



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21d/2024/01.23.16.50-TDI

**AVALIAÇÃO DE MÉTODOS DE LIMIAZIZAÇÃO DE  
IMAGENS SENTINEL-1 PARA O MAPEAMENTO DE  
SUPERFÍCIES DE ÁGUAS ABERTAS DE LAGOS DE  
VÁRZEA DO BAIXO RIO AMAZONAS**

Fellipe Lousada Pegolo

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Evlyn Márcia Leão de  
Moraes Novo, e Daniel Andrade  
Maciel, aprovada em 15 de  
dezembro de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4AK8DNE>>

INPE  
São José dos Campos  
2023

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE  
Coordenação de Ensino, Pesquisa e Extensão (COEPE)  
Divisão de Biblioteca (DIBIB)  
CEP 12.227-010  
São José dos Campos - SP - Brasil  
Tel.:(012) 3208-6923/7348  
E-mail: pubtc@inpe.br

**CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):**

**Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

**Membros:**

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)  
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)  
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)  
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon  
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)  
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

**EDITORAÇÃO ELETRÔNICA:**

Ivone Martins - Divisão de Biblioteca (DIBIB)  
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21d/2024/01.23.16.50-TDI

**AVALIAÇÃO DE MÉTODOS DE LIMIARIZAÇÃO DE  
IMAGENS SENTINEL-1 PARA O MAPEAMENTO DE  
SUPERFÍCIES DE ÁGUAS ABERTAS DE LAGOS DE  
VÁRZEA DO BAIXO RIO AMAZONAS**

Fellipe Lousada Pegolo

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Sensoriamento Remoto, orientada  
pelos Drs. Evlyn Márcia Leão de  
Moraes Novo, e Daniel Andrade  
Maciel, aprovada em 15 de  
dezembro de 2023.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/4AK8DNE>>

INPE  
São José dos Campos  
2023

Dados Internacionais de Catalogação na Publicação (CIP)

---

Pegolo, Fellipe Lousada.

P349a Avaliação de métodos de limiarização de imagens Sentinel-1 para o mapeamento de superfícies de águas abertas de lagos de várzea do baixo Rio Amazonas / Fellipe Lousada Pegolo. – São José dos Campos : INPE, 2023.

xxii + 85 p. ; (sid.inpe.br/mtc-m21d/2024/01.23.16.50-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2023.

Orientadores : Drs. Evlyn Márcia Leão de Moraes Novo, e Daniel Andrade Maciel.

1. Sentinel-1. 2. Amazônia. 3. Águas abertas. I.Título.

CDU 528.8(282.281.3)

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



MINISTÉRIO DA  
CIÊNCIA, TECNOLOGIA  
E INOVAÇÃO



**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**  
Serviço de Pós-Graduação - SEPGR

**DEFESA FINAL DE DISSERTAÇÃO DE FELIPE LOUSADA PEGOLO**  
**REG. 757889/2021, BANCA Nº 310/2023**

No dia 15 de dezembro de 2023, via teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Mestre em Sensoriamento Remoto, com a exigência de que o trabalho final a ser publicado deverá incorporar as correções sugeridas pela Banca Examinadora, com revisão pelo(s) orientador(es).

**Título:** “Avaliação de métodos de limiarização de imagens Sentinel-1 para o mapeamento de superfícies de águas abertas de lagos de várzea do Baixo Rio Amazonas”

**Observações da banca:** A banca informa que se as sugestões e correções não forem incorporadas no texto ele não deve ser encaminhado para publicação.

**Membros da banca:**

Dr. Cláudio Clemente Faria Barbosa – Presidente – INPE

Dra. Evlyn Márcia Leão de Moraes Novo – Orientadora – INPE

Dr. Daniel Andrade Maciel – Orientador – INPE

Dr. Jose Claudio Mura – Membro Interno – INPE

Dra. Alice César Fassoni de Andrade – Membro Externo – Universidade de Brasília (UnB)



Documento assinado eletronicamente por **Alice César Fassoni de Andrade (E), Usuário Externo**, em 25/04/2024, às 09:05 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Evlyn Marcia Leão de Moraes Novo, Pesquisador**, em 25/04/2024, às 13:37 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **José Cláudio Mura, Tecnologista**, em 02/05/2024, às 10:46 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **DANIEL ANDRADE MACIEL (E), Usuário Externo**, em 02/05/2024, às 11:19 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Cláudio Clemente Faria Barbosa, Tecnologista**, em 03/05/2024, às 09:53 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no site <https://sei.mcti.gov.br/verifica.html>, informando o código verificador **11907321** e o código CRC **DA2A8BBA**.

---

Referência: Processo nº 01340.010510/2023-00

SEI nº 11907321

*“A tecnologia é absolutamente fundamental para gerenciar nosso planeta, mas ainda mais importante é o entendimento e a sabedoria para aplicá-la”.*

*Greg Asner*





## **AGRADECIMENTOS**

Agradeço imensamente aos meus orientadores, Dra. Evlyn Novo e Dr. Daniel Maciel, assim como aos estimados professores, Drs. Thales Körting e José Claudio Mura, e ao INPE. Também expresso minha gratidão ao corpo docente da PGSER pela confiança, encorajamento, discussões construtivas e apoio incansável durante esta jornada. E um agradecimento especial à CAPES pelo período de bolsa que possibilitou esta trajetória.



## RESUMO

O conhecimento sobre a variabilidade espacial e temporal de águas abertas (AA), ou seja, aquelas sem a presença de vegetação, é crucial para diversos campos de pesquisa, como a hidrologia, a biogeoquímica, a geomorfologia, a ecologia, entre outros. No entanto, adquirir esses dados de AA é um desafio em vastas regiões, especialmente na Amazônia brasileira. Desde 1980, os dados de sensoriamento remoto orbital vêm sendo explorados como alternativa, apesar das limitações relativas à cobertura de nuvem constante que impacta os dados ópticos em missões devido à baixa frequência de aquisição e à baixa resolução espacial dos dados passivos de micro-ondas, então disponíveis. As poucas missões SAR, com livre acesso aos dados e alta frequência de aquisição, também dificultaram a obtenção de séries temporais AA até o lançamento dos satélites Sentinel-1A e 1B (S1) em 2014 e 2016, respectivamente. Portanto, este estudo tem como objetivo avaliar o potencial de diferentes métodos de limiarização (Empírico: supervisionado e Otsu: não supervisionado) de imagens polarimétricas SAR S1 (VV e VH) para gerar séries temporais com uma frequência de 12 dias (órbita descendente) das AA do Lago Grande de Curuai (LGC), situado no Baixo Rio Amazonas, Estado do Pará. Utilizando a plataforma Google Earth Engine (GEE) e dados SAR S1 disponíveis em seu catálogo, foram criadas máscaras de AA a partir dos métodos analisados. Essas máscaras foram validadas estatisticamente com métricas como acurácia global (AG), sensibilidade (S) e especificidade (E), e comparadas com imagens Sentinel-2 quase simultâneas. Além disso, foram analisados fatores que podem afetar a precisão dessas máscaras (nível de água, precipitação, cobertura de nuvens e eventos ENSO) para auxiliar na determinação do método mais adequado para extrair séries temporais VV e VH de AA (STAAVV e STAAVH). Os métodos Empíricos de limiarização para as polarizações VV e VH se destacaram em termos de métricas de acurácia e avaliações visuais quando comparados ao método Otsu. Embora o método Empírico com limiar de -17 dB para VV tenha apresentado maior acurácia (OA, S e E), verificou-se que em algumas condições, as máscaras geradas por esse método e polarização apresentaram lacunas (áreas que não são águas abertas (NAA)), devido principalmente à influência de nuvens carregadas, células de chuva e águas agitadas, causadas por forças hidráulicas e eólicas que afetam a velocidade e direção dos fluxos entre o Rio Amazonas e o LGC. As lacunas das máscaras de água ocasionaram em uma STAAVV ruidosa. Em contrapartida o método Empírico com limiar de -23 dB para VH por ser menos sensível a esses fatores resultou na STAAVH mais estável e coerente com os eventos climáticos de estiagens relacionadas ao El Niño e de inundações associadas ao La Niña.

Palavras-chave: Sentinel-1. Amazônia. Águas abertas.



# **ASSESSMENT OF SENTINEL-1 IMAGE THRESHOLDING METHODS FOR MAPPING OPEN WATER IN FLOODED LAKES OF THE LOWER AMAZON RIVER**

## **ABSTRACT**

The knowledge about the spatial and temporal variability of open waters, i.e., those without the presence of vegetation, is crucial for various research fields such as hydrology, biogeochemistry, geomorphology, ecology, among others. However, acquiring open waters data is challenging in vast regions, especially in the Brazilian Amazon. Since the 1980s, orbital remote sensing data have been explored as an alternative, despite limitations regarding constant cloud cover impacting optical data in missions due to low acquisition frequency and low spatial resolution of passive microwave data then available. The few SAR missions, with free access to data and high acquisition frequency, also hindered obtaining open waters time series until the launch of Sentinel-1A and 1B (S1) satellites in 2014 and 2016, respectively. Therefore, this study aims to evaluate the potential of different thresholding methods (Empirical: supervised and Otsu: unsupervised) of S1 SAR polarimetric images (VV and VH) to generate time series with a frequency of 12 days (descending orbit) of open waters of Lake Grande de Curuai (LGC), located in the Lower Amazon River, State of Pará. Using the Google Earth Engine (GEE) platform and S1 SAR data available in its catalog, open waters masks were created from the analyzed methods. These masks were statistically validated with metrics such as overall accuracy, sensitivity, and specificity, and compared with quasi-simultaneous Sentinel-2 images. Furthermore, factors that may affect the accuracy of these masks (water level, precipitation, cloud cover, and ENSO events) were analyzed to assist in determining the most suitable method for extracting VV and VH OW time series (STAAVV and STAAVH). Empirical thresholding methods for VV and VH polarizations stood out in terms of accuracy metrics and visual evaluations when compared to the Otsu method. Although the Empirical method with a threshold of -17 dB for VV presented higher accuracy, it was found that under some conditions, masks generated by this method and polarization showed gaps (areas that are not open waters), mainly due to the influence of heavy clouds, rain cells, and agitated waters caused by hydraulic and wind forces affecting the speed and direction of flow between the Amazon River and LGC. The gaps in water masks resulted in noisy STAAVV. In contrast, the Empirical method with a threshold of -23 dB for VH, being less sensitive to these factors, resulted in a more stable and coherent STAAVH with drought-related climatic events associated with El Niño and flooding associated with La Niña.

Keywords: Sentinel-1. Amazon. Open water.



## LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Variação do nível de água na estação de Curuai (1982-2016). ....	7
Figura 2.2 – Representações físicas do retroespalhamento. ....	11
Figura 2.3 – Ilustração do potencial de penetração das micro-ondas nas bandas X, C e L em estruturas vegetais. ....	12
Figura 2.4 – Representação dos diferentes tipos de reflexão entre as micro-ondas (banda C) e os alvos.....	13
Figura 2.5 – Ilustração da limiarização de histograma de frequência de pixels para diferentes valores de $\sigma^{\circ}$ . ....	18
Figura 2.6 – Interação entre mico-ondas nas bandas X e C e nuvens carregadas e células de chuva.....	26
Figura 3.1 – Área de estudo: região do Lago Grande de Curuai.....	29
Figura 3.2 – Fluxograma metodológico utilizado. ....	32
Figura 3.3 – Ilustração do método Empírico.....	33
Figura 3.4 – Ilustração do método Otsu 2022. ....	34
Figura 3.5 – Ilustração do método Otsu 2017 - 2022. ....	35
Figura 3.6 – Exemplo de distribuição mensal das amostras mensais na área do LGC.....	36
Figura 3.7 – Área utilizada na geração das séries temporais de águas abertas. . .....	37
Figura 3.8 – Regressão exponencial entre os níveis de água médios mensais das estações de Óbidos e da Vila de Curuai de 1982 a 2016.....	40
Figura 4.1 – Limiares (Empíricos e Otsu's) e níveis de água em Óbidos e Curuai. .....	41
Figura 4.2 – Acurácia global mensal dos métodos empregados.....	47
Figura 4.3 – Sensibilidade mensal dos métodos empregados. ....	49
Figura 4.4 – Especificidade mensal dos métodos empregados. ....	50
Figura 4.5 – Imagens de solos expostos classificados incorretamente.....	52
Figura 4.6 – Imagens de águas agitadas classificadas incorretamente .....	53
Figura 4.7 – Precipitação média acumulada mensal e anual. ....	54

Figura 4.8 – Níveis de água estimados em Curuai.....	56
Figura 4.9 – Séries temporais VV e VH entre 2017 e 2022.....	57
Figura 4.10 – Máscaras de água afetadas por nuvens carregadas e células de chuva.....	59
Figura 4.11 – Relação entre as extensões de águas abertas e os eventos ENSO. .....	60
Figura 4.12 – Séries temporais de superfícies de águas abertas de 2022.....	61
Figura 4.13 – Regressão entre os níveis de água estimados em Curuai e as séries temporais de águas abertas de polarização VV. ....	64
Figura 4.14 – Regressão entre os níveis de água estimados em Curuai e as séries temporais de águas abertas de polarização VH. ....	64
Figura 4.15 – Análise da relação entre os dados de cobertura de nuvens e séries temporais de águas abertas.....	65
Figura 4.16 – Análise da relação entre os dados de precipitação diária e séries temporais de águas abertas.....	68



## LISTA DE TABELAS

	<b><u>Pág.</u></b>
Tabela 2.1 – Trabalhos com dados SAR nas bandas C e L na área de hidrologia. .....	23
Tabela 3.1 – Imagens S1 (VV e VH) e S2 de 2022 utilizadas. ....	32
Tabela 3.2 – Imagens S1 (VV e VH) utilizadas nos métodos de limiarização. .	33
Tabela 3.3 – Dados auxiliares utilizados. ....	38
Tabela 3.4 – Intensidade ENSO: Índice Niño Oceânico (ONI). ....	40



## LISTA DE SIGLAS E ABREVIATURAS

AA	Águas abertas
AG	Acurácia global
AI	Artificial Intelligence (Inteligência Artificial)
ASF	Alaska Satellite Facility
CONAE	Comissão Nacional de Atividades Espaciais - Argentina
DL	Deep Learning (Aprendizado profundo)
DT	Decision Trees (Árvores de Decisão)
E	Especificidade
ENSO	Oscilação Sul do El Niño
ESA	European Space Agency (Agência Espacial Europeia)
GEE	Google Earth Engine
Hrms	Erro médio quadrático da altura da superfície
IW	Interferometric Wide (Faixa Ampla Interferométrica)
JAXA	Agência Japonesa de Exploração Aeroespacial
LGC	Lago Grande de Curuai
ML	Machine Learning (Aprendizado de máquina)
MNDWI	Modified Normalized Difference Water Index
NAA	Áreas que não são águas abertas
NDWI	Normalized Difference Water Index
NN	Neural Networks (Redes Neurais)
ONI	Índice Niño Oceânico
RF	Random Forests (Florestas Aleatórias)
S	Sensibilidade
SAR	Synthetic Aperture Radar (Radar de Abertura Sintética)
SLC	Single Look Complex
STAA	Séries temporais de águas abertas
STAAVH	Séries temporais de águas abertas na polarização VH
STAAVV	Séries temporais de águas abertas na polarização VV
S1	Sentinel-1
S1A	Sentinel-1A

S1B Sentinel-1B  
S1C Sentinel-1C  
S2 Sentinel-2  
TOPSAR Terrain Observation with Progressive Scans SAR

## LISTA DE SÍMBOLOS

$\theta$	Ângulo de incidência
$A_{\psi h}$	Área da célula de resolução no plano horizontal
$A_{\psi p}$	Área da célula de resolução no plano perpendicular
$A_{\psi o}$	Área da célula de resolução no plano oblíquo
$\sigma^\circ$	Coefficiente de retroespalhamento - Sigma Zero
$\beta^\circ$	Coefficiente de retroespalhamento - Beta Zero
$\gamma^\circ$	Coefficiente de retroespalhamento - Gamma Zero
$\lambda$	Comprimentos de onda
$\psi$	Retroespalhamento
$\delta^2_B$	Variância



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO .....</b>	<b>1</b>
1.1 Objetivo.....	6
1.2 Objetivos específicos .....	6
<b>2 FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>7</b>
2.1 Variação hidrológica do Baixo Rio Amazonas .....	7
2.1.1 Medidas de retroespalhamento de radar.....	9
2.1.2 Microtopografia e constante dielétrica.....	11
2.1.3 Polarização da onda eletromagnética .....	14
2.2 Águas abertas amazônicas sob a perspectiva SAR .....	14
2.3 Aplicação de imagens SAR na classificação de águas abertas.....	15
2.4 Fatores atmosféricos, meteorológicos, hidrológicos e climáticos .....	25
<b>3 METODOLOGIA.....</b>	<b>29</b>
3.1 Área de estudo .....	29
3.2 Dados de sensoriamento remoto Sentinel-1 e Sentinel-2.....	29
3.2.1 Dados SAR Sentinel-1.....	29
3.2.2 Dados ópticos Sentinel-2.....	30
3.3 Classificação dos dados SAR.....	31
3.3.1 Limiarização e extração de máscaras de água .....	31
3.3.2 Seleção das amostras de validação .....	35
3.3.3 Validação e avaliação visual das máscaras de água .....	36
3.3.4 Geração das séries temporais de águas abertas .....	37
3.4 Dados auxiliares .....	37
3.4.1 Dados de precipitação.....	38
3.4.2 Dados de cobertura de nuvens .....	38
3.4.3 Dados de nível de água.....	39
3.4.4 Dados climáticos ENSO .....	40
<b>4 RESULTADOS E DISCUSSÕES .....</b>	<b>41</b>
4.1 Limiarização.....	41
4.2 Acurácia das máscaras de água.....	47

4.3 Avaliação visual das máscaras de água .....	51
4.4 Precipitação média acumulada mensal e anual.....	54
4.5 Nível de água estimado para Curuai .....	55
4.6 Séries temporais de águas abertas .....	56
4.7 Análise do impacto dos fatores atmosféricos, meteorológicos e hidrológicos na acurácia das águas abertas .....	57
4.8 Relação entre as águas abertas e os dados climáticos .....	60
4.9 Águas abertas de 2022.....	61
4.10 Relações entre os níveis de água estimados em Curuai e as séries temporais de águas abertas.....	63
4.11 Relações entre séries temporais de águas abertas (VV e VH) e cobertura de nuvens.....	65
4.12 Relações entre séries temporais de águas abertas (VV e VH) e as taxas de precipitação diárias .....	67
<b>5 CONCLUSÃO.....</b>	<b>69</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>73</b>



## 1 INTRODUÇÃO

Mapear com precisão águas abertas (AA), ou seja, superfícies de águas sem a presença de vegetação aquática e terrestre (HESS et al., 1995) em sistemas hidrológicos extensos e sujeitos a significativa variação sazonal como os da Bacia do Rio Amazonas é uma tarefa de campo desafiadora e dispendiosa que demandaria a implantação e manutenção de vários equipamentos, incluindo pluviômetros, eco sondas, equipes multidisciplinares e um extenso trabalho de modelagem (BOURGOIN et al., 2007; RUDORFF et al., 2014; MUSA et al., 2015; CONSTANTINE et al., 2014; FLEISCHMANN et al., 2022). Parte deste desafio também se relaciona à forte influência hidrológica dos tributários do Rio Amazonas sobre a sazonalidade do pulso de inundação, que tem um impacto significativo na biodiversidade (CREMA et al., 2015; LOPES et al., 2016), na geomorfologia (ROSSETTI et al., 2017), na biogeoquímica (AMORIM et al., 2009; MITSUYA, 2014; BOMFIM, 2017), resultando em alterações paisagísticas notáveis, sobretudo, nas planícies de inundação da região do Baixo Amazonas (BARBOSA, 2005; RUDORFF et al., 2014). Nesse contexto, compreender a variabilidade das AA é útil para: i) estimar parâmetros como nível, volume e fluxo de água (ALSDORF et al., 2010; ARNESEN et al., 2013; CLEMENT 2020; FASSONI-ANDRADE et al., 2021); ii) calcular o balanço hídrico, especialmente considerando o alto potencial de evaporação das AA (TOMASELLA et al., 2008; GETIRANA et al., 2017; BAKER et al., 2021; FLEISCHMANN et al., 2022; BARBEDO et al., 2022; FISHER et al., 2023); calcular os fluxos de carbono (RICHEY et al., 2002; ENGLE et al., 2008; SILVA et al., 2010; SILVA et al., 2013), de metano (MELACK et al., 2023; BASSO et al., 2021) e de sedimentos (BOURGOIN et al., 2007).

A ampliação do conhecimento hidrológico sobre a dinâmica espacial e temporal das planícies de inundação amazônicas por meio de séries temporais de águas abertas (STAA), torna-se urgente devido às crescentes pressões antrópicas (FLEISCHMANN et al., 2022), especialmente aquelas relacionadas ao desmatamento (TERRABRASILIS, 2023), aos incêndios florestais (SILVEIRA et al., 2022), às atividades de mineração (MATAVELI et al., 2022; LOBO et al.,

2018), à construção de barragens (FINER; JENKINS, 2012; TUNDISI et al., 2014; LEES et al., 2016) e aos eventos climáticos extremos, como as secas associadas ao El Niño e as cheias relacionadas à La Niña (MARENGO; ESPINOZA, 2015; BARICHIVICH et al., 2018; GARCIA et al., 2018; CEMADEN, 2021).

Desde o início dos anos 1980, métodos de sensoriamento remoto têm sido aplicados para coletar informações territoriais sobre o uso e a cobertura da terra nas regiões amazônicas (FASSONI-ANDRADE et al., 2021). Contudo, esses estudos têm enfrentado desafios significativos, incluindo alta cobertura de nuvens, conteúdo abundante de vapor de água, estações de seca e de queima de biomassa que acompanham um aumento significativo na concentração de aerossóis (ASNER, 2001; MARTINS et al., 2018) e a limitada resolução espacial e temporal dos sensores disponíveis (FLEISCHMANN et al., 2022). Uma solução adotada a partir da década de 1990 para lidar com a intensa cobertura de nuvens na Amazônia foi a utilização de sensores ativos de Radar de Abertura Sintética (SAR) (HESS et al., 1995; MELACK; WANG 1998; SIQUEIRA et al., 2000; CHAPMAN et al., 2002; COSTA et al., 2002; FREEMAN et al., 2002). Por serem geralmente menos afetados por condições atmosféricas adversas (nuvens, névoa, aerossóis e fumaça) que as imagens ópticas, as imagens SAR solucionam parcialmente esses desafios (HENDERSON e LEWIS, 1998). Dados SAR, principalmente na banda C e L têm se mostrado valiosos para o mapeamento da extensão de corpos hídricos em diferentes ambientes aquáticos (HALL et al., 2011; TINER et al., 2015; WHITE et al., 2015; FASSONI-ANDRADE et al., 2021).

Na última década houve um grande aumento da aplicação de dados SAR para mapear superfícies hídricas devido à disponibilidade e gratuidade de dados dos satélites Sentinel-1 (S1), 1A (S1A) e 1B (S1B) na banda C em catálogos gerenciados pela Agência Espacial Europeia (ESA), pelo Alaska Satellite Facility (ASF), pelo Google Earth Engine (GEE) e pela Microsoft Planetary Computer, sendo disponibilizados em até 48 horas após a passagem dos satélites S1 (FLORES et al., 2019; RUIZ-RAMOS et al., 2020; KEDRON et al., 2022; HERNDON et al., 2023).

Além da gratuidade, outros fatores contribuíram para o aumento do uso de dados SAR. Esses fatores incluem: i) considerável disponibilidade de dados ópticos quase simultâneos de média resolução espacial: Landsat-8 (2013), Sentinel-2 (2016) e Landsat-9 (2021), que são comumente usados como dados auxiliares para inspeções visuais, seleção de amostras e validações em metodologias que envolvem dados SAR (WHITE et al., 2015; BANGIRA et al., 2019; GULÁCSI et al., 2020; ATCHYUTH et al., 2023); ii) melhoria da capacidade de processamento computacional dos novos equipamentos, essencial ao processamento e manipulação de dados SAR; iii) aumento da disponibilidade de plataformas de processamento de dados geoespaciais em nuvem para projetos de pesquisa sem fins lucrativos e não comerciais. No entanto, ainda há desafios ao lidar com conjuntos de dados muito extensos, a menos que se possa custear capacidade adicional (ADELI et al., 2020; VANAMA et al., 2020; PAPATHANASIOU et al., 2021; KSEŇAK et al., 2022; GEE, 2023); iv) crescimento exponencial de imagens sub-métricas SAR de empresas como Capella Space, ICEYE, Airbus Defence and Space, Satellogic e Umbra. v) acesso gratuito a imagens de média resolução espacial SAR de satélites, como o Sentinel-1 da ESA, o ALOS PALSAR-2 da Agência Japonesa de Exploração Aeroespacial (JAXA), e os SAOCOM (1A e 1B) da Comissão Nacional de Atividades Espaciais (CONAE), para fins científicos; vi) maior acessibilidade a algoritmos de segmentação e classificação, tanto de código aberto quanto proprietário, em comparação com anos anteriores, oferecendo mais opções para a análise e interpretação de dados SAR.

A maioria dos satélites SAR operacionais atualmente são comerciais e/ou de acesso restrito, como, por exemplo, os satélites de banda X ( $\lambda \sim 3$  cm): COSMO-SkyMed - ASI/Itália, TerraSAR-X - DLR/Alemanha, PAZ - HISDESAT/Espanha, ASNARO-2 - JAXA/Japão, KOMPSAT-5 - KARI/Coréia do Sul; os de banda C ( $\lambda \sim 6$  cm): RISAT-1 - ISRO/Índia, Radarsat-2 - CSA/Canadá, RCM - CSA/Canadá; o de banda S ( $\lambda \sim 9$  cm) NovaSAR-1 - Survey Satellite Technology Ltd. e Airbus Defense & Space Ltd., com coparticipação de organizações do Reino Unido, Índia, Austrália e Filipinas; os de banda L ( $\lambda \sim 23$  cm): SAOCON 1A e 1B - CONAE/Argentina, ALOS/PALSAR-2 - JAXA/Japão, o qual teve suas imagens recentemente disponibilizadas gratuitamente para fins científicos na plataforma

GEE. Esse contexto limita a ampliação do uso de sensores orbitais nas bandas X, S e L e reforça as linhas de trabalho com os dados gratuitos S1 dual-pol (VV e VH ou HH e HV) na banda C ( $\lambda \sim 6$  cm).

Além da disponibilidade gratuita dos dados, a missão S1 oferece uma série de vantagens para o estudo de ambientes aquáticos na Amazônia, tais como: i) imageamento contínuo da superfície terrestre desde 2014; ii) tempo de revisita variando de 6 a 12 dias; iii) radiometria aprimorada graças ao uso da técnica TOPSAR (*Terrain Observation with Progressive Scans SAR*), que emprega rajadas cíclicas de micro-ondas entre subfaixas. Os satélites da missão S1, S1A e S1B foram lançados em abril de 2014 e 2016, respectivamente. Esses satélites operam com diversos modos de aquisição, incluindo o modo Faixa Ampla Interferométrica, conhecido como "*Interferometric Wide*" (IW), com capacidade para cobrir uma extensão de imageamento de 250 km. Esse modo proporciona uma resolução espacial aproximada de 2,3 metros (alcance) x 14,1 metros (azimute). No hemisfério sul, a missão S1, em órbita descendente no modo IW, fornece dados dual-pol nas polarizações VV e VH a cada aproximadamente 12 dias (ESA, 2023a).

Apesar dos avanços nos métodos de mapeamento de superfícies de águas utilizando imagens SAR (ADELI et al., 2020), especialmente aqueles que empregam inteligência artificial, surge um desafio considerável para torná-los viáveis em escalas territoriais e temporais extensas (THOMAS et al., 2023). Este desafio é atribuído principalmente ao custo associado à infraestrutura computacional robusta necessária e à escassez de profissionais qualificados capazes de implementar, operar, ajustar e manter os fluxos de processamento requeridos (BUCUR et al., 2018; CLEMENT, 2020; VANAMA et al., 2020; PECHMAY et al., 2023; HERNDON et al., 2023). Nesse contexto, torna-se crucial utilizar métodos mais simples, porém eficazes. Um exemplo de método SAR simples é o de limiarização, o qual vem sendo utilizado há bastante tempo para discriminação entre superfícies aquáticas e terrestres (ADELI et al., 2020). Este método consiste em identificar um valor ótimo que permita a separação binária entre as classes de interesse (RICHARDS; XIUPING, 2006).

Assim, a limiarização de dados SAR emerge como um método viável e para mapear AA. Esse método poderia fornecer prontamente informações atualizadas para uso, por exemplo, pela comunidade ribeirinha e pela Defesa Civil, informações espaço-temporais sobre o excesso ou escassez de água nas várzeas. A disponibilidade dessas séries temporais se torna relevante devido à escassez de séries temporais de máscaras de água e pela intensificação das mudanças climáticas com impactos sem precedentes nos processos hidrológicos (LEE et al., 2023). Além disso, as existentes, por serem baseadas em dados ópticos, são frequentemente afetadas pela cobertura recorrente de nuvens, podendo ser inadequadas para representar com precisão os ambientes aquáticos amazônicos, caracterizados por grande variabilidade hidrodinâmica e hidrológica (HAN et al., 2023).

Além disso, a aplicação do método de limiarização para quantificar e monitorar a dinâmica das extensões de AA em longas escalas temporais em regiões de várzeas amazônicas distantes dos centros urbanos, como ocorre nos estados do Acre, Rondônia, Amazonas, Roraima, Pará e Amapá, poderá fornecer informações espaço-temporais de extrema importância para o melhor entendimento de eventos extremos, como inundações e estiagens. Uma compreensão mais aprofundada das extensões de AA também é fundamental para dar suporte científico a políticas de mitigação de impactos reais desses eventos. Essas informações permitirão prever as áreas de maior risco, a partir da hierarquização de sua gravidade, especialmente difusa, numa região de dimensão quase continental de Informações com estas teriam permitido prevenir a crise sanitária, ambiental, de abastecimento, de saúde, insegurança alimentar e hídrica na bacia que detém quase 20% da água doce disponível do Planeta, como a ocorrida na Seca Amazônica de 2023. Neste contexto, este trabalho se propôs a avaliar diferentes métodos de limiarização de dados polarimétricos SAR S1 VV e VH com a finalidade de mapear as AA das planícies de inundação do Baixo Amazonas durante o período entre 2017 e 2022.

## **1.1 Objetivo**

Propõe-se o desenvolvimento de um método de limiarização de dados SAR S1 para mapeamento das AA nas planícies de inundação do Baixo Amazonas do Lago Grande de Curuai (LGC) no Pará, Brasil. O método baseou-se nas seguintes demandas: 1) simplicidade, 2) replicabilidade, 3) acurácia determinada por validação robusta, 4) passível de operacionalização. O procedimento desenvolvido será de fácil replicação para que possa ser estendido para outras regiões da Amazônia, garantindo a clareza das informações fornecidas sobre sua eficácia como também suas limitações. Essa abordagem não só fornecerá informações confiáveis, mas também reforçará a credibilidade das observações realizadas. Além disso, servirá como alicerce para o aprimoramento de futuras metodologias de mapeamento de STAA que utilizam dados SAR na banda C, com polarizações VV e VH.

## **1.2 Objetivos específicos**

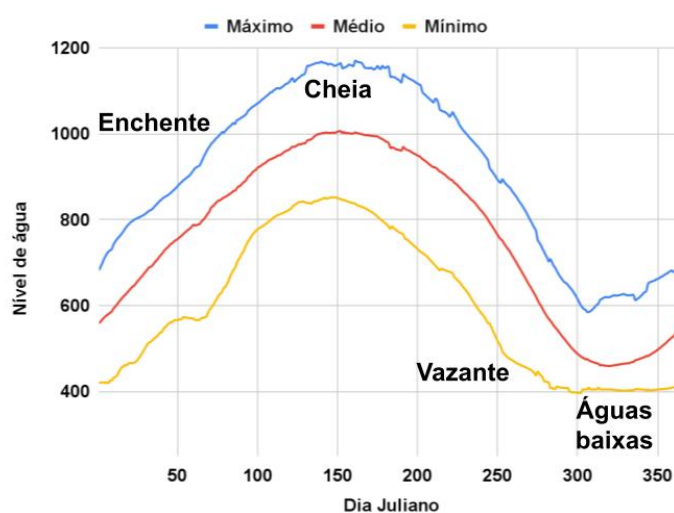
- Aplicar e validar o resultado de três métodos de limiarização por meio de métricas estatísticas de acurácia global, sensibilidade e especificidade.
- Avaliar visualmente as máscaras de água obtidas pelos métodos de limiarização utilizados.
- Identificar os principais fatores que possam influenciar os erros de classificação entre as classes de águas abertas (AA) e de não-águas abertas (NAA).
- Identificar o método de limiarização mais adequado à região de estudo.
- Gerar STAA a partir do método selecionado.
- Avaliar as STAA em função de fatores atmosféricos, meteorológicos, hidrológicos e climáticos.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Variação hidrológica do Baixo Rio Amazonas

A dinâmica hidrológica das planícies de inundação (várzeas) do Rio Amazonas desempenha um papel crucial na estruturação e dinâmica dos ecossistemas amazônicos (CREMA et al., 2015; LOPES et al., 2016). De acordo com observações de Bonnet et al. (2008) e Barbosa et al. (2010), elas são fortemente moldadas pela troca de água entre o Rio Amazonas, seus afluentes, lagos e áreas inundadas. O ciclo de inundação (Figura 2.1), geralmente tem início por volta de meados de dezembro (dia juliano aproximado de 335), logo após atingir seu nível mais baixo. A partir deste ponto, ocorre progressivamente o período de enchente das várzeas (janeiro e fevereiro, 1 - 60), o qual culmina na cheia (abril, maio, junho e julho, 90 - 210), e nos níveis mais elevados de água (junho e julho, 150 - 210). Em seguida, inicia-se a vazante (agosto e setembro, 215 - 270), quando as águas das várzeas retornam aos canais fluviais e ao curso principal do Rio Amazonas, resultando no período de águas baixas (outubro, novembro e dezembro, 275 - 335), e conseqüentemente marcando o reinício do ciclo.

Figura 2.1 – Variação do nível de água na estação de Curuai (1982-2016).



As linhas azul, vermelha e amarela correspondem, respectivamente, aos níveis máximo, médio e mínimo da série temporal considerada.

Fonte: Produção do autor.

As superfícies de água da região do Baixo Rio Amazonas apresentam um estado constante de agitação e formação de ondas, ocasionados pelas forças hidráulicas que governam a troca de água entre o rio Amazonas e a planície de inundação e pelas variáveis meteorológicas como ventos fortes (ARNESEN, 2012; FURTADO, 2014; FASSONI-ANDRADE et al., 2023). Durante o período de águas baixas, essa rugosidade da superfície da água aumenta, especialmente nos lagos rasos de várzea, devido à maior intensidade do vento entre setembro e janeiro e à redução da sua profundidade. Esses lagos podem atingir uma profundidade média inferior a um metro (BARBOSA, 2006). Os lagos de várzea amazônicos geralmente têm suas margens ocupadas pela vegetação adaptada a alternância entre fases aquáticas e terrestres (HESS et al., 1998; SILVA et al., 2008) que é comumente classificada como: arbórea, arbustiva-arbórea, arbustiva, herbácea e aquática (macrófitas, enraizadas e flutuantes, conforme classificação de Junk et al. (2011).

Fleischmann et al. (2022), em uma revisão abrangente sobre a disponibilidade de dados de inundação na Amazônia, obtidos por meio de sensoriamento remoto, modelagem hidrológica e estudos climáticos, apontam para um consenso emergente sobre um "novo estado hidroclimático" na região ao longo das últimas décadas, como resultado do aumento dos níveis máximos de água. Nesse contexto, torna-se crucial o acompanhamento sistemático de variáveis hidrológicas tais como a extensão de superfícies de AA. Para isso, o sensoriamento remoto orbital por radar polarimétrico desponta como uma ferramenta de grande potencial, dada à crescente escassez de dados fluviométricos, às limitações dos sistemas de monitoramento em campo e a intensa cobertura de nuvens características das várzeas amazônicas, que dificultam ou até mesmo inviabilizam a aplicação de informações precisas e frequentes sobre a extensão de AA.

Os sistemas SAR são sensores ativos que operam na faixa das micro-ondas do espectro eletromagnético independentemente da presença ou ausência de luz solar, ainda que, geralmente adotando órbitas sol-síncronas devido à dependência da energia proveniente de painéis solares. Estes sistemas ativos utilizam a visada lateral para capturar com precisão o eco dos feixes de micro-



ondas emitidos. Entretanto, essa técnica pode ocasionar em distorções geométricas, as quais diminuem do alcance próximo ao distante, gerando efeitos como *layover* (inversão de relevo), *foreshortening* (encurtamento de rampa) e sombra, os quais são influenciados pela elevação do terreno (JENSEN, 2007; WOODHOUSE, 2017). Os feixes são emitidos de forma coerente sob um ângulo perpendicular à trajetória do sensor, geralmente utilizam-se frequências entre 0,3 GHz e 3000 GHz ou comprimentos de onda ( $\lambda$ ) variando de 1 milímetro a 1 metro. Os comprimentos de onda ( $\lambda$ ), ou bandas, mais comuns, englobam a X ( $\lambda \sim 3$  cm), a C ( $\lambda \sim 6$  cm) e a L ( $\lambda \sim 23$  cm) (PAPATHANASSIOU et al., 2021).

Uma imagem SAR no formato bruto (SLC - *Single Look Complex*) é representada por uma matriz de números complexos, os quais são definidos principalmente pelos elementos amplitude e fase. A amplitude indica a intensidade da energia retroespalhada, resultado das reflexões independentes e aleatórias dos feixes, tanto construtivas quanto destrutivas, que ocorrem dentro de cada célula de resolução, de acordo com as características geométricas e dielétricas dos alvos presentes. Enquanto isso, a fase representa a diferença de posição entre as frentes de ondas emitidas e recebidas, permitindo a determinação da distância entre a antena do satélite e os alvos (PARADELLA et al., 2021).

A natureza coerente da radiação dos sistemas de radar provoca um padrão de interferência chamado *speckle*, que é um ruído multiplicativo que dá aspecto granuloso (sal e pimenta) à imagem SAR. Este efeito afeta tanto a interpretação visual das imagens SAR, bem como a extração de informações por meio de algoritmos que levam em conta a função de distribuição do retroespalhamento. Recomenda-se o uso de filtros de redução e/ou processamento *multi-look* para reduzir o *speckle*, mesmo que ambas as opções possam resultar em perda de resolução espacial (PAPATHANASSIOU et al., 2021).

### **2.1.1 Medidas de retroespalhamento de radar**

O retroespalhamento ( $\psi$ ) é uma medida da intensidade do sinal de radar que retorna do alvo e é registrado pelo sensor. A variação dessa medida está condicionada às propriedades geométricas e dielétricas dos alvos, bem como ao método de imageamento empregado. Tais propriedades incluem dimensão,

rugosidade, conteúdo de umidade dos espalhadores, comprimento de onda ( $\lambda$ ) e polarização utilizada, juntamente com o ângulo de incidência ( $\theta$ ), o qual é o ângulo formado entre a linha perpendicular ao terreno e o pulso de energia emitido pela antena (JENSEN, 2007). A representação do  $\psi$  frequentemente usada é a normalizada em relação a área da célula de resolução no plano horizontal ( $A_{\psi h}$ ), conhecida como Sigma Zero ( $\sigma^\circ$ ) ou coeficiente de retroespalhamento, medido em unidades de área (por exemplo, metros quadrados,  $m^2$ ) (Equação 2.1).


$$\sigma^\circ = \psi / A_{\psi h} \quad (2.1)$$

No entanto, também existem outras representações do  $\psi$ , como o Beta Zero ( $\beta^\circ$ ) (Equação 2.2) e o Gamma Zero ( $\gamma^\circ$ ) (Equação 2.3), os quais se relacionam à área do alvo segundo planos distintos (Figura 2.2) (SMALL, 2011): o  $\psi^\circ$  refere-se à área no plano oblíquo ( $A_{\psi o}$ ), enquanto o  $\gamma^\circ$  está associado à área no plano perpendicular à linha de visada do sensor ( $A_{\psi p}$ ), respectivamente (ESA, 2023a). As três representações  $\sigma^\circ$ ,  $\beta^\circ$  e  $\gamma^\circ$  geralmente são expressas em escala logarítmica devido à grande amplitude dos valores de  $\psi$  dos alvos, que podem oscilar entre -40 e +5 dB. Essa escolha facilita a visualização e a interpretação dos dados, sendo uma prática comum na análise de imagens de radar (PARADELLA et al., 2021).

$$\beta^\circ = \psi / A_{\psi o} \quad (2.2)$$

$$\gamma^\circ = \psi / A_{\psi p} \quad (2.3)$$

Figura 2.2 – Representações físicas do retroespalhamento.



Fonte: Adaptado de Small (2011).

### 2.1.2 Microtopografia e constante dielétrica

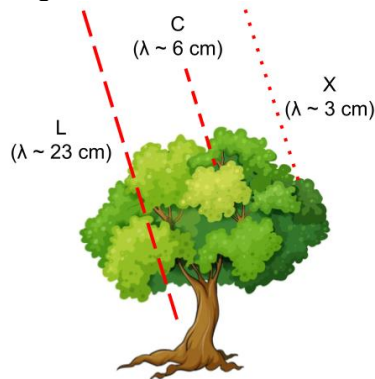
O imageamento ativo SAR é menos suscetível à interferência atmosférica, o que resulta em uma maior eficácia na obtenção de imagens de áreas úmidas, em comparação com sensores ópticos (HENDERSON; LEWIS, 1998; PARADELLA et al., 2021). Diferentemente dos dados ópticos, que se concentram nas características físico-químicas e forma dos alvos, os de radar os descrevem com base em suas características geométricas (forma, profundidade e orientação); e dielétricas (conteúdo de água) (ULABY et al., 1986).

Conforme enfatizado por Peake e Oliver (1971), a rugosidade (microtopografia) pode ser caracterizada pela variação da altura da superfície do alvo, em relação a um nível de referência. Ela é expressa em termos do erro médio quadrático da altura da superfície ( $H_{rms}$ ), o qual por sua vez depende do ângulo de incidência ( $\theta$ ) e do comprimento de onda ( $\lambda$ ). A rugosidade das superfícies é classificada como rugosa quando o  $H_{rms}$  é igual ou superior a  $\lambda/4 \cos\theta$ , lisa quando  $H_{rms}$  é menor ou igual a  $\lambda/25 \cos\theta$  e intermediária quando  $H_{rms}$  está entre esses limites. Desta forma, em um contexto geral, as superfícies tendem a parecer mais rugosas quando apresentam menores valores de  $\theta$  e de  $\lambda$  (PARADELLA et al., 2021).

Normalmente, a capacidade de penetração da radiação em materiais dielétricos aumenta à medida que o comprimento de onda ( $\lambda$ ) cresce, sendo a água uma exceção a essa regra. Isso faz com que, geralmente, alvos terrestres e vegetais com alto teor de água tendem a apresentar maiores valores de retroespalhamento em comparação com alvos equivalentes que possuam menor teor de água (HENDERSON; LEWIS, 1998).

Comprimentos de onda mais longos, como os da banda L ( $\lambda \sim 23$  cm), destacam-se pelo maior potencial de penetração em estruturas vegetais, sejam terrestres ou aquáticas (Figura 2.3) (HESS et al., 1990; SILVA et al., 2008).

Figura 2.3 – Ilustração do potencial de penetração das micro-ondas nas bandas X, C e L em estruturas vegetais.



Fonte: Produção do autor.

Essa característica permite a interação da radiação com alvos localizados abaixo do dossel vegetal. Em circunstâncias específicas de baixa ou média densidade vegetal, a radiação pode até alcançar e interagir com a base das estruturas, seja solo exposto, vegetação ou água, ou uma combinação destes, dependendo do nível da água presente (ZHANG et al., 2022).


Em contrapartida, comprimentos de onda menores, como os das bandas X ( $\lambda \sim 3$  cm) e C ( $\lambda \sim 6$  cm), tendem a interagir mais intensamente com estruturas vegetais de menor dimensão próximas ao dossel (ZHANG et al., 2022). Por essa razão, o mapeamento de áreas inundadas e superfícies de água sob o dossel de vegetação terrestre e aquática geralmente alcança melhores resultados com a

banda L, especialmente em condições de alta variabilidade hidrológica dos níveis de água (HESS et al., 1995; SILVA et al., 2008; ARNESEN, 2012).

O mapeamento de áreas de AA com a banda C se mostra adequado, uma vez que apresenta significativa sensibilidade à presença de estruturas vegetais e terrestres em meio à água ou em seu entorno. Embora haja consenso na literatura sobre essas aplicações específicas a cada uma das bandas, é importante compreender integralmente as características dos alvos, assim como as particularidades do imageamento lateral SAR (off-nadir). Isso possibilita o melhor aproveitamento dos dados de radar polarimétrico e, conseqüentemente, eleva o potencial de extração de informações acerca da observação da Terra (WOODHOUSE, 2017; PAPATHANASSIOU et al., 2021).

Na banda C (Figura 2.4), tipicamente, a interação das micro-ondas com superfícies lisas, como as de águas calmas, com florações de algas, ou com a presença de óleo biogênico ou petróleo e solo exposto seco ou de baixa densidade vegetal tende a resultar na reflexão especular (WU et al., 2018). Esse processo direciona o pulso incidente para fora do campo de detecção do sensor, acarretando baixo  $\sigma^\circ$  (ULABY et al., 1986). Por outro lado, a interação das micro-ondas com superfícies rugosas, como solos expostos com média e alta densidade vegetal, águas agitadas devido à ação de forças hidráulicas e eólicas, estruturas vegetais terrestre e aquática, geralmente resulta em reflexões dos tipos superficial, volumétrico e de reflexão de canto (double-bounce), ocasionando valores mais altos de retroespalhamento.

Figura 2.4 – Representação dos diferentes tipos de reflexão entre as micro-ondas (banda C) e os alvos.



Fonte: Produção do autor.

### **2.1.3 Polarização da onda eletromagnética**

Os sistemas SAR utilizam polarizações específicas para enviar e receber radiação, geralmente linearmente polarizada, seja na orientação vertical (V) ou horizontal (H). As configurações de transmissão e recepção da radiação, juntamente com as características de comprimento de onda, ângulo de incidência, e as propriedades dielétricas e de microtopografia do alvo, desempenham um papel fundamental na interação da radiação com os alvos e na forma como ela é registrada pelos sensores SAR. Além disso, tais configurações afetam a ocorrência maior ou menor de um dado tipo de espalhamento. Os sinais de retorno das polarizações paralelas (HH e VV) em superfícies hídricas, terrestres e vegetais geralmente apresentam maior intensidade do que os das polarizações cruzadas (HV e VH) (ULABY et al., 1986). Isso se deve à maior sensibilidade das polarizações cruzadas à rugosidade dos alvos (ROSSI et al., 2023), fazendo com que ocorram predominantemente reflexões do tipo quase-especular em superfícies suavemente onduladas, e reflexões dos tipos superficial e volumétrica em superfícies rugosas. Essas reflexões promovem a despolarização direcional do pulso emitido, seja na polarização vertical ou horizontal, resultando no retorno de apenas parte do pulso para o campo de detecção do sensor (SANT'ANNA et al., 2007; PAPATHANASSIOU et al., 2021; ZHANG et al., 2022). Portanto, o uso de diferentes polarizações pode fornecer informações valiosas sobre as características geométricas e dielétricas dos alvos (ULABY et al., 1986; HENDERSON; LEWIS, 1998; ROSSI et al., 2023).

## **2.2 Águas abertas amazônicas sob a perspectiva SAR**

A utilização do sensoriamento SAR em áreas de alta cobertura de nuvens desempenha um papel relevante para o mapeamento e monitoramento de AA (MUSA et al., 2015; ADELI et al., 2020; SOMAN e INDU 2022; MCCORMACK et al., 2023). A detecção dessas superfícies na literatura geralmente é direcionada a locais específicos dentro de redes hidrográficas, com o objetivo principal de capturar suas extensões máximas e mínimas associadas, respectivamente, a eventos de inundação e secas. Além disso, busca-se retratar a frequência de

inundação para obter uma representação hidrológica precisa. (WHITE et al., 2015; FASSONI-ANDRADE et al., 2021).

A partir da década de 90, o aumento da disponibilidade e acessibilidade de dados SAR possibilitou muitos estudos sobre as superfícies de água na Amazônia. Diversos métodos usando sensores SAR de média resolução (<100 m) foram empregados para mapear a extensão, dinâmica e padrões de inundação de rios, lagos e áreas de várzea na região. Esses estudos, utilizando dados SAR, foram valiosos e mostraram maior precisão em comparação com o uso exclusivo de dados ópticos. No entanto, devido ao uso de sensores SAR de baixa frequência de imageamento, essas avaliações foram limitadas a áreas e períodos hidrológicos específicos.

Apesar da notável disponibilidade de imagens S1 na banda C desde 2014, com resoluções espaciais aproximadas de 10 metros/pixel e intervalo temporal de imageamento de 12 dias, esses dados ainda não foram totalmente explorados em estudos na Amazônia para o mapeamento de superfícies de águas. Ao contrário do que ocorre em várias áreas úmidas remotas e/ou de difícil acesso em diferentes partes do mundo, onde esses estudos têm crescido exponencialmente (SCHUMANN et al., 2015; GASICA et al., 2020; SIPELGAS et al., 2021; MELKAMU et al., 2022; SCHLAFFER et al., 2022; ROSSI et al., 2023).

Um dos principais motivos desse crescimento exponencial do uso de dados S1 se deve, ao uso de plataformas em nuvem, como o GEE (TSAI et al., 2020; SOMAN e INDU, 2022). Ao contar com dados S1 pré-processados, o GEE otimiza e facilita os arranjos metodológicos e operacionais, além de análises geoespaciais (DEVRIES et al., 2020; AMANI et al., 2020; PHAM-DUC et al., 2023; MARKERT et al., 2023; VELASTEGUI-MONTOYA et al., 2023).

### **2.3 Aplicação de imagens SAR na classificação de águas abertas**

Existem predominantemente duas categorias de classificação de imagens digitais em sensoriamento remoto, sejam ópticas ou SAR. A primeira, chamada de classificação supervisionada, envolve o analista que, munido de conhecimento prévio ou atribuindo classes aos elementos na imagem, como

pixels ou regiões (dados temáticos), fornece amostras representativas para orientar o processo de classificação. A segunda abordagem abrange a classificação não supervisionada, em que não é estritamente necessário ter conhecimento prévio sobre as características, muito menos sobre a distribuição dos pixels na cena (RICHARDS; XIUPING, 2006; MEHMOOD et al., 2023).

No contexto do mapeamento de AA usando imagens SAR, existem vários arranjos metodológicos de classificação (WHITE et al., 2015; SCHUMANN et al., 2015; ADELI et al., 2020; VANAMA et al., 2020; ROSSI et al., 2023). Estas incluem métodos supervisionados, que fazem uso de algoritmos estatísticos, probabilísticos, de limiarização, bem como técnicas baseadas em inteligência artificial, "*Artificial Intelligence*" (AI), como modelos de aprendizado de máquina, "*Machine Learning*" (ML) e aprendizado profundo, "*Deep Learning*" (DL). Além disso, são empregadas abordagens não supervisionadas, especialmente aquelas fundamentadas em medidas de distância ou no agrupamento de amostras a partir de seus atributos, como o K-médias, EM (Esperança-Maximização) e ISODATA (Algoritmo Iterativo de Análise de Dados Auto-organizável).

Além do uso de classificações supervisionadas e não supervisionadas, as metodologias de mapeamento de AA frequentemente integram técnicas de filtragem de ruído *speckle* e crescimento de regiões para representar melhor as características hidrogeomorfológicas. Também é comum o uso de dados relacionados à variação hidrológica e ao estado atual dos recursos hídricos, incluindo máscaras de água e de frequência de inundação derivadas de dados ópticos (por exemplo, MODIS, Landsat e Sentinel-2), altimetria de sensores SAR e LIDAR (*Light Detection and Ranging*), e dados batimétricos (WHITE et al., 2015; SCHUMANN et al., 2015; BOLANOS et al., 2016; ADELI et al., 2020; TSAI et al., 2020; FASSONI-ANDRADE et al., 2021; FLEISCHMANN et al., 2022; LIANG et al., 2023; PINHEIRO et al., 2023).

Independentemente da abordagem SAR para o mapeamento de superfícies hídricas, a acurácia é frequentemente afetada não apenas pelo ruído *speckle*, mas também pelas deformações geométricas resultantes do imageamento




lateral dos sensores SAR e das superfícies de águas abertas rugosas. Essas deformações são causadas pela presença de ondas, resultantes de forças eólicas e hidrodinâmicas (ARNESEN, 2012; FURTADO, 2014). No entanto, é importante destacar que estudos quantitativos sobre como essas forças influenciam sazonalmente a formação das ondas são escassos ou inexistentes para as áreas de várzeas amazônicas (MAGALHÃES, 2022; FASSONI-ANDRADE et al., 2023). Isso pode estar relacionado à considerável variação hidrológica desses sistemas aquáticos, além dos desafios significativos e dos custos envolvidos na realização de tarefas de campo e monitoramento, que exigem a implantação e manutenção de diferentes equipamentos.

Além desses aspectos relacionados à acurácia de mapeamento, existem preocupações significativas quanto à exigência computacional da abordagem de classificação a ser empregada, especialmente quando o objetivo é mapear áreas extensas e/ou longas séries temporais. Isso se deve ao grande volume de dados a ser processado, exigindo poder computacional e infraestrutura adequados. Nessas circunstâncias, muitas vezes opta-se por métodos de limiarização ao lidar com dados SAR, em vez de abordagens de classificação supervisionada, como aquelas baseadas em algoritmos de ML, incluindo Árvores de Decisão (DT), Florestas Aleatórias (RF) e em DL, como Redes Neurais (NN). Isso ocorre porque estas últimas são computacionalmente mais dispendiosas e não necessariamente tão superiores em termos de acurácia em contextos práticos quando comparadas aos métodos de limiarização SAR (CLEMENT, 2020; MAGALHÃES, 2022; PECH-MAY et al., 2023; HAN et al., 2023; MAGALHÃES et al., 2022; ROSSI et al., 2023).

Nesse sentido, a limiarização empírica e o método Otsu são frequentemente utilizados no mapeamento de AA e NAA (SCHUMANN et al., 2015; LIANG et al., 2023; ROSSI et al., 2023; LIU et al., 2024). Em ambos, define-se um limiar que delimita de forma ideal as modas referentes à distribuição de frequência dos valores dos pixels da imagem SAR em questão, cada um deles baseando-se em regras e fundamentações distintas (Figura 2.5).

Figura 2.5 – Ilustração da limiarização de histograma de frequência de pixels para diferentes valores de  $\sigma^\circ$ .



Fonte: Produção do autor.

No método Empírico (classificação supervisionada), o analista determina um limiar (ex. valor de retroespalhamento) por meio de testes que envolvem diferentes procedimentos, tais como: i) a visualização do histograma de frequência dos pixels (distribuição dos valores de retroespalhamento), ii) a aplicação de conhecimento da localização geográfica e do contexto da imagem, incluindo a seleção e verificação dos valores das amostras, iii) a utilização de imagens ópticas auxiliares de média, alta e altíssima resolução espacial de datas próximas às da imagem SAR para validar visualmente a eficácia do limiar escolhido, e iv) a validação quantitativa por meio de dados coletados in situ. Essas etapas são frequentemente sugeridas na literatura para orientar o analista na definição precisa do limiar empírico.

Por outro lado, também merece destaque o método de Otsu (OTSU, 1979), um método não supervisionado que procura encontrar um limiar ideal ao analisar a distribuição dos valores de pixels na imagem. Ele otimiza a variância entre duas classes, identificando o ponto ótimo que separa duas modas (classes), como AA e NAA. Essas classes geralmente exibem diferenças significativas, especialmente no contexto de retroespalhamento, associadas a valores menores e maiores, respectivamente. A formulação teórica do método de Otsu fundamenta-se em um valor limite, o qual é calculado minimizando a soma ponderada das variações intraclasse, o que, em termos matemáticos, é equivalente a maximizar a variância entre classes (Equação 2.4) (VANAMA et al., 2020; LIANG et al., 2023; ATCHYUTH et al., 2023).

$$\delta^2_B = \omega_{\text{água}} \omega_{\text{não-água}} (\mu_{\text{água}} - \mu_{\text{não-água}}) \quad (2.4)$$

Onde  $\mu_{\text{água}}$  e  $\mu_{\text{não-água}}$  são os valores médios das classes de água e não-água,  $\omega_{\text{água}}$  e  $\omega_{\text{não-água}}$  são as frações de pixels e  $\delta^2_B$  é a variância entre classes.

Os métodos de limiarização empírica e Otsu são amplamente utilizados na literatura de sensoriamento remoto aquático, principalmente com dados ópticos, por meio de índices espectrais de água, como o Índice da Diferença Normalizada da Água ("Normalized Difference Water Index" - NDWI) e sua versão modificada ("Modified Normalized Difference Water Index" - MNDWI) e com dados SAR em diferentes polarizações, com destaque para a polarização VV (MOHARRAMI et al., 2021; ZHANG et al., 2022; HANA et al., 2023). Esses métodos têm se mostrado particularmente eficazes em suas abordagens com dados SAR para mapear AA em escalas espaciais e territoriais significativas (BANGIRA et al., 2019; WANG et al., 2019; MOHARRAMI et al., 2021; SOMAN e INDU, 2022; TRAN et al., 2022; MARKERT et al., 2023; ROSSI et al., 2023).

Liang et al. (2023) empregaram os métodos de limiarização empírico (-18 dB) e Otsu (valor não especificado no estudo) aos dados S1, na polarização VV, para mapear as AA e NAA do Lago Dongping, situado na bacia do rio Dawenhe, no leste da China. Os valores de acurácia global (AG) alcançados foram de 0,9758 e 0,9736 para os métodos Empírico e Otsu, respectivamente. Em outro estudo, Liang e Liu (2020), delimitaram AA e NAA na região metropolitana de Baton Rouge, localizada no estado de Louisiana, EUA, atingindo valores de AG de 0,9891 e 0,9812 para os métodos Empírico e Otsu, respectivamente.

Soman e Indu et al. (2020) desenvolveram uma aplicação web de código aberto para o mapeamento automatizado de AA e NAA, utilizando imagens S1 na polarização VV e o método Otsu (valor não especificado no estudo) em datas específicas em 20 locais (10 lagos e 10 rios) ao redor do mundo, incluindo o Rio Amazonas. Os resultados indicaram valores de AG, variando de 0,8416 a 0,9947 para lagos e de 0,8723 a 98,96 para rios. A AG do mapeamento da área do Rio Amazonas na data de 11/10/2020, foi de 0,9861.

Atchyuth et al. (2023), utilizaram o método Otsu na polarização VV para mapear inundações do Rio Baitarano, situado no leste da Índia, durante os anos de 2018 a 2022. Os valores Otsu e as áreas máximas inundadas obtidas foram -10,86 dB e 440,3 km<sup>2</sup> para 2018, -12,93 dB e 268,56 km<sup>2</sup> para 2019, -12,86 dB e 178,40 km<sup>2</sup> para 2020, -12,79 dB e 203,79 km<sup>2</sup> para 2021 e -12,96 dB e 321,33 km<sup>2</sup> para 2022. Um detalhe interessante, não abordado no estudo, é que o maior limiar Otsu foi associado à maior área inundada no ano de 2018. Esse resultado parece compreensível, uma vez que o evento extremo de inundação pode estar relacionado às tempestades, com a atuação de ventos intensos que aumentaram a rugosidade das AA, consequentemente resultando em maiores valores de  $\sigma^\circ$ . A validação dos mapas de inundação foi realizada por meio de amostras de áreas AA e NAA, selecionadas na interseção e nos limites das máscaras de água Otsu e de NDWI derivado de imagens S2. Isso resultou em valores de AG de 0,9024 para 2018, 0,8276 para 2019, 0,90 para 2020, 0,8750 para 2021 e 0,8947 para 2022, respectivamente. A escolha da polarização VV foi baseada na investigação de oito combinações distintas de polarização (VH, VV, VV×VH, VV+VH, VH-VV, VV-VH, VV/VH e VH/VV) para avaliar o potencial dessas combinações na correta identificação das superfícies hídricas em comparação com as terrestres.

Vanama et al. (2020) realizaram o mapeamento de áreas inundadas durante as enchentes em Kerala, Índia, desencadeadas por precipitações intensas em agosto de 2018. Para esta análise, empregaram o método de Otsu em uma imagem SAR S1 VV média multitemporal, derivada do mosaico dos valores médios de  $\sigma^\circ$  de 264 imagens capturadas entre 1 de janeiro de 2015 e 31 de dezembro de 2017. A seleção da polarização VV foi fundamentada na literatura indicando maior adequação das polarizações paralelas (HH e VV) ao mapeamento de inundações. A validação do mapeamento foi conduzida com amostras de AA e NAA, selecionadas a partir de imagens ópticas de média e alta resolução espacial, como Landsat-8 (30 metros/pixel) e Sentinel-2 (10 metros/pixel), além da altíssima resolução do WorldView-3 (0,31 metros/pixel). O valor de AG alcançado foi de 0,82. Os autores destacaram que estes valores não foram mais elevados, principalmente porque áreas com baixo valor de

retroespalhamento, como alvos lisos e áreas sob os efeitos de *foreshortening* e sombra, foram classificadas erroneamente como AA. Isso resultou na superestimação das AA, proporcionando uma visão equivocada da verdadeira extensão inundada. No entanto, dada às circunstâncias de relativa adequação dos valores de AG, a urgência e a aplicabilidade prática, o mapeamento foi aceito como adequado.

Moharrami et al. (2021) aplicaram o método de Otsu aos dados S1 de polarização VV para mapear as áreas alagadas durante uma grave inundação em Aqqala, localizada na parte norte da província de Golestan, Irã, em março de 2019, que perdurou por aproximadamente dois meses. Foram criadas máscaras de AA para cada uma das oito cenas, sendo uma cena pré-cheia, seis durante as cheias e uma pós-cheia. Utilizou-se o valor fixo de limite Otsu de -14,9 dB, uma vez que os limiares calculados para cada cena variaram apenas 0,07 dB. Os valores de AG das máscaras foram superiores a 0,9. Além disso, visualmente, pôde-se constatar uma significativa correspondência espacial da máscara de AA com as interfaces hídrico-terrestre. Segundo os autores, esses resultados são atribuídos principalmente à maior hidrodinâmica nas fases de enchente e vazante.

Han et al. (2023) desenvolveram uma metodologia para a detecção e monitoramento mensal de AA, permanentes e sazonais, sujeitas a variações hidrológicas significativas com base em dados ópticos e SAR. Este estudo baseou-se na utilização de dados de sensoriamento remoto orbital do ano de 2022, marcado por cheias históricas em diferentes regiões do mundo. O método de mapeamento integrava o uso de uma abordagem lógica, combinando diferentes índices espectrais de dados ópticos (Sentinel-2 e Landsat-8), com o método de limiarização Otsu aplicado aos dados SAR (Sentinel-1). A eficácia das máscaras de águas abertas foi confirmada por comparações com produtos existentes, como o *Global Surface Water*, *Global Surface Water Dynamics*, *Global 3 arc-second Water Body Map*, *Global Land Cover Facility*, *Global Water Body*, *Global Inundation Extent from Multisatellite* e *Global Seasonal Dynamics of Inland Open Water and Ice*. Essas comparações foram realizadas em setembro no Lago Poyang, na China, em julho na Planície do Rio Pó, na Itália, e

em julho na planície do rio Indo, no Paquistão. Um aspecto interessante é que essa metodologia também demonstra eficácia na análise de dados ópticos.

É relevante destacar que as NN se sobressaem quanto à precisão em relação aos métodos de limiares. No entanto, é importante mencionar que elas também apresentam a desvantagem de demandar maior poder computacional em comparação com outros métodos de classificação, principalmente quando grandes áreas são avaliadas (VANAMA et al., 2020; GUO et al., 2022; WU et al., 2023; ROSSI et al., 2023). Portanto, a aplicação da limiarização Empírica e do método Otsu em conjuntos de dados SAR representa uma abordagem adequada para estudos que englobam AA em contextos de vastas extensões geográficas e longas séries temporais.

Uma série de estudos utilizando sensores SAR nas bandas C e L foi conduzida com o objetivo de mapear superfícies de água nas planícies amazônicas, empregando dados SAR (Tabela 2.1). No entanto, as abordagens adotadas não se mostrariam práticas em um contexto operacional de mapeamento, uma vez que incluem predominantemente: i) a aplicação de métodos de classificação baseados em conjuntos de pixels (regiões), considerando atributos texturais que contribuem para uma compreensão mais contextual e semântica da cena SAR (SILVA et al., 2010; FURTADO, 2014); ii) o uso de dados SAR complexos SLC; iii) o emprego frequente de algoritmos como DT e RF. Essas condições, que já explicam um significativo poder computacional, seriam ainda mais dispendiosas em um contexto de grande volume de dados envolvendo uma larga escala espacial e temporal. É possível que tais fatores contribuam, em parte, para a escassez de estudos baseados em séries temporais de imagens para o estudo de tendências das AA das várzeas amazônicas, sobretudo aqueles que envolvem o uso de dados S1 (FLEISCHMANN et al., 2022).

Tabela 2.1 – Trabalhos com dados SAR nas bandas C e L na área de hidrologia.

<b>Satélite (Banda) Res. Esp. e Temp. Período de operação</b>	<b>Área (Período)</b>	<b>Referência(s)</b>
JERS-1 (L) 18 metros e 44 dias 1992 - 1998	Baixo Rio Amazonas (1995 - 1996) Rio Amazonas (1994) Sub-bacia do Rio Negro (1995 - 1996) Baixo Rio Amazonas (1993 - 1997)	HESS et al., 2015 SAKURAI-AMANO et al., 2005 FRAPPART et al., 2005 MARTINEZ; LE TOAN, 2007
ALOS-1 (L) 7 - 100 metros e 14 dias 2006 - 2011	Amazônia Central (2007 - 2010)	FERREIRA-FERREIRA et al., 2015
ALOS-2 (L) 1 - 100 metros e 14 - 56 dias 2006 - 2011	Bacia Amazônica (2014 - 2017)	ROSENQVIST et al., 2020
ERS-1 (C) 30 metros e 270 dias 1991 - 2000	Floresta Nacional do Tapajós (1992, 1993 e 1996)	ANGELIS et al., 2001
ERS-2 (C) 30 metros e 270 dias 1995 - 2011	Amazônia boliviana (1996 - 1998)	BOURREL et al., 2009
Radarsat-1 (C) 8 - 100 metros e 24 dias 1995 - 2012	Amazônia Oriental (2003 – 2004) (2006 – 2010)	SILVA et al., 2010 SILVA et al., 2013
Radarsat-2 (C) 3 - 100 metros e 24 dias 2007 - Em operação	Baixo Rio Amazonas (2011) Baixo Rio Amazonas (2014 - 2016)	FURTADO et al., 2016 CANISIUS et al., 2019
Sentinel-1 (C) 4 - 80 metros e 5 - 90 dias 1A: 2014 - Em operação 1B: 2015 - 2021	Amazônia Central (2016 – 2020) Amazônia Central (2017 – 2019)	MAGALHÃES, 2022 MAGALHÃES et al., 2022

Fonte: Produção do autor.

Magalhães et al. (2022) e Ferreira (2018) são exemplos de estudos que mapearam áreas inundadas na Amazônia, utilizando imagens SAR S1 em diferentes regiões amazônicas, demonstrando assim o seu potencial de aplicação.

O estudo de Ferreira (2018) utilizou 29 imagens do sensor S1 para mapear áreas inundáveis (AA e áreas alagáveis) no sul do estado de Roraima, no interflúvio do Rio Branco até sua junção com o Rio Negro ao longo de 2017, adotando um

limiar VV de -17 dB. A área de estudo em questão é dominada por Campinaranas, uma vegetação pioneira de porte arbustivo médio a baixo, típica de planícies fluviais com solo arenoso. Apesar da importância e contribuição significativas para o mapeamento da dinâmica das áreas inundadas, o estudo não incluiu um processo de validação das máscaras geradas, como a coleta de amostras in situ ou o uso de imagens ópticas ou de outras imagens SAR de datas semelhantes. Isso limitou a capacidade de confirmar a eficácia real deste método de limiarização.

Por outro lado, Magalhães et al. (2022) empregaram 59 imagens do sensor S1 para mapear áreas inundáveis em uma região às margens do Rio Amazonas, entre os municípios de Urucará e Parintins, no estado do Amazonas, na Amazônia Central, durante o período de 26 de setembro de 2016 a 8 de fevereiro de 2020. Os limiares de intensidade de retroespalhamento (VV e VH) foram estabelecidos pelo programa Envi 5.5, no entanto, os seus valores não foram informados. Assim como o estudo de Ferreira (2018), este também carece de um processo de validação, provavelmente devido a limitações semelhantes. Na tentativa de demonstrar a eficácia do método de limiarização, Magalhães et al. (2022) correlacionaram as áreas inundadas obtidas pelas polarizações VH e VV, obtendo um coeficiente de determinação  $R^2$  de 0,89.

Em ambos os estudos de Ferreira (2018) e Magalhães et al. (2022), há uma lacuna em relação à validação das metodologias utilizadas para o mapeamento de áreas inundáveis e/ou de AA. Além disso, não fica claro nos dois estudos como ocorre realmente a seleção dos limiares e se eles são ou não sazonalmente adequados, já que variações hidrológicas ao longo do ano podem influenciar em diferenças na distribuição de frequência de valores de retroespalhamento entre as cenas.

Este contexto ressalta a importância crescente de pesquisas centradas em técnicas de limiarização, usando dados SAR S1 nas polarizações VV e VH para mapeamento de superfícies de água. Apesar de serem mais simples em comparação com abordagens de AI, essas técnicas ofereceriam uma base teórica essencial para compreender melhor as limitações e os fatores que podem



afetar a precisão do mapeamento de áreas inundadas e de AA. O que por sua vez proporcionaria conhecimentos prévios essenciais, inerentes a esse tipo de mapeamento, que facilitariam o uso e a implementação de modelos mais robustos, como os baseados em ML e DL, que, apesar de sua eficácia, muitas vezes ainda são considerados "caixas pretas".

#### **2.4 Fatores atmosféricos, meteorológicos, hidrológicos e climáticos**


A principal vantagem do imageamento por radar, em comparação com o óptico, é a sua capacidade de imageamento com diferentes condições climáticas, devido ao maior comprimento de onda. Isso possibilita o imageamento em condições atmosféricas adversas, como nuvens, brumas e fumaça (PARADELLA et al., 2021). No entanto, em situações atmosféricas extremas, como nuvens carregadas, células de chuva e eventos atmosféricos similares, as micro-ondas podem sofrer consideráveis interferências durante a transmissão, especialmente nas bandas X ( $\lambda \sim 3$  cm) e C ( $\lambda \sim 6$  cm) de baixo comprimento de onda, enquanto que na banda L ( $\lambda \sim 23$  cm), de maior comprimento de onda, tais interferências são menos usuais (ATLAS et al., 1993; LIN et al., 1997; MOORE et al., 1997; ALPERS et al., 2016).

A literatura indica que têm sido realizados esforços significativos para aprimorar a compreensão e caracterização dessas interferências, comumente conhecidas como ruídos, anomalias ou assinaturas, nas imagens SAR. No entanto, devido à complexidade das interações entre as micro-ondas, diferentes tipos de nuvens carregadas e células de chuva, e, em alguns casos, interações entre superfícies terrestres e aquáticas, essas interferências são difíceis de serem totalmente explicadas. Além disso, tais interações dependem de características do imageamento SAR, como o comprimento de onda, a polarização e o ângulo de incidência, além das características geométricas e dielétricas dos alvos, o que pode resultar em diversos tipos de interações e retroespalhamento. Portanto, existem muitas variáveis que podem contribuir para essas complexas interferências.

As interações entre as micro-ondas na banda X e C e as gotas de água presentes em nuvens carregadas e em células de chuva podem resultar em valores de

retroespalhamento, altos (manchas brilhantes) quando as gotas intensificam o retorno do pulso (Figura 2.6a), ou baixos (manchas escuras) quando atenuam (bloqueiam ou enfraquecem) o sinal de retorno (Figura 2.6b) (FERREIRA, 2017; DOBLAS, 2023). Desta forma, a complexidade na observação de zonas tropicais com altas taxas de precipitação e recorrência de nuvens torna-se ainda mais desafiadora e, em alguns casos, inviável, também a partir da perspectiva das micro-ondas (ZHAO et al., 2021; DOBLAS, 2023).

Figura 2.6 – Interação entre micro-ondas nas bandas X e C e nuvens carregadas e células de chuva.



Fonte: Produção do autor.

São necessárias mais pesquisas nesta área, incluindo investigações mais aprofundadas sobre os dois principais tipos de células de chuva mais comuns: a *nimbostratus* (chuva estratiforme), associada a precipitações prolongadas de intensidade leve a moderada; e a *cumulonimbus* (chuva convectiva), caracterizada por um desenvolvimento vertical significativo de baixas temperaturas e relacionada a tempestades, geralmente variando entre -28 °C e -55 °C, conforme mencionado por Doblas et al. (2023) ao referenciar o estudo de Machado et al. (1998). Estes tipos de interferências ou anomalias nos valores de retroespalhamento da banda C S1A geralmente são mais visíveis em cenas de polarização paralela (ALPERS et al., 2016). Portanto, torna-se importante ter à disposição dados de caráter atmosférico e meteorológico para ampliar a compreensão dos fatores que explicam mudanças abruptas no retroespalhamento registrado em imagens SAR na interface atmosférica (DOBLAS, 2023).

As anomalias nos valores de retroespalhamento também podem ser atribuídas à presença de ondas causadas pelo estado agitado das águas abertas, resultante das forças hidráulicas e eólicas. Esse aumento na agitação das águas abertas leva à maior rugosidade e, conseqüentemente, a valores mais altos de  $\sigma^0$  em comparação com os das superfícies lisas de águas calmas (BARTSCH et al., 2012; SCHUMANN et al., 2015; ZHANG et al., 2022; ROSSI et al., 2023).

Outras condições que podem resultar em diferentes distribuições de frequência dos valores dos pixels da imagem SAR estão relacionadas a variações significativas nos níveis de água em lagos, reservatórios e rios de planícies, já que propiciam mudanças na distribuição espacial de diferentes usos e coberturas. Em situações de águas baixas, a redução do nível da água pode expor o substrato de rios e lagos, que acabam por ser colonizados por vegetação herbácea e arbustiva (JUNK; PIEDADE, 1997). Por outro lado, em situações de águas altas podem ocorrer inundações de diferentes tipos de coberturas terrestres e vegetais (SILVA, et al., 2008; AUGUSTO-SILVA et al., 2018).

O aumento da presença da água na vegetação, seja por acúmulo de gotículas (devido à evapotranspiração, orvalho e chuvas) ou pela proximidade de águas abertas, geralmente resulta em um aumento da constante dielétrica desses alvos. Isso faz com que eles apresentem valores de retroespalhamento mais elevados momentaneamente em comparação às da cobertura vegetal com menor umidade intra ou extracelular, ou maior ou menor proximidade de corpos de AA. Dessa forma, a sazonalidade hidrológica dos recursos hídricos pode influenciar fortemente a variabilidade dos valores de retroespalhamento de alvos terrestre e vegetais (HENDERSON; LEWIS, 1998; JONG et al., 2000; BENNINGA et al., 2019). Essa variabilidade, por sua vez, pode introduzir complexidade ao processo de mapeamento de diferentes classes (SILVA et al., 2010; FURTADO, 2014; DOBLAS et al., 2020; ZHANG et al., 2022).

Zhang et al. (2022) destacaram que as variações sazonais nos valores de retroespalhamento das estruturas vegetais nas polarizações VV e VH estavam fortemente relacionadas às mudanças no nível das águas nos extensos Pântanos de Everglades, localizados no sul da Flórida, Estados Unidos. Esse

fenômeno foi especialmente observado em estruturas de vegetação aquática com baixa densidade de cobertura, como a *Cladium jamaicense* Crantz. Com o aumento do nível das águas, o retroespalhamento crescia até um ponto em que as estruturas eram parcialmente submersas. Isso resultava em espalhamentos predominantemente volumétricos e de dupla-rebatida nas estruturas de vegetação aquática próximas à água, caracterizados por altos valores de retroespalhamento. No entanto, à medida que as águas continuavam a subir e as estruturas eram quase que completamente submersas, ocorria um predomínio de espalhamento especular sobre as águas abertas livres desta vegetação entre as plantas aquáticas, caracterizado por baixos valores de retroespalhamento.

Outro aspecto importante que influencia as condições atmosféricas, terrestres e os regimes hídricos, e, por conseguinte, os valores de retroespalhamento dos alvos e a eficácia do mapeamento, são os eventos climáticos El Niño e La Niña, já que exercem influências diretas sobre o ciclo hidrológico nas planícies amazônicas (GLOOR et al. 2013; BARICHIVICH et al., 2018). Durante os eventos de El Niño, as várzeas costumam enfrentar secas prolongadas e intensas, já que este fenômeno tende a dificultar a formação de chuvas (MARENGO; ESPINOZA 2015; CAI et al. 2020). Em contraste, os períodos de La Niña podem resultar em um aumento considerável das precipitações durante os meses mais chuvosos (janeiro a maio), levando a inundações, como as históricas ocorrências em junho de 2021 (CEMADEN, 2021) e subsequentemente em 2022, como as relatadas nas várzeas amazônicas (ESPINOZA et al., 2022).

Desta forma, observa-se que diferentes variáveis atmosféricas, meteorológicas, hidrológicas e climáticas podem impactar os valores de  $\sigma^0$  na banda C de alvos hídricos e terrestres, e, conseqüentemente, influenciar na acurácia do mapeamento de AA.

### 3 METODOLOGIA

#### 3.1 Área de estudo

O Lago Grande de Curuai (LGC) (Figura 3.1), composto por uma série de lagos, localiza-se na margem direita do Rio Amazonas, nos arredores da Vila de Curuai, no estado do Pará, Brasil. O LGC faz parte da vasta planície de inundação do Baixo Rio Amazonas. Reconhecido por suas águas ricas em sedimentos e relativamente rasas (BARBOSA et al., 2010), o LGC possui uma porção setentrional separada do Rio Amazonas por estreitos diques (RUDORFF et al., 2014). Com uma variação máxima sazonal do nível médio da água de aproximadamente sete metros (BARBOSA, 2005), esse fenômeno é principalmente influenciado pelos fluxos provenientes do Rio Amazonas (BONNET et al., 2008). Essas mudanças determinam a morfologia de uma série de lagos do LGC e desempenham um papel essencial na interconectividade hidrológica, tendo em vista que durante os períodos de águas altas, os lagos se unem, enquanto durante as águas baixas, eles se fragmentam e se separam.

Figura 3.1 – Área de estudo: região do Lago Grande de Curuai.



Fonte: Produção do autor.

#### 3.2 Dados de sensoriamento remoto Sentinel-1 e Sentinel-2

##### 3.2.1 Dados SAR Sentinel-1

A missão S1 da ESA consiste em dois sistemas SAR idênticos: S1A e S1B, operando na banda C ( $\lambda = 5,6$  cm) a uma frequência de 5,405 GHz. Eles foram

lançados em abril de 2014 e abril de 2016, respectivamente. Além disso, está planejado o lançamento do Sentinel-1C (S1C) para 2024. Os produtos do S1 estão sistematicamente disponíveis gratuitamente ao público, incluindo as comunidades científica de setores privados e comerciais. Os satélites S1A e S1B compartilhavam uma órbita no mesmo plano, com uma diferença de fase de 180°. Eles realizavam a captura de imagens diurnas e noturnas a cada 6 dias especificamente para a Europa, tanto em suas órbitas ascendentes quanto descendentes, enquanto para outras regiões, a captura ocorria a cada 12 dias em suas órbitas descendentes. Entretanto, em 23 de dezembro de 2021, às 06:53 UTC, o S1B apresentou problemas eletrônicos e perdeu sua funcionalidade. Atualmente, somente o S1A continua operacional, oferecendo uma taxa de revisita de 12 dias tanto para a Europa quanto para as demais localidades (ESA, 2023a).

Neste estudo, os dados do S1 foram adquiridos a partir do catálogo GEE, caracterizando-se por serem do tipo GRD, modo IW, com resolução espacial de 10 metros/pixel e largura de imageamento de 250 km. Esses dados passaram por etapas prévias de calibração radiométrica, ortorretificação, e redução de ruídos de borda e térmicos (FILIPPONI, 2019). Aplicou-se a esses dados o filtro morfológico de mediana *Kernel (.focal\_median)* com geometria circular, disponível na plataforma GEE, com um raio de trinta (30) metros, visando reduzir a influência do ruído *speckle*. Essa abordagem de filtragem circular, denominada '*circle*', proporcionou um nível aprimorado de detalhamento das interfaces hídricas-terrestres na região sul do Rio Grande do Sul, Brasil, e na região de Aveiro, Portugal, quando comparada com outras geometrias de filtragem disponíveis, como '*square*', '*cross*', '*plus*', '*octagon*' e '*diamond*' (TERRES et al., 2021).

### **3.2.2 Dados ópticos Sentinel-2**

A missão Sentinel-2 (S2) da ESA consiste em dois satélites idênticos em órbita polar síncrona ao sol (2A e 2B), com uma diferença de fase de 180°. A missão S2 tem como objetivo monitorar as mudanças na superfície da Terra com uma largura de varredura ampla (290 km) e tempo de revisita de 10 dias com um

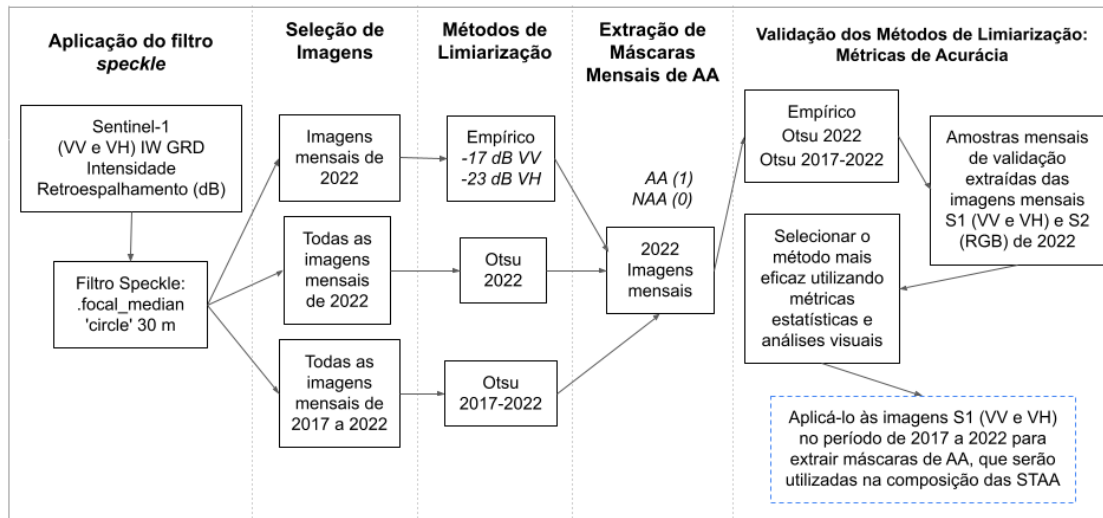
satélite e 5 dias com dois satélites, fornecendo dados gratuitos ao público (ESA, 2023b). A ESA lançou os satélites S2A e S2B em 23 de julho de 2015 e 7 de março de 2017, respectivamente. A carga útil de ambos os satélites consiste no Instrumento Multiespectral (MSI), que possui uma resolução radiométrica de 12 bits, um alcance de imagem de 290 km e 13 bandas distribuídas nas regiões visível (VIS), infravermelho próximo (NIR), borda do vermelho (Red-Edge) e infravermelho de ondas curtas (SWIR). Estas bandas apresentam resoluções espaciais de 10 metros/pixel para as regiões VIS e NIR, enquanto para as bandas Red-Edge, NIR e SWIR a resolução espacial é de 20 metros/pixel. Os produtos do S2 estão disponíveis nos Níveis 1C (reflectância no topo da atmosfera) e 2A (reflectância de superfície). Para a metodologia aplicada neste trabalho, foram utilizados os dados S2 na região do VIS com resolução espacial de 10 metros/pixel de reflectância de superfície provenientes do catálogo GEE.

### **3.3 Classificação dos dados SAR**

#### **3.3.1 Limiarização e extração de máscaras de água**

Foram aplicados três métodos distintos para estabelecer limites mensais em diferentes imagens S1 VV e VH do ano de 2022 (Figura 3.2). Estas imagens foram inicialmente suavizadas por meio de um filtro morfológico de mediana, usando um Kernel circular de 30 metros. O objetivo principal dessa etapa foi criar máscaras de AA, utilizando limites de retroespalhamento apropriados para distinguir entre as classes de AA e NAA, atribuindo os números 1 e 0, respectivamente, a essas classes. A eficácia das máscaras de AA geradas pelos métodos foi avaliada por meio de métricas de acurácia e análises visuais. No final, o principal objetivo era gerar STAA representativas ao longo do período de 2017 a 2022, utilizando o método de limiarização mais apropriado. Os métodos empregados incluem a limiarização Empírica, Otsu 2022 e Otsu 2017-2022, os quais serão explicados a seguir.

Figura 3.2 – Fluxograma metodológico utilizado.



Fonte: Produção do autor.

**Método Empírico:** Neste método foram conduzidos no GEE testes por tentativa e erro de limiares em cada uma das imagens mensais do S1 VV e VH de 2022, selecionadas com base na disponibilidade de imagens S2 defasadas em no máximo 3 dias, uma vez que estas foram utilizadas para auxiliar na identificação e seleção de amostras das classes de AA e NAA (Tabela 3.1). O objetivo dessa limiarização foi identificar um limiar fixo VV e VH entre as imagens S1 que garantisse a máxima coerência espacial entre as máscaras de AA com as superfícies de AA observadas nas imagens S2 em composição RGB colorida, assim como nas áreas de baixo retroespalhamento das imagens S1 (Figura 3.3). Estas análises e testes visuais foram conduzidas no GEE.

Tabela 3.1 – Imagens S1 (VV e VH) e S2 de 2022 utilizadas.


2022	jan	fev	mar	abr	maio	jun	jul	ago	set	out	nov	dez
S1	11/01	04/02	25/03	17/04	23/05	28/06	22/07	03/08	08/09	02/10	19/11	13/12
S2	14/01	03/02	24/03	19/04	24/05	28/06	23/07	02/08	06/09	01/10	20/11	10/12

Características do S1 SAR: Órbita descendente, Faixa de Ângulo de Incidência: 37,6° - 44,0°, Órbita Absoluta: 48586 e Caminho: 39; e S2 Óptico: Órbita descendente, Ângulo Azimute de Iluminação: 136,93, Ângulo Zenith de Iluminação: 29,79, Número de órbita (início): 39146 e Órbita relativa (início): 110.

Fonte: Produção do autor.



Figura 3.3 – Ilustração do método Empírico.



Fonte: Produção do autor.

Método Otsu 2022: Neste método, os limiares mensais foram extraídos a partir dos histogramas de frequência dos conjuntos mensais de imagens S1 disponíveis ao longo do ano de 2022 (Tabela 3.2). Isso possibilitou a obtenção dos limiares mensais Otsu para a distinção entre as classes AA e NAA (Figura 3.4). O número de imagens nos histogramas mensais variou de 1 a 3, conforme detalhado na linha correspondente ao ano de 2022 na Tabela 3.2.

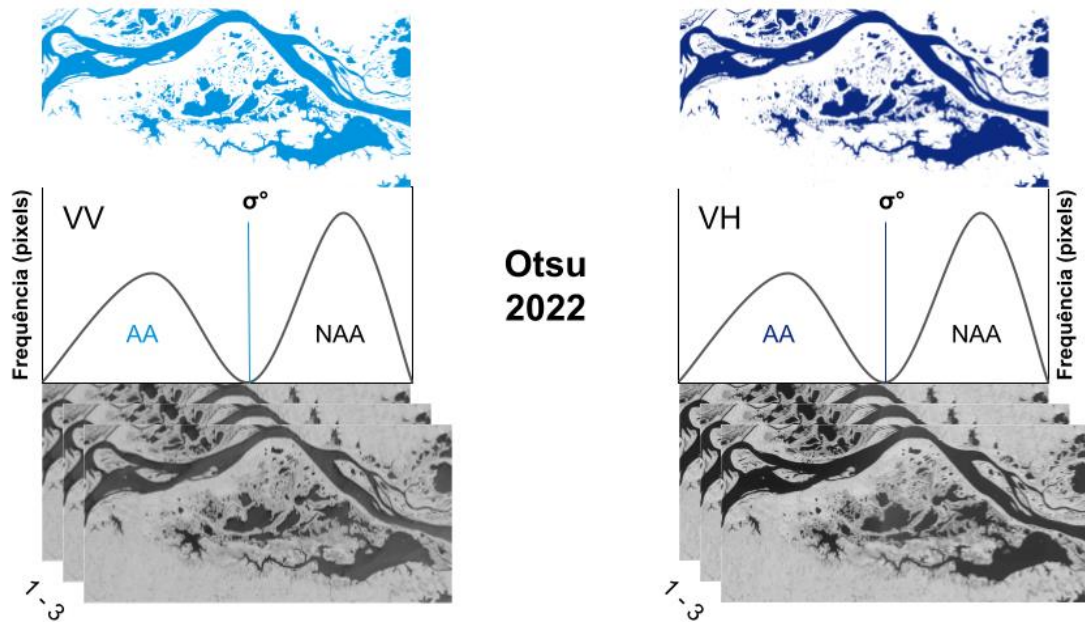
Tabela 3.2 – Imagens S1 (VV e VH) utilizadas nos métodos de limiarização.

Ano	jan	fev	mar	abr	maio	jun	jul	ago	set	out	nov	dez
2017	3	2	3	1	3	3	2	3	2	3	2	3
2018	2	3	2	3	2	3	3	4	5	3	3	2
2019	3	2	3	2	2	3	2	3	3	3	2	3
2020	2	3	2	3	2	3	2	3	3	2	3	2
2021	3	2	3	2	3	2	3	2	3	3	2	3
2022	2	3	2	3	2	3	1	3	2	3	2	3
N	15	15	15	14	14	17	13	18	18	17	14	16

Na tabela, apresenta-se a quantidade de cenas S1 disponíveis para cada mês em cada ano, e "N" indica o total de cenas ao longo da série histórica para cada mês.

Fonte: Produção do autor.

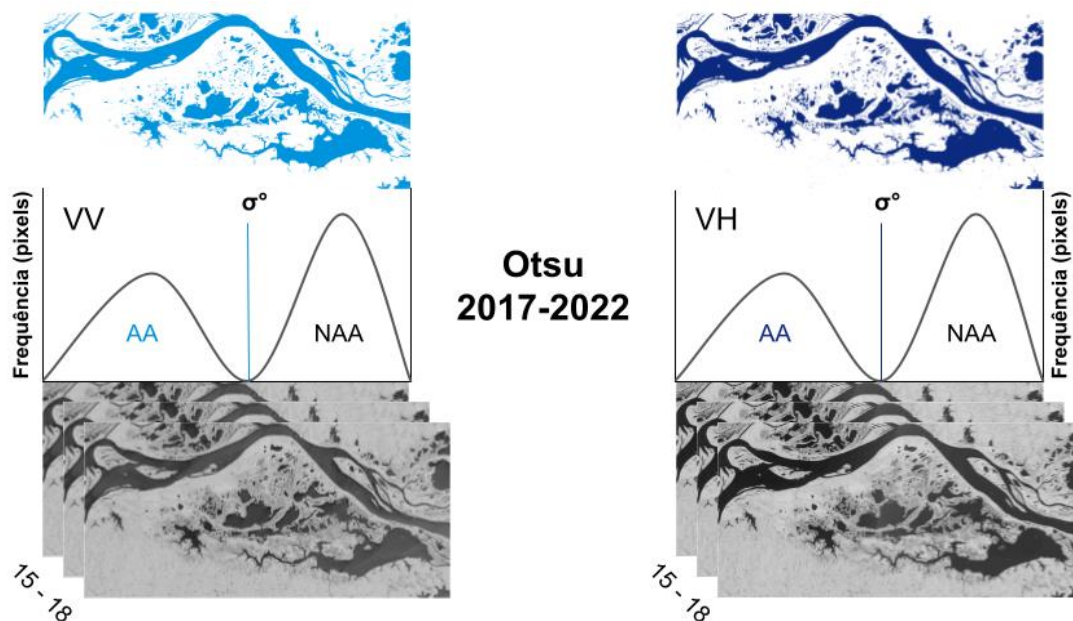
Figura 3.4 – Ilustração do método Otsu 2022.



Fonte: Produção do autor.

Otsu 2017 - 2022: Foi realizada a extração de limiares mensais Otsu, utilizando histogramas de frequência gerados a partir de conjuntos mensais de imagens S1 disponíveis entre 2017 a 2022 (Figura 3.5). Ou seja, as imagens utilizadas para criar os histogramas mensais foram todas aquelas disponíveis em cada mês. O número total de imagens "N" que formaram os histogramas mensais variou de 15 a 18, conforme indicado na última linha da Tabela 3.2.

Figura 3.5 – Ilustração do método Otsu 2017 - 2022.




Fonte: Produção do autor.

### 3.3.2 Seleção das amostras de validação

As imagens mensais SAR S1 e ópticas S2 de 2022, conforme listadas na Tabela 3.1, foram exportadas do GEE e posteriormente utilizadas no software QGIS com o auxílio da ferramenta MapSwipe Tool. Isso facilitou a visualização síncrona das imagens. Para cada mês, seguindo inicialmente a combinação de cenas S1 VV e S2 RGB, foram escolhidas 250 amostras de AA e 250 de NAA. Em seguida, o mesmo procedimento foi repetido para a combinação S1 VH e RGB. Essa abordagem foi adotada para evitar viés no processo de seleção. Dessa forma, o total de amostras mensais foi de 1.000, divididas igualmente em 500 amostras para cada classe (250 selecionadas com base na visualização VV e RGB, e outras 250 com base na visualização VH e RGB) (Figura 3.6). Portanto, ao longo dos 12 meses, foram coletadas 12.000 amostras.

Figura 3.6 – Exemplo de distribuição mensal das amostras mensais na área do LGC.



Fonte: Produção do autor.

### 3.3.3 Validação e avaliação visual das máscaras de água

A validação mensal de cada máscara de AA considerou as 1.000 amostras, 500 de AA e 500 de NAA do mês correspondente, as métricas estatísticas utilizadas foram as seguintes, acurácia global (AG), sensibilidade (S) (habilidade do modelo em detectar corretamente AA) e especificidade (E) (capacidade de identificar adequadamente NAA) (Equações 3.1, 3.2 e 3.3). Elas são apropriadas para contextos binários, como no caso de AA e AN (SAHOUR et al., 2022).

$$\text{Acurácia global (AG)} = (TP + TN) / (TP + TN + FP + FN) \quad (3.1)$$

$$\text{Sensibilidade (S) (Taxa de verdadeiros positivos)} = TP / (TP + FN) \quad (3.2)$$

$$\text{Especificidade (E) (Taxa de verdadeiros negativos)} = TN / (TN + FP) \quad (3.3)$$

Em que,  $TP$  são os verdadeiros positivos (pixels de AA classificados corretamente),  $TN$  são os verdadeiros negativos (pixels de NAA classificados corretamente),  $FP$  são os falsos positivos (pixels classificados como AA, mas



que na verdade são NAA) e *FN* são os falsos negativos (pixels classificados como águas não-abertas, mas que na verdade são águas abertas).

Como complemento à análise estatística, conduziu-se uma avaliação visual das máscaras de água mensais de 2022 geradas pelos três métodos. O objetivo foi verificar qualitativamente a correspondência espacial entre essas máscaras e as áreas de AA visíveis nas imagens mensais S2 de 2022 (Tabela 3.1).

### 3.3.4 Geração das séries temporais de águas abertas

Após a seleção do método de limiarização mensal mais apropriado, fundamentada em análises visuais e métricas de acurácia, aplicaram-se os limiares resultantes desses métodos para gerar séries temporais de águas abertas (STAA) para as polarizações VV (STAAVV) e VH (STAAVH). Foi utilizado um conjunto de 186 imagens S1 (VV e VH) abrangendo o período de 2017 a 2022, que cobrem a área do LGC, conforme ilustrado na Figura 3.7. A delimitação dessa área foi realizada com base em uma imagem de satélite de altíssima resolução da Maxar, disponível como mapa base no GEE, datada de 04/08/2022, seguindo a geometria proposta por Bonnet et al. (2008).

Figura 3.7 – Área utilizada na geração das séries temporais de águas abertas.



Fonte: Produção do autor.

## 3.4 Dados auxiliares

Este estudo investigou como os fatores atmosféricos, meteorológicos, hidrológicos e climáticos podem influenciar a precisão do mapeamento de águas

abertas ao longo do período de 2017 a 2022. Para isso, foram utilizados dados de precipitação média acumulada (diária, mensal e anual), cobertura de nuvens diária, nível de água (médio mensal e diário) e dados climáticos de ocorrência dos fenômenos El Niño e La Niña (Tabela 3.3).

Tabela 3.3 – Dados auxiliares utilizados.

Dados	Característica	Período	Fonte	Aplicação
Precipitação Média Acumulada (mm)	Resolução Espacial 5566 metros/pixel	2017 - 2022	CHIRPS/NASA/NOAA	Diária, Mensal e Anual
Cobertura de Nuvens Diária (0 – 1)	Resolução Espacial 1000 metros/pixel	2017 - 2022	MODIS/MYD09GA Band: state_1Km	Cobertura de Nuvens
Nível de Água (cm) Médio Mensal e Diário	Estação 17060000 (Vila de Curuai) Estação 17050001 (Óbidos)	1982 - 2023	ANA/SNIRH	Sazonalidade hidrológica
Climáticos: El Niño e La Niña	Índice Niño Oceânico (ONI)	2017 - 2022	NOAA	Severidade do evento climático

Fonte: Produção do autor.

### 3.4.1 Dados de precipitação

Foram utilizados dados de precipitação média acumulada (diária, mensal e anual) do CHIRPS (*Climate Hazards Group Infrared Precipitation with Stations*) para a região do LGC entre 2017 e 2022. Esses dados têm um alcance temporal que abrange desde 1981 e estão disponíveis no catálogo do GEE. O produto CHIRPS combina dados de precipitação provenientes de satélites estadunidenses da Administração Nacional da Aeronáutica e Espaço (NASA) e da Administração Nacional Oceânica e Atmosférica (NOAA), juntamente com dados de estações terrestres (FUNK et al., 2015). Esses dados foram usados como indicador de padrões e condições sazonais da atmosfera (recorrência de nuvens carregadas, presença de células de chuva e ventos) quanto terrestres (teor de umidade), que podem influenciar o  $\sigma^{\circ}$  e, conseqüentemente, o mapeamento das classes AA e NAA.

### 3.4.2 Dados de cobertura de nuvens

Os dados diários de cobertura de nuvens, obtidos para as mesmas datas das imagens do S1 utilizadas na geração das STAA entre 2017 e 2022, foram derivados das imagens capturadas pelo sensor MODIS (*Moderate Resolution*


*Imaging Spectroradiometer*) a bordo do satélite Terra (passagem matutina em torno das 10:30). Esses dados estão disponíveis no catálogo do GEE. A extração dos dados foi realizada por meio da função "cloudiness", que fornece informações sobre a cobertura de nuvens na banda "state\_1km". Os pixels foram classificados em valores que variam de 0 (sem nuvens) a 1 (com nuvens).

### **3.4.3 Dados de nível de água**

Os dados de nível de água (NA) provenientes das estações mais próximas do LGC são oriundos de duas estações específicas: Vila de Curuai - PA 17060000 (de janeiro de 2017 a março de 2019), referida como (NACuruai), e Óbidos - PA 17050001 (de janeiro de 2017 a dezembro de 2022), denominada como (NAÓbidos). Esses dados de NA, disponibilizados diariamente e mensalmente em centímetros (cm), estão disponíveis no site HIDROWEB, gerenciado pela Agência Nacional de Águas e Saneamento Básico (ANA). É importante observar que os dados de NACuruai foram registrados até março de 2019, devido a recorrentes dificuldades na estabilização da régua, um problema persistente desde 2017. Para superar essa limitação, realizou-se uma análise de regressão entre os NACuruai e NAÓbidos para a série de medidas compreendidas entre os anos de 1982 a 2016. Essa regressão permitiu estimar os valores de NACuruai para o período de janeiro de 2017 a dezembro de 2022. Os anos de 2011 e 2015 não foram incluídos na regressão. O ano de 2011 não apresentou dados de NACuruai, e o ano de 2015 exibiu uma série de valores considerados anômalos, possivelmente relacionados a uma estiagem severa e/ou a erros de registro. O modelo de regressão (NACuruai.estimado) escolhido com melhor desempenho foi o exponencial, representado pela Equação 3.4, com um valor de  $R^2$  de 0,991 (Figura 3.8).

$$\text{NACuruai.estimado} = 395 * e^{(0,00131 * \text{NAÓbidos})} \quad (3.4)$$

Figura 3.8 – Regressão exponencial entre os níveis de água médios mensais das estações de Óbidos e da Vila de Curuai de 1982 a 2016.



Fonte: Produção do autor.

#### 3.4.4 Dados climáticos ENSO

Os dados climáticos do El Niño e La Niña, que são componentes do fenômeno conhecido como Oscilação Sul do El Niño (ENSO), foram obtidos da NOAA. O Índice Niño Oceânico (ONI), expresso em graus Celsius (°C), quantifica as anomalias de temperatura no oceano Pacífico tropical relacionadas a esses eventos, classificando-os como Fracos, Moderados, Fortes ou Muito Fortes (Tabela 3.4) (NOAA, 2023). Esse índice é crucial para avaliar a potencial magnitude dos eventos ENSO e seus respectivos impactos (ENSO, 2023).

Tabela 3.4 – Intensidade ENSO: Índice Niño Oceânico (ONI).

ENSO / ONI (°C)	Fraco	Moderado	Forte	Muito Forte
<b>El Nino</b>	0,5 a 1,0	1,0 a 1,5	1,5 a 2,0	2,0 a 2,5
<b>La Nina</b>	-0,5 a -1,0	-1,0 a -1,5	-1,5 a -2,0	-2,0 a -2,5

Fonte: Produção do autor.

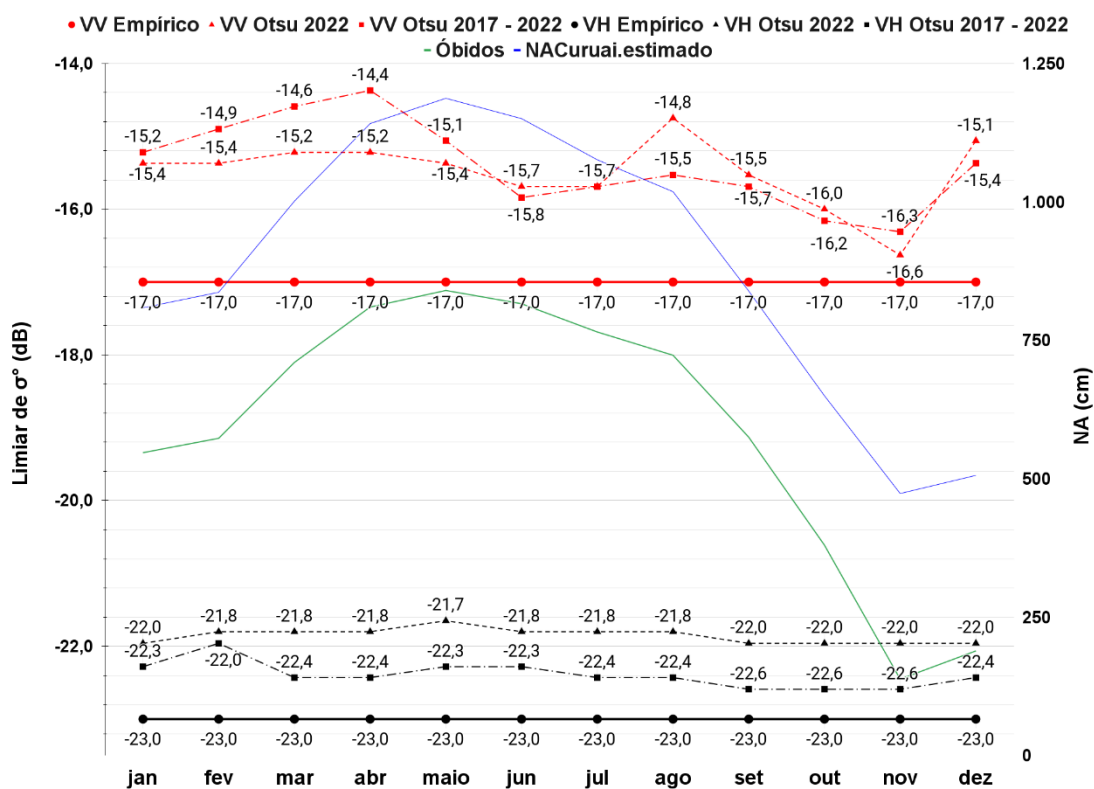


## 4 RESULTADOS E DISCUSSÕES

### 4.1 Limiarização

A Figura 4.1 indica que os limiares mensais obtidos por meio da aplicação dos três métodos variaram de -17,0 a -14,4 dB para a polarização VV e de -23,0 dB a -21,7 dB para a polarização VH. Além disso, fica evidente que os limiares Empíricos VV (-17 dB) e VH (-23 dB) apresentaram valores de  $\sigma^0$  muito menores do que os obtidos pelos métodos Otsu's (Otsu 2022 e Otsu 2017 - 2022).

Figura 4.1 – Limiares (Empíricos e Otsu's) e níveis de água em Óbidos e Curuai.



Fonte: Produção do autor.

Os limiares VV Otsu 2022 variaram de -16,6 a -14,8 dB, enquanto os limiares VV Otsu 2017 - 2022 variaram de -16,3 a -14,4 dB. Essas variações sugerem possíveis correlações com a sazonalidade hidrológica da planície do LGC. As flutuações significativas na extensão das inundações ao longo do ano hidrológico resultam em diferentes proporções de ambientes aquáticos e terrestres, como

AA, macrófitas, florestas inundadas e não inundadas, além de solo exposto ou com baixa biomassa (ARNESEN, 2012). Essas mudanças na cobertura podem ter uma influência substancial nos valores de  $\sigma^\circ$  registrados pelo sensor e, conseqüentemente, na variabilidade dos limiares Otsu's, devido às consideráveis modificações nas características geométricas e dielétricas das superfícies hídricas e terrestres ao longo do ano hidrológico. Além disso, a variabilidade dos valores de  $\sigma^\circ$  e, por conseguinte, dos limiares Otsu's também pode ocorrer devido à presença de nuvens carregadas, células de chuva e eventos atmosféricos em áreas específicas da extensa planície de inundação do LGC. Esses eventos atmosféricos têm o potencial de causar interferências na transmissão das micro-ondas na banda C (ALPERS et al., 2016) tanto atenuando como intensificando os valores de  $\sigma^\circ$ .

A análise da Figura 4.1, também indica que um elemento crucial no comportamento dos limiares mensais de  $\sigma^\circ$  VV Otsu de 2022 parece ser a rugosidade das águas abertas, dado que Arnesen (2012) e Furtado (2014) já haviam ressaltado a influência negativa da rugosidade da água no LGC sobre o mapeamento das superfícies hídricas, respectivamente, tanto em micro-ondas de banda L do sensor ALOS-2 quanto em banda C do Radarsat-2. Isso ocorre porque, a rugosidade de águas agitadas favorece a reflexão em todas as direções conforme a movimentação imposta pelas forças hidrodinâmicas provocadas pelo vento e pelo fluxo das águas superficiais, enquanto em águas calmas de microtopografia lisa, ocorre predominantemente a reflexão especular (SILVA et al., 2008; BARTSCH et al., 2012).

Águas sob a ação do vento tendem a gerar  $\sigma^\circ$  mais elevados do que os encontrados em águas calmas devido ao aumento da rugosidade da superfície, podendo até mesmo apresentar valores que se assemelham aos de alvos terrestres, dificultando assim a discriminação e a caracterização de diferentes tipos de cobertura por meio de imagens SAR (SCHUMANN et al., 2015). Em alguns casos, a intensa agitação das águas, causada, por exemplo, pela passagem de furacões, pode resultar em valores relativamente altos, a ponto de tornar as cenas SAR inviáveis para a aplicação (ZHANG et al., 2022).

O mapeamento de AA em condições de águas calmas é amplamente favorecido pelo uso de polarizações paralelas (HH e VV), conforme discutido na literatura. Essas polarizações proporcionam uma maior distinção em relação a outras classes com base nos valores de  $\sigma^\circ$ , devido à sua sensibilidade à rugosidade dos alvos (TWELE et al., 2016; SOMAN; INDU et al., 2020; ROSSI et al., 2023). Essa capacidade da polarização paralela é bastante útil para discriminar entre AA e NAA (ULABY et al., 1986; WHITE et al., 2015; ATCHYUTH et al., 2023). Em condições de águas agitadas submetidas a fatores que alteram a sua rugosidade, como é o caso das águas do LGC, as polarizações cruzadas (HV e VH) parecem ser mais apropriadas, pois geralmente são menos afetadas pela rugosidade da superfície da água. No entanto, é importante observar que esses aspectos ainda precisam ser mais bem investigados em estudos futuros.

Ao analisar o comportamento dos limiares VV Otsu's na Figura 4.1 em relação ao nível de água em Óbidos (NAÓbidos) e em Curuai (NACuruai.estimado), e considerando os padrões hidrológicos e geomorfológicos descritos na literatura, observam-se as seguintes constatações:

1) Houve um aumento nos limiares VV Otsu's nos meses de janeiro a abril, correspondentes à transição entre a enchente e a cheia, culminando nos limiares Otsu mais altos. Durante esse período, ocorrem variações acentuadas no NA, conforme previsto, devido à entrada de água do Rio Amazonas no LGC (BARBOSA, 2005). De fato, os fluxos de várzea durante as cheias são muito intensos, com entrada a montante e saída a jusante ao longo das várias unidades de várzea (FASSONI-ANDRADE et al., 2023), o que resulta no aparecimento de ondas na superfície da água aumentando sua rugosidade. O aumento de rugosidade, por sua vez, tende a causar elevados valores de  $\sigma^\circ$  (BARTSCH et al., 2012), refletindo-se seguramente em limiares Otsu's mais elevados.

Nos meses de março e abril, foram registrados os limiares VV Otsu's mais altos, coincidindo com maiores taxas positivas de elevação da estimativa do NACuruai.estimado. Além disso, os limiares VV desses dois meses (março e abril) estão compreendidos entre -15,2 e -14,4 dB, próximos do limiar VV fixo Otsu de -14,9 dB obtido em Moharrami et al. (2021). Nesse estudo, o método

Otsu foi aplicado para mapear águas agitadas durante um evento de inundação grave no Irã.

2) Os limiares VV Otsu's apresentaram um comportamento decrescente entre abril e junho, possivelmente devido ao menor estado de agitação das águas nesse período. Isso ocorre em razão da redução na intensidade dos fluxos entre o Rio Amazonas e os lagos e canais que compõem o LGC (BONNET et al., 2008; RUDORFF et al., 2014), resultando em superfícies de águas mais estáveis (lisas) e com menor  $\sigma^{\circ}$ . Durante esses meses do período de cheia, observam-se os valores mais elevados e estáveis de NACuruai. estimado, o que está alinhado com a hidrodinâmica sazonal desse período.

3) Entre julho e agosto, durante o período de vazante, observa-se um aumento nos valores dos limiares VV Otsu's. Isso pode ser justificado pelo maior estado de agitação (rugosidade) das águas abertas, resultante do fluxo de saída de água dos lagos para o canal do Rio Amazonas. Essa dinâmica está eventualmente relacionada ao que foi mencionado por Bonnet et al. (2008) e Fassoni-Andrade et al. (2023), que destacam que o escoamento máximo do LGC, através de vários canais conectados ao Rio Amazonas, ocorre durante os meses de agosto e setembro. Um ponto relevante é que, de acordo com Barbosa (2005), durante esse período de vazante, também podem ocorrer fluxos de entrada de água no LGC devido ao efeito de remanso. Esta condição aumenta a probabilidade de que o estado da água esteja agitado, contribuindo para o aumento nos dos limiares VV Otsu's.

4) Durante os meses de setembro e novembro, que assinalam o fim da vazante e todo o período de águas baixas, nota-se uma queda nos limiares VV em ambos os métodos Otsu's. Essa diminuição pode ser parcialmente explicada pela estabilidade das águas retidas em lagos profundos localizados em áreas de baixada, como o Lago Poção. Esses lagos, devido à sua localização em depressões em comparação com outros lagos mais rasos situados em terrenos mais elevados, podem ser menos afetados pelos ventos. No entanto, outro fator que parece contribuir para a redução dos limiares VV Otsu's durante setembro e novembro é a diminuição da disponibilidade hídrica local. Isso resulta em uma

menor constante dielétrica pelas superfícies lisas de baixo  $\sigma^\circ$ , como sedimentos argilo arenoso do substrato (fundo) dos lagos do LGC, devido à diminuição do nível das águas nesse período, o que está alinhado com os valores estimados do NACuruai. estimado.

5) Em dezembro, marcado pelo início do período de enchente e, portanto, pelo aumento dos fluxos de água provenientes do Rio Amazonas (águas agitadas) (BONNET et al., 2008), os limiares VV Otsu's voltam a subir, como o aumento da rugosidade da superfície de água.

Ao analisar os limiares VH Otsu's, observa-se que os valores estiveram no intervalo de -22,0 dB a -21,7 dB para o VH Otsu de 2022 e de -22,6 dB a -22,0 dB para o VH Otsu de 2017 a 2022. Os limiares VH Otsu's mostraram um comportamento bastante estável ao longo do ano hidrológico, em comparação com os limiares VV Otsu's. No entanto, ainda foi possível constatar que durante o período de águas baixas, entre os meses de setembro a novembro, foram registrados os menores valores dos limiares VH Otsu's. Isso pode estar relacionado ao fato de que a polarização VH é menos sensível à rugosidade dos alvos, quando comparada à polarização VV e, conseqüentemente, às diferentes condições hidrodinâmicas em estados variados de agitação das águas.

A agitação das AA, causada tanto pelo movimento do fluxo que escoar pela planície quanto pelo vento, faz com que sua superfície se torne rugosa. Isso, por sua vez, leva a um aumento nos valores de  $\sigma^\circ$  dessas superfícies. No entanto, devido à falta de instrumentos de medição, sistemas de monitoramento e informações detalhadas na literatura que descrevam os padrões de vento, fluxos hídricos de escoamento e ondas na região do LGC, é difícil determinar com precisão o impacto real da rugosidade no aumento dos valores de  $\sigma^\circ$ . Isso se torna ainda mais desafiador ao considerar diferentes comprimentos de onda e polarizações.

Ao empregar diferentes imagens mensais, os métodos Otsu's para VV e VH conseguem capturar de forma abrangente o impacto dos fatores que afetam o sinal de micro-ondas dos sensores SAR, incluindo as variações sazonais. Isso sugere que os limiares mensais Otsu's fornecem informações valiosas sobre a

sazonalidade hidrológica, além de revelar padrões hidrodinâmicos e atmosféricos em diferentes períodos.

Os limiares VV (-17 dB) e VH (-23 dB) obtidos pelo método Empírico se alinham com os valores de  $\sigma^0$  S1 utilizados para mapear AA e áreas inundáveis em diferentes várzeas amazônicas, os quais estão dentro do intervalo de -24,57 a -18,14 dB (VV) e -28,2 a -22,52 dB (VH) (MAGALHÃES et al., 2022). O valor -17 dB (VV) obtido pelo método VV Empírico neste trabalho para extrair AA, se mostrou eficaz em Ferreira (2018) no mapeamento de AA e áreas inundáveis no sul de Roraima, particularmente na região do baixo curso do Rio Branco. O limiar empírico de -23 dB (VH) está em consonância com o estudo de Tran et al. (2022), no qual foi observado que o intervalo de -23 a -21 dB, obtidos através do método Otsu aplicado a diferentes imagens, era adequado para a detecção de superfícies de água em campos de arroz no Delta do Mekong, no Vietnã.

Embora os valores dos limiares obtidos pelos métodos Empíricos e Otsu's estejam alinhados com os resultados de estudos realizados em diversas localidades, incluindo áreas inundadas amazônicas, conforme demonstrado nos trabalhos de Ferreira et al. (2018) e Magalhães et al. (2022). É importante notar que muitos estudos que utilizam imagens SAR para mapear áreas inundadas e AA não explicam completamente como são feitas as amostragens, tanto em termos de onde e quando exatamente são coletadas. Isso se aplica tanto às amostras usadas para definir os limiares empiricamente quanto às utilizadas na validação dos resultados. Essa falta de detalhes torna difícil entender como as amostras de AA são escolhidas e se os procedimentos fornecem dados que refletem com precisão a realidade. Esse problema é especialmente desafiador em áreas como as várzeas amazônicas, onde a hidrologia varia significativamente e há uma grande diversidade de vegetação, além de fatores atmosféricos e hidrodinâmicos que podem afetar os resultados.


Esses fatores contribuem para uma complexidade considerável na abordagem desse tipo de problema. Além disso, é relevante ressaltar a escassez de estudos que ofereçam uma série amostral abrangente no tempo e no espaço dos valores de  $\sigma^0$  do S1 das AA do Baixo Rio Amazonas, bem como uma descrição

detalhada das condições hidrodinâmicas e eólicas no momento da aquisição das imagens.

## 4.2 Acurácia das máscaras de água

A análise da acurácia global (AG) das máscaras mensais de água VV e VH da Figura 4.2 revela que, de janeiro a setembro, essa métrica é consistentemente alta, variando de 0,94 a 0,99. No entanto, de outubro a dezembro, os três métodos mostram maiores diferenças entre os valores de AG, especialmente para a polarização VH, que apresenta valores mais baixos em comparação com a polarização VV. Isso faz sentido, uma vez que na literatura a polarização VV é considerada melhor para distinguir entre alvos aquáticos e terrestres (WHITE et al., 2015; ATCHYUTH et al., 2023). E essa situação ocorre especialmente em outubro, durante o período de águas baixas, quando os valores de AG dos métodos baseados na polarização VH caem para aproximadamente 0,80, enquanto os métodos baseados na polarização VV permanecem iguais ou superiores a 0,96.

Figura 4.2 – Acurácia global mensal dos métodos empregados.



Fonte: Produção do autor.

Na Figura 4.2, observa-se que as máscaras geradas pelos métodos Empíricos apresentam uma pequena vantagem em termos de AG em comparação com aquelas produzidas pelos métodos Otsu's. Essa diferença é mais destacada na polarização VV entre setembro e dezembro, durante a transição da vazante para a enchente. Durante esse período, ocorrem variações significativas nos níveis de água, o que resulta no aumento de áreas com superfícies rugosas, causadas pelos fluxos hídricos intensos, condições típicas da vazante e da enchente.

Durante os períodos de águas baixas, quando os NA diminuem, surgem grandes extensões de áreas de superfícies lisas de leitos de lagos expostos e de bancos de areia. Essas variações nos NA podem ser significativas, às vezes até sete metros (BARBOSA, 2005), e podem expor margens íngremes que delimitam os diferentes lagos que compõem o grande LGC formado durante a cheia. Essas quebras de topografia podem causar sombras nas imagens SAR, resultando em áreas escuras (áreas de baixo  $\sigma^0$ ), ou em algumas situações, podem causar reflexões de canto (áreas de alto  $\sigma^0$ ), dependendo de sua orientação em relação à antena (JENSEN, 2007; SCHUMANN et al., 2015; WOODHOUSE, 2017). Essas duas possibilidades podem levar a erros na classificação entre as classes AA e NAA, resultando em uma redução dos valores de AG.


Ao examinar o desempenho da métrica de sensibilidade (S), isto é, a habilidade de identificar corretamente AA (Figura 4.3), observam-se variações de 0,90 a 0,99 para VV e de 0,61 a 0,99 para VH, o que sugere maior eficácia nos métodos baseados em VV, especialmente no VV Empírico, que se destacou com os valores mais altos e estáveis de S.

Os valores mais elevados de S, aproximando-se de 1 (Figura 4.3), foram observados em junho (cheia) para todos os métodos. Por outro lado, os valores mais baixos de S (0,61 a 0,66) foram registrados em outubro, durante o início do período de águas baixas, especialmente com os métodos baseados em VH. Isso sugere que, neste mês específico, áreas de superfícies lisas com baixo  $\sigma^0$ , como bancos de areia e solos expostos ou de baixa biomassa, foram erroneamente identificadas como AA, devido à semelhança nos valores de  $\sigma^0$  na polarização



cruzada VH. Essas observações são consistentes com estudos anteriores (FURTADO, 2014; SANTORO et al., 2015; ATCHYUTH et al., 2023).

Figura 4.3 – Sensibilidade mensal dos métodos empregados.



Fonte: Produção do autor.

Durante o período de águas baixas (outubro, novembro e dezembro), observam-se valores menores de S (Figura 4.3). Isso confirma o que foi discutido na seção 4.1 (Limiarização), que durante essa fase há uma maior variedade de cobertura. Isso abrange tanto superfícies terrestres lisas (sedimentos expostos devido à diminuição do NA) quanto superfícies hídras rugosas (especialmente AA em lagos rasos de várzea, onde a rugosidade aumenta devido ao vento mais intenso entre setembro e janeiro). Essa diversidade possivelmente contribui na maior ocorrência de erros na classificação entre áreas de águas abertas (AA) e áreas que não são águas abertas (NAA).


Por outro lado, durante o período de cheia (abril, maio e junho) e os meses de NA mais elevados (junho e julho), observa-se um aumento nos valores de S (Figura 4.3). Nesse período predominam dois tipos de alvos, os com elevado valor de  $\sigma^0$ , como a vegetação, e de alvos de baixo  $\sigma^0$ , como as superfícies de águas calmas ou menos rugosas. Isso ocorre devido à redução dos fluxos de

entrada e saída de água na várzea. Assim, há um maior contraste de  $\sigma^0$  entre esses alvos, o que certamente contribui para uma melhor discriminação entre AA e NAA e, conseqüentemente, para valores mais altos de S.

No geral, ao analisar as métricas mensais de S, verifica-se que os métodos Empíricos são ligeiramente superiores aos métodos Otsu's, tanto na polarização VV quanto na VH (Figura 4.3). Isso parece ocorrer porque os métodos Empíricos se baseiam em apenas no valor de limiar extraído de uma única data de imagem, o que reduz a influência dos fatores ambientais (hidrológicos e atmosféricos) sobre o sinal de micro-ondas registrado. Esse padrão é mais evidente ao se analisar os métodos VH Otsu's entre os meses de outubro e dezembro, que é o período compreendido entre as águas baixas e o início da enchente.

No que se refere à especificidade (E), que neste caso é a capacidade de identificar corretamente áreas que não são cobertas por AA (Figura 4.4), nota-se que ela variou de 0,94 a praticamente 1 para ambas as polarizações.

Figura 4.4 – Especificidade mensal dos métodos empregados.



Fonte: Produção do autor.

Esse intervalo (0,94 – 1) é menor do que o observado para a S, que variou de 0,61 a 0,99. Isso sugere que o principal desafio desses métodos está relacionado


à S, ou seja, à identificação precisa de AA, especialmente nos meses de águas baixas (outubro a dezembro), quando ocorrem os menores NA.

### **4.3 Avaliação visual das máscaras de água**

Além da eficácia dos métodos Empíricos, em termos de métricas de acurácia, esses métodos também se demonstraram adequados para representar com precisão as áreas de AA a partir da superposição das máscaras de água às respectivas imagens mensais S1 e S2 (Tabela 3.1). Por outro lado, os métodos Otsu's tenderam a superestimar a classe de AA, ao identificar erroneamente superfícies lisas como sedimentos expostos. Esse problema é amplamente relatado na literatura e, neste trabalho, ocorre principalmente nos métodos Otsu's para a polarização VH durante o período de águas baixas, quando esses tipos de alvos são mais comuns. Isso pode ser observado na Figura 4.5 do mês de outubro, que mostra a melhor máscara de água (VV Empírico) e a pior (VH Otsu 2022) para o dia 01/10/2022. É importante salientar que a imagem em composição RGB colorida é afetada pelo espalhamento de luz solar, o que resulta em cores e tons mais claros e ligeiramente difusos (Figura 4.5).

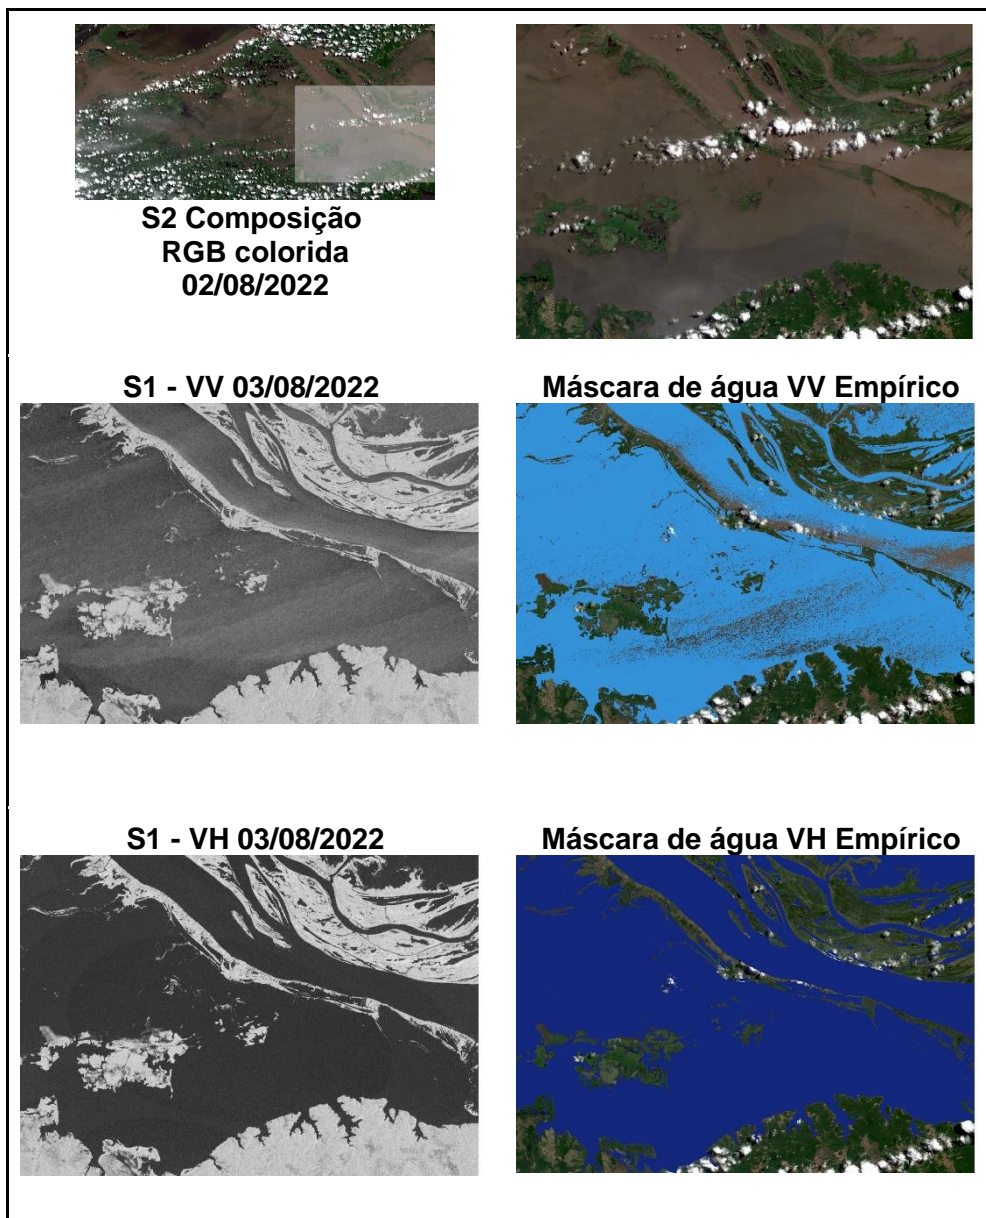
As máscaras de água produzidas pelo método VV Empírico (-17 dB) foram as que melhor representaram visualmente as AA ao longo do LGC ao longo do tempo. No entanto, em áreas de águas agitadas devido ao vento ou a fluxos intensos, as superfícies apresentaram maior rugosidade (valores de  $\sigma^{\circ}$ ), o que resultou em manchas dispersas na máscara gerada pelo método VV Empírico, tornando visível a imagem óptica S2 do dia 02/08/2022 (Figura 4.6). Nessas condições, o método VH Empírico (-23 dB) foi mais eficaz em identificar as AA, pois essas manchas dispersas praticamente não foram observadas na máscara de água gerada pelo método VH Empírico.

Figura 4.5 – Imagens de solos expostos classificados incorretamente.



Fonte: Produção do autor.

Figura 4.6 – Imagens de águas agitadas classificadas incorretamente.



Fonte: Produção do autor.

A avaliação visual das máscaras mensais de água geradas pelos três métodos revelou uma limitação no mapeamento das bordas, bem como de canais estreitos com largura inferior a aproximadamente 70 metros. Esse tipo de erro pode ser atribuído à incapacidade do sensor em capturar essas superfícies de água devido ao desnível topográfico entre o nível da água e as margens dos canais, devido à presença de quebras abruptas de relevo ou estarem ocupadas por florestas que podem causar reflexões superficiais, volumétricas ou de dupla-




rebatida nas áreas de interfaces hídricas e terrestres (SCHUMANN et al., 2015; MCCORMACK et al., 2021; CHEN; ZHAO, 2022).

Em consonância com as métricas de acurácia, a análise visual das máscaras mensais corroborou com a escolha do método Empírico, por ser o método mais adequado em comparação com os métodos Otsu's. Desta forma, ele foi empregado na criação das séries temporais de AA entre 2017 e 2022.

#### 4.4 Precipitação média acumulada mensal e anual

Os dados de precipitação foram utilizados para investigar possíveis relações sazonais com os padrões atmosféricos e terrestres do LGC. Para iniciar essa análise, foram examinadas as distribuições das taxas de precipitação média acumulada mensal e anual ao longo do tempo (Figura 4.7).

Figura 4.7 – Precipitação média acumulada mensal e anual.



As colunas contornadas em vermelho representam as taxas de precipitação superiores a 300 mm, enquanto aquelas contornadas em preto denotam taxas de precipitação inferiores a 100 mm. O retângulo verde inclui a precipitação acumulada dos meses de janeiro a abril de 2022, totalizando 1358 mm.

Fonte: Produção do autor.

Identificou-se que os períodos consecutivos de menores taxas de precipitação acumulada mensal (inferiores a 100 mm e até 26% superiores a este valor, contornadas em preto) ocorreram, respectivamente, nos anos e períodos: 2017

(agosto a novembro), 2018 e 2021 (agosto a outubro), 2019 e 2020 (junho a outubro), 2021 (agosto a outubro) e 2022 (julho a novembro). Desta forma, para os seis anos analisados, o período de junho a novembro compreende os meses de menores taxas de precipitação. Isso sugere que nesse período as imagens estão menos sujeitas a influências atmosféricas sobre os valores de  $\sigma^\circ$  devido à provável menor frequência de nuvens carregadas e células de chuva sobre a área do LGC. Essa observação está em consonância com os registros dos menores valores de limiares de Otsu para VV e VH, ocorrendo entre junho e novembro (Figura 4.1).


Por outro lado, as maiores taxas de precipitação (similares ou até 50% superiores a 300 mm, contornadas em vermelho) foram registradas, respectivamente, nos anos e meses: 2017 (janeiro, fevereiro e março), 2018 (fevereiro, abril e dezembro), 2019 (fevereiro, março e maio), 2020 (fevereiro, março, abril e maio), 2021 (fevereiro e março) e 2022 (janeiro, fevereiro e março). Dessa forma, o período de maiores taxas de precipitação ocorre entre janeiro e maio, o que coincide com o padrão identificado por Bonnet et al. (2008) ao analisarem dados pluviométricos da estação do LGC entre os anos de 1970 a 2007. Bonnet et al. (2008) observaram que os meses de chuvas mais intensas geralmente são em fevereiro e abril. Segundo esses autores, a precipitação média acumulada obtida considerando esse intervalo de anos foi de 1800 mm. No entanto, em relação aos dados fornecidos pelo CHIRPS, que integra informações de precipitação de satélites da NASA e da NOAA, utilizados neste estudo, os valores registrados foram os seguintes: 1917 mm em 2017, 2112 mm em 2020, 2176 mm em 2019, 2205 mm em 2018, 2354 mm em 2021 e 2414 mm em 2022. Para compreender as razões por trás dessas disparidades, seria necessário realizar análises e investigações abrangendo aspectos meteorológicos, climáticos, instrumentais e metodológicos.

#### **4.5 Nível de água estimado para Curuai**

Ao analisar os valores de  $NAC_{Curuai}$  estimado para o período de janeiro de 2017 a dezembro de 2022 (Figura 4.8), observou-se que os maiores valores ocorreram em maio, destacando-se os anos de 2021 (31/05/2021) e 2022 (15/05/2021), que

atingiram aproximadamente 1200 cm. Por outro lado, os menores valores foram registrados em novembro, especificamente no ano de 2020 (10/11/2020), com cerca de 430 cm. Esses padrões de variação, tanto nos valores máximos quanto nos mínimos, estão de acordo com o que é descrito na literatura para o LGC (ARNESEN, 2012; RUDORFF et al., 2014; FASSONI-ANDRADE et al., 2023).

Figura 4.8 – Níveis de água estimados em Curuai.



Fonte: Produção do autor.


#### 4.6 Séries temporais de águas abertas

A análise das séries temporais de águas abertas (STAA) para as polarizações VV (STAAVV) e VH (STAAVH) no LGC entre 2017 e 2022 (Figura 4.9), utilizando o método Empírico, revelou que as STAAVH são geralmente mais consistentes e exibem maiores extensões em comparação com as STAAVV. Em determinados períodos, entre os meses de abril e outubro, houve ocasiões em que as extensões registradas nas STAAVV excederam as registradas nas STAAVH em até 15 km<sup>2</sup>. Além disso, observou-se que as extensões máximas de AA considerando a polarização VH geralmente ocorrem entre o final de junho e a primeira metade de julho, alcançando valores próximos a 1500 km<sup>2</sup>, com destaque para o máximo histórico de 1473 km<sup>2</sup> em 21 de junho de 2021. Por outro lado, os valores mínimos das AA considerando a polarização VH



normalmente ocorrem entre a segunda semana de novembro e a primeira semana de dezembro, destacando-se o mínimo histórico de 515 km<sup>2</sup> em 29 de novembro de 2020. Estes resultados estão de acordo com a literatura relacionada à ocorrência de eventos extremos de estiagem em 2020 (CAI et al. 2020) e de inundação em 2021 (CEMADEN, 2021), respectivamente.

Figura 4.9 – Séries temporais VV e VH entre 2017 e 2022.



Fonte: Produção do autor.

#### 4.7 Análise do impacto dos fatores atmosféricos, meteorológicos e hidrológicos na acurácia das águas abertas


Analisando de forma mais detalhada o padrão sazonal das métricas de acurácia, das máscaras de água e das taxas de precipitação mensais e anuais na região do LGC, foram identificadas duas situações importantes:

1) As máscaras de água VH e VV Otsu's, assim como a VH Empírica (-23 dB) de abril, revelaram uma menor eficácia na identificação de AA, evidenciada por seus valores menores de S em comparação com os meses anteriores (março) e posteriores (maio) (Figura 4.3). Este fenômeno parece estar fortemente relacionado à formação de áreas inundáveis e alagadas típicas deste período de cheia, bem como lâminas de água em áreas de solos úmidos, e devido ao acumulado significativo de precipitação de 1358 mm de janeiro a abril de 2022

no LGC, conforme indicado no retângulo verde da Figura 4.7. A interligação das massas de água de áreas inundadas, alagadas e de AA pode intensificar o estado de agitação das águas, levando a erros de mapeamento associados à classificação de águas agitadas como NAA. Por outro lado, a máscara de água de abril com o valor mais alto de S, ou seja, aquela que se mostrou mais eficaz na identificação de AA, foi a gerada pelo método VV Empírico (-17 dB), possivelmente devido à sua maior eficiência em evitar a classificação incorreta de áreas inundadas ou alagadas como AA.

2) A máscara de água VV Empírico do mês de maio foi significativamente impactada pela presença de nuvens carregadas, células de chuva e provavelmente águas agitadas (Figura 4.10), como evidenciado pelas numerosas lacunas visíveis, enquanto a máscara de água VH Empírico do mesmo mês praticamente não foi afetada, uma situação semelhante àquela observada para as máscaras VV e VH Empírico do mês de outubro (Figura 4.6). Isso está em consonância com o que foi observado por Alpers et al. (2016), onde foi constatado que a polarização paralela VV é mais suscetível a tais eventos atmosféricos do que a polarização cruzada VH. Nesse caso específico, o aumento nos valores de  $\sigma^\circ$  das áreas sob a influência de nuvens carregadas e células de chuva resultou na classificação dessas áreas como NAA, pois seus valores de  $\sigma^\circ$  excederam o limiar VV Empírico (-17 dB).

Figura 4.10 – Máscaras de água afetadas por nuvens carregadas e células de chuva.




Fonte: Produção do autor.

Os valores das métricas estatísticas neste caso específico (23/05/2022) parecem não fazer muito sentido (VV Empírico: OA = 0,99; S = 0,99; E = 0,99 e VH Empírico: OA = 0,98; S = 0,96; E = 0,99), pois na própria seleção das amostras (pixels) mensais do mês de maio podem ter sido introduzidos erros devido à grande variabilidade nos valores de  $\sigma^{\circ}$  na cena. Isso sugere que, em tais condições, o processo de validação pode não ser válido.

#### 4.8 Relação entre as águas abertas e os dados climáticos

A análise dos dados de STAAVV e STAAVH do LGC (Figura 4.11), em conjunto com os registros climáticos, revela relações interessantes. A primeira delas é que o período de El Niño Fraco (2018, 2019 e 2020) parece ter exercido um impacto significativo durante o ano hidrológico no LGC, resultando em menores extensões de AA, reflexo de uma menor precipitação à montante (MARENGO; ESPINOZA, 2015; GARCIA et al., 2018; CAI et al., 2020; FASSONI-ANDRADE et al., 2023). Por outro lado, é provável que o La Niña Moderado/Forte (2020, 2021 e 2022) contribuiu para as maiores extensões de AA registradas em 2021 e 2022, como resultado de uma maior precipitação a montante (BARICHIVICH et al., 2018; CEMADEN, 2021).

Figura 4.11 – Relação entre as extensões de águas abertas e os eventos ENSO.




Fonte: Produção do autor.

## 4.9 Águas abertas de 2022

A Figura 4.12 ilustra as séries temporais STAAVH (em vermelho) e STAAVV (em preto), bem como as diferenças entre ambas ( $\Delta$ STAA = STAAVH - STAAVV) (em roxo) no LGC ao longo do ano de 2022, obtidas por meio do método Empírico. Os valores das AA destacados em negrito foram derivados das imagens S1 de 2022, as quais foram utilizadas na determinação dos limiares empíricos (conforme indicado na Tabela 3.1).

Figura 4.12 – Séries temporais de superfícies de águas abertas de 2022.



Fonte: Produção do autor.

A análise da Figura 4.12 revela pelo menos três aspectos interessantes:

1) As variações abruptas das extensões de AA, sobretudo nas STAAVV em datas específicas (marcadas por asteriscos): 05/04/2022, 29/04/2022, 23/05/2022, 28/06/2022 e 03/08/2022, estão associadas à presença de nuvens carregadas, células de chuva e águas agitadas nas respectivas imagens S1.

Esses padrões de variações abruptas em 2022, resultado dos eventos atmosféricos e hidrodinâmicos mencionados, também se mostram recorrentes ao longo dos diferentes anos (Figura 4.9), principalmente entre o final do período de enchente (fevereiro e março) e o início da vazante (agosto). Isso sugere uma maior incidência sazonal de nuvens carregadas, células de chuva, forças hidráulicas e eólicas (águas agitadas), bem como condições hidrológicas, concorrendo para a subestimação da extensão de AA nas máscaras de água geradas pelo método VV Empírico (-17 dB).

2) Apenas duas ocasiões foram observadas em 2022 em que os valores das STAAVV foram levemente superiores aos das STAAVH, respectivamente, 4 km<sup>2</sup> em 04/06/2022 e 5 km<sup>2</sup> em 16/06/2022. Ambas as datas ocorreram durante o período de cheia, marcado pelas maiores extensões registradas, momento em que ocorre um maior equilíbrio entre os fluxos de entrada e saída no LGC (BONNET et al., 2008).

3) Entre setembro (vazante) e dezembro (águas baixas) de 2022, os maiores valores das  $\Delta$ STAA são registrados (conforme mostrado na Figura 4.12). Isso parece ser principalmente atribuído à classificação incorreta de AA pelo método Empírico VH, que inclui áreas com baixo  $\sigma^\circ$  como sendo AA. Por exemplo, sedimentos expostos do fundo dos lagos do LGC e áreas de baixa densidade vegetal, geralmente presentes durante o período de águas baixas (outubro, novembro e dezembro) (BARBOSA, 2005; FURTADO, 2014). As duas maiores  $\Delta$ STAA entre os períodos de vazante e águas baixas ocorreram em outubro, mais especificamente em 14/10/2022 (163 km<sup>2</sup>) e 26/10/2022 (205 km<sup>2</sup>). Essas constatações são apoiadas pela análise visual da imagem RGB S2 de 01/10/2022 e das máscaras de águas de 02/10/2022 (Figura 4.5), e também pela observação dos menores valores das métricas estatísticas de S entre outubro e dezembro (Figuras 4.3). Além disso, essa tendência de registro de maiores valores de  $\Delta$ STAA entre setembro e dezembro também é verificada nos demais anos, já que são perceptíveis o distanciamento entre as linhas das STAAVH e das STAAVV (Figura 4.9).

Esses três aspectos sugerem que a análise sazonal das STAA pode ser aplicado para inferir diferentes condições atmosféricas, hidrodinâmicas e hidrológicas, sendo, portanto, útil para: i) identificar datas e períodos com maior incidência de nuvens carregadas, células de chuva, forças hidráulicas e eólicas, bem como maiores extensões de solos expostos ou de baixa densidade vegetal; ii) determinar datas em que ocorreram as extensões máximas e mínimas de AA; e iii) analisar tendências hidrológicas a partir das STAAVH, já que estas são mais estáveis e consistentes ao longo do tempo.

Atualmente, são poucos os estudos que exploram análises de STAA utilizando técnicas de limiarização SAR banda C nas polarizações VV e VH. No entanto, é plausível que esses estudos se tornem mais frequentes no futuro, considerando os sinais recorrentes de intensificação das mudanças climáticas e o aumento da ocorrência de eventos extremos. Isso ressalta a necessidade crescente desse tipo de análise. Além disso, a continuação da missão S1 com o satélite Sentinel-1C (S1C), prevista para 2024, possibilitará a geração de STAA mais longas, tornando a metodologia de limiarização utilizada, ainda mais útil. Isso, por sua vez, contribuirá significativamente para a caracterização e avaliação da severidade dos impactos de inundações e estiagens em áreas de várzea amazônica.


#### **4.10 Relações entre os níveis de água estimados em Curuai e as séries temporais de águas abertas**

Com o objetivo de investigar as relações entre os níveis mensais estimados de água de Curuai (NACuruai.estimado) e as STAA nas polarizações VV (STAAVV) e VH (STAAVH), foram realizadas análises de regressão (Figuras 4.13 e 4.14). Obteve-se o melhor ajuste com um modelo exponencial com valores de  $R^2$  de 0,745 (NACuruai.estimado versus STAAVV) e 0,776 (NACuruai.estimado versus STAAVH).

A forma das duas distribuições (histereses) (Figuras 4.13 e 4.14), reflete uma ampla variação ao longo do tempo, abrangendo não apenas a variabilidade sazonal típica das hidrógrafas, mas também variações interanuais entre 2017 e 2022, atribuídas à dinâmica climática, incluindo eventos marcantes, como a

estiagem entre 2019 e 2020 (El Niño) e as inundações de 2021 e 2022 (La Niña). A análise dessas relações em cenários mais específicos, que considerem escalas temporais, como períodos de intensidade de eventos climáticos (conforme o índice ONI), análises mensais ou diferentes períodos hidrológicos (enchente, cheia, vazante e águas baixas), pode resultar em um melhor ajuste na modelagem da variabilidade hidrológica nessas condições, contribuindo para a identificação, avaliação e projeção de cenários futuros no contexto do LGC.


Figura 4.13 – Regressão entre os níveis de água estimados em Curuai e as séries temporais de águas abertas de polarização VV.



Fonte: Produção do autor.

Figura 4.14 – Regressão entre os níveis de água estimados em Curuai e as séries temporais de águas abertas de polarização VH.



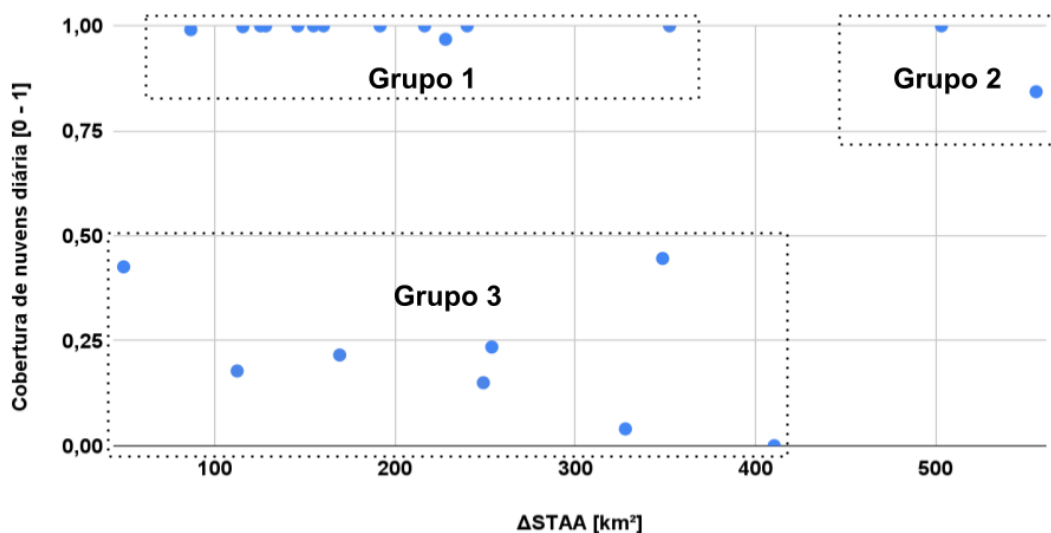


Fonte: Produção do autor.

#### 4.11 Relações entre séries temporais de águas abertas (VV e VH) e cobertura de nuvens

Dadas as discontinuidades observadas na série temporal de STAAVV de 2022 entre janeiro e setembro (Figura 4.12), as quais são causadas pela presença predominante de nuvens carregadas, células de chuva e águas agitadas, resultando em valores esporádicos relativamente altos de  $\Delta STAA$ , foi realizada uma análise para investigar a relação entre esses valores de  $\Delta STAA$  e os dados diários de cobertura de nuvens no mesmo dia da passagem do S1 entre janeiro e setembro para o período de 2017 a 2022 (Figura 4.15).

Figura 4.15 – Análise da relação entre os dados de cobertura de nuvens e séries temporais de águas abertas.



Fonte: Produção do autor.

Ao analisar a Figura 4.15, a primeira observação notável é a presença de três grupos distintos:

O Grupo 1 exibe uma série de pontos com densa cobertura de nuvens e valores de  $\Delta$ STAA variando de 87 a 240. Isso representa, em termos relativos, entre 5% e 15% da extensão máxima das águas abertas do LGC, que é de aproximadamente 1500 km<sup>2</sup> o que indica que a cobertura de nuvens nessas datas específicas não é um bom indicador da presença de células de chuva e não interferiu no mapeamento das AA, possivelmente porque essas nuvens podem não estar associadas a nuvens carregadas e/ou células de chuva.

Portanto, além de considerar a cobertura de nuvens e sua sazonalidade, é crucial analisar aspectos como o tipo de nuvem, fatores ambientais, tipos de aerossóis, estabilidade atmosférica, temperatura da cobertura de nuvens e a probabilidade de conversão em precipitação. Isso seria fundamental para uma previsão precisa de se as nuvens estão associadas a nuvens carregadas e/ou células de chuva (TOKAY; SHORT, 1996; SOROOSHIAN et al., 2013). Um estudo aprofundado que integre essas informações seria de grande valor para entender a possibilidade ou probabilidade de as imagens de banda SAR S1 serem influenciadas negativamente por estes eventos atmosféricos.

No entanto, o Grupo 2, composto por dois registros, destaca-se por apresentar não apenas uma densa cobertura de nuvens (0,84 e 1), mas também valores altos de  $\Delta$ STAA (503 e 556), cobrindo cerca de um terço da área do LGC. Isso sugere uma forte associação com eventos significativos de nuvens carregadas e células de chuva, possivelmente relacionados também a águas agitadas.

Por fim, o Grupo 3 mostra registros com cobertura de nuvens variando de 0 a 0,5 e  $\Delta$ STAA de 49 a 410. Em tais datas, o  $\Delta$ STAA parece estar relacionado a processos hidráulicos e hidrodinâmicos que, resultam em maior rugosidade da superfície das águas.


Embora essas análises façam sentido, são apenas hipóteses que precisariam ser validadas caso ambas as variáveis fossem obtidas de forma síncrona. No entanto, devido à diferença de aproximadamente uma hora entre a aquisição dos dados de  $\Delta$ STAA (09:23 da manhã) e cobertura de nuvens (10:30 da manhã), não se pode afirmar se houve variações consideráveis na cobertura e tipo de nuvem. Portanto, o uso de dados síncronos poderia fornecer uma base mais sólida para análises e inferências mais precisas sobre a relação entre as duas variáveis. Outro ponto importante a ser considerado é que a  $\Delta$ STAA pode não ser a melhor variável para análise em conjunto com a cobertura de nuvens, independentemente de serem síncronas ou quase síncronas.

#### **4.12 Relações entre séries temporais de águas abertas (VV e VH) e as taxas de precipitação diárias**

Durante os meses de setembro a novembro, observa-se um aumento significativo de áreas com sedimentos e solos expostos, ou densidade vegetal baixa, devido à redução do nível da água no LGC. Essas áreas, quando têm baixo teor de umidade (HENDERSON; LEWIS, 1998; BENNINGA et al., 2019), frequentemente exibem valores de  $\sigma^\circ$  próximos àqueles observados em superfícies de águas. Isso pode levar a uma superestimação de AA, especialmente pelo método VH Empírico. No entanto, quando essas áreas possuem alto teor de umidade (WOODHOUSE, 2017; PARADELLA et al., 2021), esse problema tende a ser atenuado, pois os valores de  $\sigma^\circ$  tendem a ser mais

elevados, não causando o aumento da contabilização das AA. Diante dessa perspectiva, optou-se por investigar a relação entre os valores de  $\Delta\text{STAA}$  e as taxas de precipitação para esse período específico (Figura 4.16).

Figura 4.16 – Análise da relação entre os dados de precipitação diária e séries temporais de águas abertas.



Fonte: Produção do autor.

Um aspecto notável na Figura 4.15 foi a presença dos maiores valores de precipitação média acumulada, que excederam 250 mm, em uma área com uma diferença máxima de apenas 171 km<sup>2</sup> de  $\Delta\text{STAA}$  (11 %). Isso sugere que parte desses valores de precipitação diária cumulativa anterior à passagem do S1 pode contribuir para um mapeamento mais consistente de AA com os métodos VV e VH Empíricos durante os meses de setembro a novembro. Nesse período, observam-se maiores extensões de solos expostos, cujo teor de umidade mais elevado (e, conseqüentemente, uma maior constante dielétrica) aumenta o potencial de um mapeamento correto. No entanto, como os dados se referem à precipitação diária cumulativa e não fornecem informações sobre as taxas horárias específicas de acordo com os satélites NOAA e NASA que compõem a metodologia CHIRPS, não é possível confirmar essa hipótese. Além disso, em 98,4% das cenas analisadas, as variações na precipitação entre 0 e 250 mm estão associadas a variações de  $\Delta\text{STAA}$  entre 0 e 500 km.

## 5 CONCLUSÃO

Os resultados desta pesquisa sugerem que as máscaras de água geradas pelos métodos Empíricos são mais adequadas a estudos hidrológicos quando comparadas às máscaras geradas pelos métodos Otsu's testados. O método Empírico apresentou métricas mensais de acurácia mais altas bem como a delimitação visualmente mais fiel ao contato água aberta/terrenos emersos. Especial destaque é dado ao método Empírico VV (-17 dB), que apresentou melhores métricas de acurácia ao longo do tempo. No entanto, é importante ressaltar que este método tende a ser eficaz apenas quando as imagens SAR S1 são adquiridas sem a presença de nuvens carregadas, células de chuva e águas agitadas. Como essas condições se mostraram frequentes na região do LGC, isso inviabilizou seu uso em séries temporais.

Por outro lado, o método Empírico VH (-23 dB) oferece maior consistência interanual com a STAAVH, dado que a polarização VH é menos influenciada pela presença de nuvens carregadas, células de chuva e pela rugosidade da água originada pelas forças hidrodinâmicas ao longo do tempo. No entanto, é importante notar que as máscaras geradas por este método, especialmente durante os meses de outubro e novembro, podem superestimar a extensão de AA devido à classificação incorreta como AA, de alvos como sedimentos do fundo dos lagos e solos expostos em suas margens, e áreas de baixa densidade vegetal com a redução do nível da água. Apesar desse inconveniente, o método Empírico VH mostrou-se uma ferramenta extremamente valiosa, especialmente devido à sua consistência sazonal e à coerência de sua série temporal (STAAVH) com os eventos climáticos ENSO.

No contexto apresentado, as STAAVH emergem como uma ferramenta para a caracterização, representação dos padrões hidrológicos sazonais, interanuais e climáticos e interpretação de seu impacto sobre a provisão de recursos ecossistêmicos a longo prazo. Além disso, elas têm o potencial de estimular a realização de análises relacionadas ao início, término e duração de eventos extremos de inundação e estiagem. Essas informações são particularmente

relevantes, dada a escassez desses tipos de dados, tanto em nível regional quanto na bacia Amazônica como um todo.

Outro aspecto fundamental é que as máscaras de água derivadas dos métodos VV e VH Empíricos poderiam contribuir para programas de monitoramento e ações da defesa civil em regiões remotas da várzea Amazônica, oferecendo dados atualizados com base em uma data específica, em contraste com as máscaras provenientes de imagens ópticas de diferentes datas, como Landsat e Sentinel-2, disponíveis em plataformas e metodologias de iniciativas como *Brazil Data Cube*, *MapBiomas*, *Global Surface Water Explorer*, *Worsica*, *Dynamic World* e *Dynamic Surface Water Extent*.

A investigação sobre o papel da cobertura de nuvem durante a aquisição das imagens SAR como fator explanatório das discontinuidades da STAAVV observadas entre janeiro e setembro, utilizando a diferença entre as STAA ( $\Delta STAA = STAAVH - STAAVV$ ), mostrou-se inadequada. Da mesma forma, a precipitação média acumulada diária também não explica de forma adequada a  $\Delta STAA$ .

Isso sugere que os dados utilizados nesta pesquisa não foram bons indicadores da qualidade das máscaras de água nem das condições atmosféricas e/ou ambientais durante a aquisição das imagens Sentinel-1. Esse resultado pode ser atribuído a dois aspectos principalmente que precisam ser mais bem avaliados em estudos futuros: a falta de sincronização entre a passagem do sensor MODIS a bordo do satélite Terra e a do S1, e diferença de resolução entre o sensor MODIS e SAR S1. O MODIS com a resolução espacial 100 vezes maior que a do sensor SAR S1, fornece uma cobertura de nuvem generalizada. Uma abordagem mais promissora poderia ser o uso de dados diários de cobertura de nuvens e precipitação provenientes de radares meteorológicos instalados no LGC ou de imagens de satélite com melhor resolução espacial, sincronizados com o horário de imageamento do S1. Isso poderia resultar em correlações mais precisas e fornecer uma indicação da qualidade das máscaras de água geradas pelos métodos VV e VH Empíricos, permitindo uma estimativa dos erros de

classificação associados. Isso seria útil já que os dados S1 geralmente são disponibilizados até 48 horas após o imageamento.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ADELI, S. et al. Wetland monitoring using SAR data: a meta-analysis and comprehensive review. **Remote Sensing**, v. 12, n. 14, p. 2292, 2020.
- ALSDORF, D. et al. Seasonal water storage on the Amazon floodplain measured from satellites. **Remote Sensing of Environment**, v. 114, n. 11, p. 2448-2456, 2010.
- AMANI, M. et al. Google Earth Engine cloud computing platform for remote sensing big data applications: a comprehensive review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 6255-6267, 2020.
- AMORIM, M. A. et al. Origem e dinâmica da deposição dos sedimentos superficiais na Várzea do Lago Grande de Curuai. **Acta Amazonica**, v. 39, n. 1, p. 165-172, 2009.
- ANGELIS, C. F. et al. ERS-1 multitemporal backscatter analysis of different types of land cover in Brazilian Amazonia. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2001. **Proceedings... IEEE**, 2001.
- ARNESSEN, A. S. et al. Monitoring flood extent in the lower Amazon River floodplain using ALOS/PALSAR ScanSAR images. **Remote Sensing of Environment**, v. 130, p. 51-61, 2013.
- ASNER, G. P. Cloud cover in Landsat observations of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 2, p. 385-388, 2001.
- ATCHYUTH, B.; SWAIN, R.; DAS, P. Near real-time flood inundation and hazard mapping of Baitarani River Basin using Google Earth Engine and SAR imagery. **Environment Monitoring and Assessment**, v.195, e1331, 2023.
- AUGUSTO-SILVA, P. B. et al. Stratification and mixing in large floodplain lakes along the lower Amazon River. **Journal of Great Lakes Research**, v. 45, n. 1, p. 179-189, 2019.
- BARBOSA, C. C. F. **Sensoriamento remoto da dinâmica da circulação da água do sistema planície de Curuai/ Rio Amazonas**. 2005. 287p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007. Disponível em: [mtc-m16c.sid.inpe.br/col/sid.inpe.br/MTC-13@80/2006/02.22.15.../publicacao.pdf](http://mtc-m16c.sid.inpe.br/col/sid.inpe.br/MTC-13@80/2006/02.22.15.../publicacao.pdf). Acesso em: 10 jan. 2022.



BAKER, J. C. A. et al. Evapotranspiration in the Amazon: spatial patterns, seasonality, and recent trends in observations, reanalysis, and climate models. **Hydrology and Earth System Sciences**, v. 25, n. 4, p. 2017-2039, 2021.

BARBEDO, R. et al. Water storage variability across Brazil. **Revista Brasileira de Recursos Hídricos (RBRH)**, v. 27, 2022.

BARBOSA, C. C. F. et al. Metodologia de análise da dinâmica de área e volume inundável: o exemplo da várzea do Lago Grande de Curuai. **Revista Brasileira de Cartografia**, v. 58, p. 1–10, 2006.

BARBOSA, C. C. F. et al. Geospatial analysis of spatiotemporal patterns of pH, total suspended sediment and chlorophyll-a on the Amazon floodplain. **Limnology**, v. 11, n. 2, p. 155–166, 2010.

BARICHIVICH, J. et al. Recent intensification of Amazon flooding extremes driven by strengthened Walker circulation. **Science Advances**, v. 4, n. 9, 2018.

BARTSCH, A. et al. Detection of open water dynamics with ENVISAT ASAR in support of land surface modelling at high latitudes. **Biogeosciences**, v. 9, n. 2, p. 703-714, 2012.

BASSO, L. S. et al. Amazon methane budget derived from multi-year airborne observations highlights regional variations in emissions. **Communications Earth & Environment**, v. 3, n. 1, p. 1-10, 2021.

BENNINGA, H.-J. F.; VELDE, R.; SU, Z. Impacts of radiometric uncertainty and weather-related surface conditions on soil moisture retrievals with Sentinel-1. **Remote Sensing**, v. 11, n. 17, p. 2025–2053, 2019.

BOLAÑOS, S. et al. Operational Surface Water Detection and Monitoring Using Radarsat 2. **Remote Sensing**, v. 8, n. 4, p. 307, 2016.

BOMFIM, E. O. **Indicadores biogeoquímicos de qualidade ambiental na planície de inundação do Lago Grande do Curuai, Amazônia Brasileira**. 2017. 152 p. Tese (Doutorado em Geociências Aplicadas) - Universidade de Brasília, Brasília, 2017. Disponível em: <https://repositorio.unb.br/handle/10482/24483>. Acesso em: 15 jun. 2023.

BONNET, M. P. et al. Floodplain hydrology in an Amazon floodplain lake (Lago Grande de Curuai). **Journal of Hydrology**, v. 349, n. 1/2, p. 18-30, jan. 2008.

BOURGOIN, L. M. et al. Temporal dynamics of water and sediment exchanges between the Curuaí floodplain and the Amazon River, Brazil. **Journal of Hydrology**, 2007.

BOURREL, L.; PHILLIPS, L.; MOREAU, S. The dynamics of floods in the Bolivian Amazon Basin. **Hydrological Processes**, v. 23, n. 15, p. 2143-2153, 2009.

BUCUR, A. et al. Development of an Earth observation cloud platform in support to water resources monitoring. In: MATHIEU, P. P.; AUBRECHT, C. (Ed.). **Earth observation open science and innovation**. [S.l.]: Springer, 2018.

CANISIUS, F. et al. SAR Backscatter and InSAR coherence for monitoring wetland extent, flood pulse and vegetation: a study of the Amazon lowland. **Remote Sensing**, v. 11, n. 7, p. 813, 2019.

CAI, W. et al. Climate impacts of the El Niño–Southern Oscillation on South America. **Nature Reviews Earth & Environment**, v. 1, p. 400–415, 2020.

CENTRO NACIONAL DE MONITORAMENTO E ALERTAS DE DESASTRES NATURAIS (CEMADEN). **Boletim de Impactos de Extremos Hidro-Geo-Climáticos em Atividades Estratégicas para o Brasil**. 8 set. 2021. Disponível em: <http://www2.cemaden.gov.br/boletim-de-impactos-de-extremos-de-origem-hidro-geo-climatico-em-atividades-estrategicas-para-o-brasil-08092021/>. Acesso em: 15 set. 2021.

CHAPMAN, B. et al. Mapping regional inundation with Spaceborne L-Band SAR. **Remote Sensing**, v. 7, n. 5, p. 6278-6314, 2015.

CHEN, Z.; ZHAO, S. Automatic monitoring of surface water dynamics using Sentinel-1 and Sentinel-2 data with Google Earth Engine. **International Journal of Applied Earth Observation and Geoinformation**, v. 113, p. 103010, 2022.

CLEMENT, M. A. **Flood extent and volume estimation using multi-temporal Synthetic Aperture Radar**. 2020. Thesis (PhD) - Newcastle University, Newcastle, 2020. Disponível em: <https://core.ac.uk/outputs/475637020>. Acesso em: 15 jun. 2022.

CONSTANTINE, J. A. et al. Sediment supply as a driver of river meandering and floodplain evolution in the Amazon Basin. **Nature Geoscience**, v. 7, p. 899–903, 2014.

COSTA, M. P. F. et al. Biophysical properties and mapping of aquatic vegetation during the hydrological cycle of the Amazon floodplain using JERS-1 and Radarsat. **International Journal of Remote Sensing**, v. 23, n. 1, p. 71-95, 2002.

CREMA, L. C. et al. **Conhecendo as macrófitas aquáticas da Amazônia**. Manaus: INPA, 2015.

DATTA, A. et al. Monitoring the spread of water hyacinth (*pontederia crassipes*): challenges and future developments. **Frontiers in Ecology and Evolution**, v. 8, 2021.

DEVRIES, B. et al. Rapid and robust monitoring of flood events using Sentinel-1 and Landsat data on the Google Earth Engine. **Remote Sensing of Environment**, v. 238, 2020.

DOBLAS, J. et al. Stabilization of Sentinel-1 SAR time-series using climate and forest structure data for early tropical deforestation detection. **ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences**, v.3-2020, p. 89–96, 2020.

DOBLAS, J. **Operational near real-time detection of deforestation on the brazilian Amazon using synthetic aperture radar data**. 2023. 257 p. IBI: 8JMKD3MGP3W34T/47UH49B. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2022. Disponível em: <http://urlib.net/ibi/8JMKD3MGP3W34T/47UH49B>. Acesso em: 19 jun. 2023.

ENGLE, D. L. et al. High rates of net primary production and turnover of floating grasses on the Amazon floodplain: implications for aquatic respiration and regional CO<sub>2</sub> flux. **Global Change Biology**, v. 13, n. 2, p. 282-291, 2007.

EUROPEAN SPACE AGENCY (ESA). **Sentinel-1**. Disponível em: <https://sentinel.esa.int/web/sentinel/copernicus/sentinel-1>. Acesso em: 23 jan. 2023a.

EUROPEAN SPACE AGENCY (ESA). **Sentinel-2**. Disponível em: <https://sentinel.esa.int/web/sentinel/copernicus/sentinel-2>. Acesso em: 23 jan. 2023b.

ESPINOZA, J.-C. et al. The new historical flood of 2021 in the Amazon River compared to major floods of the 21st century: atmospheric features in the context of the intensification of floods. **Weather and Climate Extremes**, v. 36, 2022.

FASSONI-ANDRADE, A. C.; PAIVA, R. C. D.; FLEISCHMANN, A. S. Lake topography and active storage from satellite observations of flood frequency. **Water Resources Research**, v. 56, n. 6, 2020.

FASSONI-ANDRADE, A. C. et al. Amazon hydrology from space: scientific advances and future challenges. **Reviews of Geophysics**, v. 59, n. 4, 2021.

FERREIRA, G. H. S. **Identificação de áreas inundadas na porção sul de Roraima utilizando imagens de radar**. 2018. 100p. Dissertação (Mestrado em Geociências) - Universidade de Brasília, Brasília, 2018. Disponível em: <https://repositorio.unb.br/handle/10482/33928>. Acesso em: 03 mar. 2022.

- FILIPPONI, F. Sentinel-1 GRD preprocessing workflow. **Proceedings**, v. 18, n. 1, p. 11, 2019.
- FINER, M.; JENKINS, C. N. Proliferation of hydroelectric dams in the Andean Amazon and implications for Andes-Amazon connectivity. **PLoS One**, v. 7, n. 4, e35126, 2012.
- FISHER, J. B. et al. Remotely sensed terrestrial open water evaporation. **Scientific Reports**, 2023.
- FLEISCHMANN, A. S. et al. How much inundation occurs in the Amazon River basin? **Remote Sensing of Environment**, v. 278, p. 113099, 2022.
- FLORES, A. et al. **Synthetic Aperture Radar (SAR) handbook: comprehensive methodologies for forest monitoring and biomass estimation**. Washington: NASA, 2019.
- FRAPPART, F. et al. Floodplain water storage in the Negro River basin estimated from microwave remote sensing of inundation area and water levels. **Remote Sensing of Environment**, v. 99, n. 4, p. 387-399, 2005.
- FREEMAN, A.; CHAPMAN, B.; SIQUEIRA, P. The JERS-1 Amazon Multi-season Mapping Study (JAMMS): science objectives and implications for future missions. **International Journal of Remote Sensing**, v. 23, n. 7, p. 1447-1460, 2002.
- FUNK, C. et al. The climate hazards infrared precipitation with stations: a new environmental record for monitoring extremes. **Sci Data**, v. 2, p. 150066, 2015.
- FURTADO, L. F. A. **Mapeamento e modelagem da estrutura da vegetação na várzea Amazônica utilizando dados polarimétricos de banda C**. 2014. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2014.
- 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, pp. 212-222, 2016.
- GARCIA, B.; LIBONATI, R.; NUNES, A. Extreme drought events over the Amazon basin: the perspective from the reconstruction of South American hydroclimate. **Water**, v. 10, n. 1594, 2018.
- GASICA, T. A.; BIORRESITA, F.; MURTIYOSO, A. Identification of temporary surface water using Sentinel-1 SAR data, case study: Sentani Flash Flooding, Indonesia. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 43B3, p. 55–59, 2020.

GOOGLE EARTH ENGINE (GEE). **Earth Engine**. Disponível em: <https://cloud.google.com/earth-engine?hl=es> 419. Acesso em: 23 jun. 2022.

GETIRANA, A. et al. Rivers and floodplains as key components of global terrestrial water storage variability. **Geophysical Research Letters**, v. 44, n. 20, p. 10,359-10,368, 2017.

GOMES, V.; QUEIROZ, G.; FERREIRA, K. An overview of platforms for big earth observation data management and analysis. **Remote Sensing**, v. 12, n. 8, p. 1253, 2020.

GLOOR, M. et al. Intensification of the Amazon hydrological cycle over the last two decades. **Geophysical Research Letters**, v. 40, n. 9, p. 1729-1733, 2013.

GRIMALDI, S. et al. Remote sensing-derived water extent and level to constrain hydraulic flood forecasting models: opportunities and challenges. **Surveys in Geophysics**, v. 37, p. 977–1034, 2016.

GULÁCSI, A.; KOVÁCS, F. Sentinel-1-imagery-based high-resolution water cover detection on wetlands, aided by Google Earth Engine. **Remote Sensing**, v. 12, n. 10, p. 1587, 2020.

GUO, Z. et al. Water-body segmentation for SAR Images: past, current, and future. **Remote Sensing**, v. 14, n. 7, p. 1191, 2022.

HALL, A. C. et al. Tracking water level changes of the Amazon Basin with space-borne remote sensing and integration with large scale hydrodynamic modelling: a review. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 36, n. 7–8, p. 223-231, 2011.

HAN, Y. et al. Water distribution based on SAR and optical data to improve hazard mapping. **Environmental Research**, v. 235, p. 116694, 2023.

HENDERSON, F.; LEWIS, A. Radar detection of wetland ecosystems: a review. **International Journal of Remote Sensing**, v. 29, n. 20, p. 5809–5835, 2008.

HERNDON, K. E. et al. Google Earth Engine for archaeologists: an updated look at the progress and promise of remotely sensed big data. **Journal of Archaeological Science: Reports**, v. 43, 2023.

HESS, L. L.; MELACK, J. M.; SIMONETT, D. S. Radar detection of flooding beneath the forest canopy: a review. **International Journal of Remote Sensing**, v. 11, n. 7, p. 1253-1265, 1990.

HESS, L. L. et al. Delineation of inundated area and vegetation along the Amazon floodplain with the SIR-C synthetic aperture radar. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 4, p. 896-904, 1995.

HESS, L. L. et al. Large-scale vegetation features of the Amazon basin visible on the JERS-1 low-water Amazon mosaic. In: IGARSS, 1998. **Proceedings...** 1998.

HESS, L. L. et al. 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, n. 3, p. 565-578, 2015.

INSTITUTO NACIONAL DE PESQUISAS DA AMAZÔNIA (INPA). A seca de 2023 na Amazônia terá muito estrago pela frente. **Amazônia Real**. 26 out. 2023. Disponível em: [https://philip.inpa.gov.br/publ\\_livres/2023/Silva\\_&\\_Fearnside-2023-A\\_seca\\_de\\_2023-Amazonia\\_Real-26-10-23.pdf](https://philip.inpa.gov.br/publ_livres/2023/Silva_&_Fearnside-2023-A_seca_de_2023-Amazonia_Real-26-10-23.pdf). Acesso em: 17 nov. 2023.

JONG, J.; KLAASSEN, W.; BALLAST, A. Rain storage in forests detected with ERS tandem mission SAR. **Remote Sensing of Environment**, v. 72, n. 2, p. 170–180, 2000.

JUNK, W. J.; PIEDADE, M. T. F. Plant life in the floodplain with special reference to herbaceous plants. In: JUNK, W. J. (Ed.). **The central Amazon floodplain**. Berlin: Springer, 1997. p.147-185.

JUNK, W. J. et al. A classification of major naturally-occurring Amazonian lowland wetlands. **Wetlands**, v. 31, p. 623–640, 2011.

KEDRON, P.; FRAZIER, A. E. How to improve the reproducibility, replicability, and extensibility of remote sensing research. **Remote Sensing**, v. 14, n. 21, p. 5471, 2022.

KSEŇAK, L. et al. Assessment of the usability of SAR and optical satellite data for monitoring spatio-temporal changes in surface water: bodrog river case study. **Water**, v. 14, n. 2, p. 271-286, 2022.

LEE, H. et al. **Climate change 2023**: synthesis report. Geneva: IPCC, 2023.

LEES, A. C. et al. Hydropower and the future of Amazonian biodiversity. **Biodiversity and Conservation**, v. 25, n. 3, p. 451-466, 2016.

LIANG, J.; LIU, D. A local thresholding approach to flood water delineation using Sentinel-1 SAR imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 159, p. 156-169, 2020.

LIANG, J.; LIANG, G.; SUN, L. Using Sentinel images for analyzing water and land separability in an agricultural river basin. **Environmental Monitoring and Assessment**, v. 195, n. 11, p. 682, 2023.

LIU, C. et al. Mapping large-scale aquaculture ponds in Jiangsu Province, China: an automatic extraction framework based on Sentinel-1 time-series imagery. **Aquaculture**, v. 581, p. 740441, 2024.

LOBO, F. L. et al. Mapping mining areas in the Brazilian Amazon using MSI/Sentinel-2 Imagery (2017). **Remote Sensing**, v. 10, n. 8, p. 1137, 2018.

LOPES, A., PAROLIN, P., PIEDADE, M. T. F. Morphological and physiological traits of aquatic macrophytes respond to water chemistry in the Amazon Basin: an example of the genus *Montrichardia* Crueg (Araceae). **Hydrobiologia**, v. 766, n. 1, p. 1-15, 2016.

MAGALHÃES, I. A. L. et al. **Sentinel-1 time series analysis on central amazon floods**. Fortaleza: Universidade Federal do Ceara, 2022.

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. Tese (Doutorado em Geografia) - Universidade de Brasília, Brasília, 2022. Disponível em: <https://repositorio.unb.br/handle/10482/45371>. Acesso em: 3 abr. 2023.

MARENGO, J. A.; ESPINOZA, J. C. Extreme seasonal droughts and floods in Amazonia: causes, trends and impacts. **International Journal of Climatology**, v. 35, n. 7, p. 1033-1050, 2015.

MARTINEZ, J.; LE TOAN, T. Mapping of flood dynamics and spatial distribution of vegetation in the Amazon floodplain using multitemporal SAR data. **Remote Sensing of Environment**, v. 108, n. 4, p. 209-223, 2007.

MARTINIS, S. A Sentinel-1 times series-based exclusion layer for improved flood mapping in arid areas. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2018. **Proceedings...** IEEE 2018.

MATAVELI, G. et al. Mining is a growing threat within indigenous lands of the Brazilian Amazon. **Remote Sensing**, v. 14, n. 16, p. 3247, 2022.

MARKERT, K.; DONCHYTS, G.; HAAG, A. Surface water mapping. In: CARDILLE, J. A. et al. (Ed.). **Cloud-based remote sensing with Google Earth Engine**. Berlin: Springer, 2023.

MARTINS, V. S. et al. Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): insights for remote sensing and climate analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2018.

MCCORMACK, T.; CAMPANYÀ, J.; NAUGHTON, O. A methodology for mapping annual flood extent using multi-temporal Sentinel-1 imagery. **Remote Sensing of Environment**, v. 282, p. 113273, 2022.



MCCORMACK, T.; CAMPAÑYÀ, J.; NAUGHTON, O. Reconstructing flood level time series at seasonal wetlands in Ireland using Sentinel-1. **Remote Sensing of Environment**, v. 299, p. 113839, 2023.

MEHMOOD, M. et al. Remote sensing image classification: a comprehensive review and applications. **Mathematical Problems in Engineering**, v. 2022, e5880959, 2022.

MELACK, J. M.; WANG, Y. **Delineation of flooded area and flooded vegetation in Balbina Reservoir (Amazonas, Brazil) with synthetic aperture radar**. UK: SIL, 1998.

MELACK, J. M.; HESS, L. L. Areal extent of vegetative cover: a challenge to regional upscaling of methane emissions. **Aquatic Botany**, v. 184, p. 103592, 2023.

MELKAMU, T. et al. Detecting and mapping flood inundation areas in Fogera-Dera Floodplain, Ethiopia during an extreme wet season using Sentinel-1 data. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 127, p. 103189, 2022.

MITSUYA, M. **Variação sazonal na composição química da água no leito principal do Rio Amazonas em frente à cidade de Óbidos-PA**. 2014. 68 f. Dissertação (Mestrado em Recursos Naturais da Amazônia) - Universidade Federal do Oeste do Pará, Santarém, 2014. Disponível em: <https://repositorio.ufopa.edu.br/jspui/handle/123456789/254>. Acesso em: 12 ago. 2022.

MOHARRAMI, M., JAVANBAKHT, M., ATTARCHI, S. Automatic flood detection using Sentinel-1 images on the Google Earth Engine. **Environmental Monitoring and Assessment**, v. 193, n. 4, p. 248, 2021.

MOORE, R. K. et al. Rain measurement with SIR-C/X-SAR. **Remote Sensing of Environment**, v. 59, n. 2, p. 280–293, 1997.

MUSA, Z. N.; POPESCU, I.; MYNETT, A. A review of applications of satellite SAR, optical, altimetry and DEM data for surface water modelling, mapping and parameter estimation. **Hydrology and Earth System Sciences**, v. 19, n. 9, p. 3755–3769, 2015.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION (NOAA). **Oceanic Niño Index (ONI) data**. 2023. Disponível em: <https://psl.noaa.gov/data/correlation/oni.data>. Acesso em: 23 jan. 2023.

NOVO, E. M. L. M. et al. RADARSAT exploratory survey on macrophyte biophysical parameters in tropical reservoirs. **Canadian Journal of Remote Sensing**, v. 24, n. 4, p. 367-375, 1998.



- OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62-66, 1979.
- PAPATHANASIOU, K. P. et al. Forest applications. In: HAJNSEK, I.; DESNOS, Y-L. (Ed.). **Remote sensing and digital image processing: polarimetric synthetic aperture radar**. [S.l.: s.n.], 2021. p.59-117.
- PARADELLA, R. W.; MURA, J. C.; GAMA, F. F. **Monitoramento DInSAR para mineração de geotecnia**. São Paulo: Oficina de Texto, 2022.
- PEAKE, W. H.; OLIVER, T. L. **The response of terrestrial surfaces at microwave frequencies**. Columbus: Ohio State University, 1971.
- PECH-MAY, F.; AQUINO-SANTOS, R.; DELGADILLO-PARTIDA, J. Sentinel-1 SAR images and deep learning for water body mapping. **Remote Sensing**, v. 15, n. 12, p. 3009, 2023.
- PEREIRA, S.A. et al. Assessing biological traits of Amazonian high-value fishes through Local Ecological Knowledge of urban and rural fishers. **Hydrobiologia**, v. 848, p. 2483–2504, 2021.
- PHAM-DUC, B. et al. Trends and applications of Google Earth Engine in remote sensing and earth science research: a bibliometric analysis using Scopus database. **Earth Science Informatics**, v. 16, p. 2355–2371, 2023.
- PINHEIRO, G. et al. **Inundation extend mapping for multi-temporal SAR using automatic thresholding and change detection: a case study on Kosi river of India**. [S.l.]: Spatial Information Research, 2023.
- RESTREPO-COUBE, N. et al. Asymmetric response of Amazon forest water and energy fluxes to wet and dry hydrological extremes reveals onset of a local drought-induced tipping point. **Global Change Biology**, v. 29, n. 21, p. 6077-6092, 2023.
- RICHARDS, J. A.; XIUPING, J. **Remote sensing digital image analysis**. 4.ed. Berlin: Springer, 2006.
- RICHEY, J. et al. Outgassing from Amazonian rivers and wetlands as a large tropical source of atmospheric CO<sub>2</sub>. **Nature**, v. 416, p. 617–620, 2002.
- ROSENQVIST, J. et al. Mapping of maximum and minimum inundation extents in the Amazon Basin 2014–2017 with ALOS-2 PALSAR-2 ScanSAR Time-series data. **Remote Sensing**, v. 12, n. 8, p. 1326, 2020.
- ROSSETTI, D. F. et al. Late Holocene tectonic influence on hydrology and vegetation patterns in a northern Amazonian megafan. **Catena**, v. 158, p. 121-130, 2017.

ROSSI, D. et al. Monitoring braided river-bed dynamics at the sub-event time scale using time series of Sentinel-1 SAR imagery. **Remote Sensing**, v. 15, n. 14, p. 3622, 2023.

RUDORFF, C. M.; MELACK, J. M.; BATES, P. D. Flooding dynamics on the lower Amazon floodplain: 1. hydraulic controls on water elevation, inundation extent, and river-floodplain discharge. **Water Resources Research**, v. 50, n. 1, p. 619–634, 2014.

RUIZ-RAMOS, J. et al. Continuous forest monitoring using cumulative sums of Sentinel-1 timeseries. **Remote Sensing**, v. 12, n.18, p. 3061, 2020.

SAHOUR, H.; KEMINK, K. M.; O'CONNELL, J. Integrating SAR and optical remote sensing for conservation-targeted wetlands mapping. **Remote Sensing**, v. 14, p. 159, 2022.

SAKURAI-AMANO, T. et al. Visualization of narrow rivers within forested areas using JERS-1 SAR Images of the Amazon river basin. **Journal of the Japan Society of Photogrammetry and Remote Sensing**, v. 44, n. 5, p. 64-72, 2005.

SANT'ANNA, S. J. S. et al. Introdução ao processamento de imagens de radar. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 205. Disponível em: <http://urlib.net/sid.inpe.br/mtcm17@80/2007/12.10.15.19>. Acesso em: 21 nov. 2023.

SANTORO, M. et al. Strengths and weaknesses of multi-year Envisat ASAR backscatter measurements to map permanent open water bodies at global scale. **Remote Sensing of Environment**, v. 171, p. 185-201, 2015.

SCHLAFFER, S. et al. Monitoring surface water dynamics in the Prairie Pothole Region of North Dakota using dual-polarised Sentinel-1 synthetic aperture radar (SAR) time series. **Hydrology and Earth System Sciences**, v. 26, p. 841-902, 2022.

SHEN, G. et al. Water body mapping using long time series Sentinel-1 SAR data in Poyang Lake. **Water**, v. 14, p. 1902, 2022.

SCHUMANN, G. J.-P.; MOLLER, D. K. Microwave remote sensing of flood inundation. **Physics and Chemistry of the Earth, Parts A/B/C**, v. 83/84, p. 84-95, 2015.

SILVA, T. S. F. et al. Remote sensing of aquatic vegetation: theory and applications. **Environmental Monitoring and Assessment**, v. 140, n. 1/3, p. 131–145, 2008.

SILVA, T. S. F.; COSTA, M. P. F.; MELACK, J. M. Annual net primary production of macrophytes in the eastern Amazon floodplain. **Wetlands**, v. 29, p. 747–758, 2009.

SILVA, T. S. F.; COSTA, M. P. F.; MELACK, J. M. Spatial and temporal variability of macrophyte cover and productivity in the eastern Amazon floodplain: a remote sensing approach. **Remote Sensing of Environment**, v. 114, n. 9, p. 1998-2010, 2010.

SILVA, T. S. F. et al. A multisensor, multitemporal approach for monitoring herbaceous vegetation growth in the Amazon floodplain. In: INTERNATIONAL WORKSHOP ON THE ANALYSIS OF MULTI-TEMPORAL REMOTE SENSING IMAGES, 7., 2013. **Proceedings...** 2013. Disponível em: <https://ieeexplore.ieee.org/document/6866019>. Acesso em: 24 mar. 2023.

SILVEIRA, M. V. F. et al. Amazon fires in the 21st century: the year of 2020 in evidence. **Global Ecology and Biogeography**, v. 31, n. 10, p. 2026-2040, 2022.

SIPELGAS, L.; AAVASTE, A.; UIBOUPIN, R. Mapping flood extent and frequency from sentinel-1 imagery during the extremely warm winter of 2020 in Boreal Floodplains and Forests. **Remote Sensing**, v. 13, n. 23, p. 4949, 2021.

SMALL, D. Flattening gamma: radiometric terrain correction for sar imagery. **IEEE Transactions on Geosciences and Remote Sensing**, v. 49, n. 8, p. 3081-3093, 2011.

SOMAN, M. K.; INDU, J. Sentinel-1 based Inland water dynamics Mapping System (SIMS). **Environmental Modelling & Software**, v. 149, 2022.

SOROOSHIAN, A. et al. A satellite perspective on cloud water to rain water conversion rates and relationships with environmental conditions. **Journal of Geophysical Research: Atmospheres**, v. 118, n. 12, p. 6643-6650, 2013.

TERRABRASILIS. PROGRAMA DE MONITORAMENTO DA AMAZÔNIA E DE MAIS BIOMAS. **Desmatamento – Amazônia Legal** – Disponível em: <http://terrabrasilis.dpi.inpe.br/downloads/>. Acesso em: 19 set. 2023.

TERRES DE LIMA, L. et al. Development of tools for coastal management in Google Earth Engine: uncertainty bathtub model and bruun rule. **Remote Sensing**, v. 13, n. 8, p. 1424, 2021.

THOMAS, M. et al. A framework to assess remote sensing algorithms for satellite-based flood index insurance. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 16, p. 2589-2604, 2023.

TINER, R.; LANG, M.; KLEMAS, V. **Remote sensing of wetlands: applications and advances**. [S.l.]: Taylor and Francis, 2015.

TOKAY, A.; SHORT, D. A. Evidence from tropical raindrop spectra of the origin of rain from stratiform versus convective clouds. **Journal of Applied Meteorology**, v. 35, n. 3, p. 355–371, 1996.

TOMASELLA, J. et al. The water balance of an Amazonian micro-catchment: the effect of interannual variability of rainfall on hydrological behaviour. **Hydrological Processes**, v. 22, n. 13, p. 2133-2147, 2007.

TRAN, K. H.; MENENTI, M.; JIA, L. Surface water mapping and flood monitoring in the mekong delta using Sentinel-1 SAR Time Series and Otsu Threshold. **Remote Sensing**, v. 14, n. 22, p. 5721, 2022.

TSAI, Y.-L. S. et al. Monitoring large-scale inland water dynamics by Fusing Sentinel-1 SAR and Sentinel-3 Altimetry data and by analyzing causal effects of snowmelt. **Remote Sensing**, v. 12, n. 23, p. 3896, 2020.

TUNDISI, J. G. et al. How many more dams in the Amazon? **Energy Policy**, v. 74, p. 703-708, 2014.

TWELE, A. et al. Sentinel-1-based flood mapping: a fully automated processing chain. **International Journal of Remote Sensing**, v. 37, n. 13, p. 2990-3004, 2016.

ULABY, F. T.; MOORE, R. K.; FUNG, A. K. **Microwave remote sensing: active and : radar remote sensing and surface scattering and emission theory**. Norwood: Artech House, 1986. p. 962-966.

VELASTEGUI-MONTOYA, A. et al. Google Earth Engine: a global analysis and future trends. **Remote Sensing**, v. 15, n. 14, p. 3675, 2023.

WHITE, L. et al. A Collection of SAR Methodologies for Monitoring Wetlands. **Remote Sensing**, v. 7, n. 6, p. 7615-7645, 2015.

WANG, Z. et al. An automatic thresholding method for water body detection from SAR image. In: IEEE INTERNATIONAL CONFERENCE ON SIGNAL, INFORMATION AND DATA PROCESSING (ICSIDP), 2019. **Proceedings...** IEEE, 2019.

WOODHOUSE, I. H. **Introduction to microwave remote sensing**. [S.l.]: CRC Press, 2017.

WU, L. et al. Discrimination of algal-bloom using spaceborne sar observations of great lakes in China. **Remote Sensing**, v. 10, n. 5, p. 767, 2018.

WU, X. et al. A near-real-time flood detection method based on deep learning and SAR images. **Remote Sensing**, v. 15, n. 8, p. 2046, 2023.

YU, Z.; AN, Q.; LIU, W.; WANG, Y. Analysis and evaluation of surface water changes in the lower reaches of the Yangtze River using Sentinel-1 imagery. **Journal of Hydrology: Regional Studies**, v. 41, p. 101074, 2022.

ZHANG, W. et al. Automatic surface water mapping using polarimetric SAR data for long-term change detection. **Water**, v. 12, n. 3, p. 872, 2020.

ZHANG, B. et al. Spatiotemporal variations of wetland backscatter: the role of water depth and vegetation characteristics in Sentinel-1 dual-polarization SAR observations. **Remote Sensing of Environment**, v. 270, 2022.