci. Remote Sens.* **2010**, *48*, 864–873, doi:10.1109/TGRS.2009.2026895.
128. Brisco, B. Early Applications of Remote Sensing for Mapping Wetlands. In *Remote Sensing of Wetlands*; Tiner, R.W., Lang, M.W., Klemas, V. V., Eds.; CRC Press, 2015; pp. 86–97.
129. Zhang, B.; Wdowinski, S.; Oliver-Cabrera, T.; Koirala, R.; Jo, M.J.; Osmanoglu, B. Mapping the extent and magnitude of severe flooding induced by hurricane irma with multi-temporal Sentinel-1 SAR and INSAR observations. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2018**, *XLII-3*, 2237–2244, doi:10.5194/isprs-archives-XLII-3-2237-2018.
130. Lasko, K.; Vadrevu, K.P.; Tran, V.T.; Justice, C. Mapping Double and Single Crop Paddy Rice with Sentinel-1A at Varying Spatial Scales and Polarizations in Hanoi, Vietnam. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2018**, *11*, 498–512, doi:10.1109/JSTARS.2017.2784784.
131. Bem, P.P. de; de Carvalho Júnior, O.A.; Carvalho, O.L.F. de; Gomes, R.A.T.; Guimarães, R.F.; Pimentel, C.M.M.M. Irrigated rice crop identification in Southern Brazil using convolutional neural networks and Sentinel-1 time series. *Remote Sens. Appl. Soc. Environ.* **2021**, *24*, doi:10.1016/j.rsase.2021.100627.