



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS  
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

JONAS FELIPE SANTOS DE SOUZA

**USO DE IMAGENS SAR E ÓPTICAS DO SATÉLITE SENTINEL NO  
MONITORAMENTO DE RESERVATÓRIOS EM REGIÕES SEMIÁRIDA E DE MATA  
ATLÂNTICA**

Recife

2024

JONAS FELIPE SANTOS DE SOUZA

**USO DE IMAGENS SAR E ÓPTICAS DO SATÉLITE SENTINEL NO  
MONITORAMENTO DE RESERVATÓRIOS EM REGIÕES SEMIÁRIDA E DE MATA  
ATLÂNTICA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para obtenção do título de Mestre em Engenharia Civil. Área de concentração: Tecnologia Ambiental e Recursos Hídricos.

**Área de Concentração:** Tecnologia Ambiental e Recursos Hídricos.

**Orientador:** Prof. Dr. Alfredo Ribeiro Neto.

Recife

2024

Catálogo na fonte  
Bibliotecária Margareth Malta, CRB-4 / 1198

S729a	<p>Souza, Jonas Felipe Santos de. Uso de imagens SAR e ópticas do Satélite Sentinel no monitoramento de reservatórios em regiões semiárida e de mata atlântica / Jonas Felipe Santos de Souza – 2024. 82 f.: il., figs., qds., tabs.</p> <p>Orientador: Prof. Dr. Alfredo Ribeiro Neto. Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil, 2024. Inclui Referências.</p> <p>1. Engenharia Civil. 2. Sentinel 1. 3. Sentinel 2. 4. Detecção de água. 5. Rede Neural Artificial. I. Ribeiro Neto, Alfredo (Orientador). II. Título.</p> <p>UFPE</p> <p>624 CDD (22. ed.)</p> <p>BCTG/2024-49</p>
-------	--

JONAS FELIPE SANTOS DE SOUZA

**USO DE IMAGENS SAR E ÓPTICAS DO SATÉLITE SENTINEL NO  
MONITORAMENTO DE RESERVATÓRIOS EM REGIÕES SEMIÁRIDA E DE MATA  
ATLÂNTICA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para obtenção do título de Mestre em Engenharia Civil. Área de concentração: Tecnologia Ambiental e Recursos Hídricos.

Aprovada em 21/02/2024

Orientador: Prof. Dr. Alfredo Ribeiro Neto – UFPE.

**BANCA EXAMINADORA**

participação por videoconferência  
Prof. Dr. José Roberto Gonçalves de Azevedo (examinador interno)  
Universidade Federal de Pernambuco

participação por videoconferência  
Prof. Dr. Wendson de Oliveira Souza (examinador externo)  
Universidade Federal do Piauí

participação por videoconferência  
Prof. Dr. Gerald Norbert Souza da Silva (examinador externo)  
Universidade Federal da Paraíba

## AGRADECIMENTOS

À minha mãe, Elizângela, por todo o amor, dedicação e incentivo. Em especial, nos últimos dois anos que tenho me dedicado ao mestrado, pois sem seu apoio eu não conseguiria chegar onde cheguei.

Ao meu pai, Bira, por todo amor e amizade durante os momentos que passamos juntos.

À minha amada, Luciana Juvêncio, que sempre me motivou e vibrou com meus esforços e conquistas, assim como me amparou nos momentos difíceis, especialmente porque também conhece os prazeres e as dores de estar numa pós-graduação.

À minha querida amiga, Beatriz, que vem caminhando junto comigo da graduação ao mestrado, por toda a sua amizade e confiança.

Ao Centro de Capoeira São Salomão, em especial aos mestres Mago, Bel, Cabrito, Dani e Camarão, por ter me ensinado o tempo de capoeira com um São Bento Grande bem balanceado. Nada de novo, tudo de novo.

Ao Centro Nacional de Estudos Espaciais da França, em especial ao pesquisador Santiago Peña-Luque, pela concessão do acesso ao servidor virtual e parte dos algoritmos utilizados, bem como no auxílio à resolução dos problemas encontrados no decorrer deste trabalho.

Ao Douglas Tiburcio Procópio, aluno PIBIC do curso de Engenharia Civil da UFPE, pelo auxílio com o processamento dos dados de satélite utilizados neste trabalho.

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pela concessão da bolsa de mestrado.

Por fim, ao meu orientador, professor Alfredo Ribeiro Neto, por ter me dado a oportunidade de trabalhar ao seu lado, me dando todo o auxílio necessário e compartilhando parte de seu vasto conhecimento. Com certeza um dos responsáveis pelo meu interesse em seguir como pesquisador.

*"O essencial não é só a noção de que o singular depende do todo, mas igualmente a noção de que cada momento por si só, independentemente do todo, é o todo, e isso constitui o aprofundar-se na coisa."*

*(G. W. F. Hegel)*

*"De fato, todo conhecer real e exaustivo consiste apenas em que elevemos, por meio do pensamento, o singular da individualidade à particularidade e desta à universalidade, que encontremos e constatemos o infinito no finito, o eterno no transitório."*

*(Friedrich Engels)*

## RESUMO

Este trabalho analisou a aplicabilidade do sensoriamento remoto com o uso de imagens de radar e ópticas provenientes dos satélites Sentinel 1 e Sentinel 2, respectivamente, para mapeamento e monitoramento da extensão da água superficial em reservatórios nas regiões semiárida e de mata atlântica do estado de Pernambuco. Além disso, também foi proposta e aplicada uma metodologia para correção de viés dos dados de área de água obtidos por satélite utilizando Redes Neurais Artificiais. Na primeira abordagem, com a utilização de produtos Sentinel 1, foram selecionados os reservatórios de Bitá, Bonitinho, Pirapama, Serro Azul, Sicupema e Utinga na Mata Norte e Região Metropolitana do Recife para a aplicação e avaliação de um algoritmo de detecção de água baseado em *Random Forest* utilizando 365 cenas e de três métodos de limiarização utilizando 122 cenas, sendo estes o método de limiar predefinido, método de Otsu e método de Kittler-Illingworth. Na segunda abordagem, com a utilização de produtos Sentinel 2, foram selecionados os reservatórios de Chapéu com 37 cenas, Serrinha II com 78 cenas e Poço da Cruz com 36 cenas na região Sertão para aplicação e avaliação de um algoritmo automático não-supervisionado e não-paramétrico de detecção de água. Após a geração das máscaras de água e o respectivo cálculo das áreas de água superficial nas duas abordagens, os resultados foram comparados com dois conjuntos de dados de área de referência: monitoramento *in situ* e MapBiomás. Para a metodologia adotada na primeira abordagem, o algoritmo baseado em *Random Forest* apresentou os melhores resultados, com os valores de área obtidos refletindo de modo satisfatório as tendências da série histórica do monitoramento *in situ*, mas com limitações na detecção de água, com a subestimação dos valores máximos de área e problemas em ambientes complexos. Para a metodologia adotada na segunda abordagem, o algoritmo aplicado não alcançou resultados satisfatórios na detecção de água, com os valores de área calculados subestimando os valores obtidos de observações *in situ*. Além disso, diversas máscaras de água geradas pelo algoritmo apresentaram falhas na classificação dos *pixels*, comprometendo o resultado final. A utilização do MapBiomás como base de dados de referência apresentou limitações quanto à escala temporal, à classificação dos corpos hídricos e à subestimação dos valores mínimos de área de água superficial. Por fim, o método de correção de viés aplicado mostrou-se eficiente para situações com tamanho de amostra de teste suficiente para o treinamento e calibração do modelo de Rede Neural Artificial.

**Palavras-chave:** Sentinel 1; Sentinel 2; detecção de água; Rede Neural Artificial.

## ABSTRACT

This work analyzes the application of remote sensing using radar and optical images from the Sentinel-1 and Sentinel-2 satellites, respectively, for mapping and monitoring the extent of surface water in reservoirs in the semi-arid and atlantic forest regions of the state of Pernambuco. Furthermore, a methodology for bias correction of water area data obtained by satellite using Artificial Neural Networks was also proposed and applied. In the first approach, using Sentinel-1 products, the reservoirs of Bitá, Bonitinho, Pirapama, Serro Azul, Sicupema and Utinga were selected in Mata Norte and the Metropolitan Region of Recife for the application and evaluation of a water detection algorithm based on Random Forest using 365 scenes and three thresholding methods using 122 scenes, these being the predefined threshold method, Otsu method and Kittler-Illingworth method. In the second approach, using Sentinel-2 products, the reservoirs of Chapéu with 37 scenes, Serrinha II with 78 scenes, and Poço da Cruz with 36 scenes in the Sertão region were selected for the application and evaluation of an unsupervised and non-parametric automatic water detection algorithm. After generating the water masks and calculating the surface water areas in both approaches, the results were compared with two sets of reference area data: *in situ* monitoring and MapBiomás. For the methodology adopted in the first approach, the algorithm based on Random Forest presented the best results, with the area values obtained satisfactorily reflecting the trends of the historical series of *in situ* monitoring, but with limitations in water detection, with underestimation maximum area values and problems in complex environments. For the methodology adopted in the second approach, the applied algorithm did not achieve satisfactory results in water detection, with the calculated area values underestimating the values obtained from *in situ* observations. Furthermore, several water masks generated by the algorithm presented gaps in the *pixel* classification, compromising the final result. The use of MapBiomás as a reference database presented limitations regarding the temporal scale, the classification of water bodies and the underestimation of minimum values of surface water area. Finally, the applied bias correction method proved to be efficient for situations with a sufficient test sample size for training and calibration the Artificial Neural Network model.

**Keywords:** Sentinel-1; Sentinel-2; water detection; Artificial Neural Network.

## LISTA DE FIGURAS

Figura 1 – Dimensão resiliência do ISH para o Estado de Pernambuco . . . . .	21
Figura 2 – Reservatórios monitorados pela APAC . . . . .	22
Figura 3 – Disponibilidade Hídrica no estado de Pernambuco . . . . .	23
Figura 4 – Polarização do sinal de radar . . . . .	25
Figura 5 – Modos do Sentinel 1 . . . . .	27
Figura 6 – Reflectância de diversos tipos de objetos da cobertura terrestre . . . . .	29
Figura 7 – Rede Neural Artificial . . . . .	33
Figura 8 – Fluxograma da metodologia adotada neste trabalho . . . . .	35
Figura 9 – Configuração espacial da área de estudo (Abordagem 1) . . . . .	36
Figura 10 – Histograma bimodal de intensidade do retroespalhamento SAR . . . . .	41
Figura 11 – Configuração espacial da área de estudo (Abordagem 2) . . . . .	43
Figura 12 – Área de água observada e calculada considerando os parâmetros de entrada do <i>SurfWater</i> . . . . .	49
Figura 13 – Área de água observada e calculada considerando diferentes composições de polarização do <i>SurfWater</i> . . . . .	50
Figura 14 – Área de água observada e calculada considerando os métodos de limiarização predefinido, Otsu e KI . . . . .	52
Figura 15 – Avaliação do histograma bimodal para os métodos de limiarização . . . . .	53
Figura 16 – Comparação entre <i>SurfWater</i> e método de limiar predefinido . . . . .	56
Figura 17 – Área de água observada, calculada e do MapBiomias . . . . .	58
Figura 18 – Mapas de ocorrência de água de observações Sentinel 1 processadas pelo <i>SurfWater</i> . . . . .	61
Figura 20 – Área de água observada, calculada e corrigida via RNA MLP com produtos Sentinel 1 . . . . .	62
Figura 21 – Área de água observada <i>in situ</i> e MapBiomias e calculada pelo <i>WaterDetect</i> . . . . .	65
Figura 22 – Composição RGB de imagens Sentinel 2 e <i>pixels</i> de água detectadas pelo <i>WaterDetect</i> . . . . .	66
Figura 23 – Mapas de ocorrência de água de observações Sentinel 2 processadas pelo <i>WaterDetect</i> . . . . .	68
Figura 24 – Área de água observada, calculada e corrigida via RNA MLP com produtos Sentinel 2 . . . . .	69

## LISTA DE TABELAS

Tabela 1 – Dimensões e indicadores do ISH . . . . .	20
Tabela 2 – Características dos reservatórios (Abordagem 1) . . . . .	37
Tabela 3 – Cenários testados para os parâmetros de entrada . . . . .	39
Tabela 4 – Cenários testados para a composição de polarização . . . . .	39
Tabela 5 – Características dos reservatórios (Abordagem 2) . . . . .	43
Tabela 6 – Recursos e métodos de cálculo dos índices considerados pelo <i>WaterDetect</i> .	44
Tabela 7 – Métrica RMSE para os cenários de parâmetros de entrada do <i>SurfWater</i> . . .	48
Tabela 8 – Métrica RMSE para os cenários de composição de polarização do <i>SurfWater</i>	50
Tabela 9 – Métrica RMSE para os métodos de limiar predefinido, Otsu e KI . . . . .	52
Tabela 10 – Métricas de avaliação para <i>SurfWater</i> e método de limiar predefinido . . . .	56
Tabela 11 – Medidas estatísticas para <i>SurfWater</i> e método de limiar predefinido . . . . .	57
Tabela 12 – Métricas de avaliação para <i>SurfWater</i> × MapBiomias . . . . .	60
Tabela 13 – Medidas estatísticas para MapBiomias . . . . .	60
Tabela 14 – Métricas de avaliação da RNA MLP aplicadas em produtos Sentinel 1 . . . .	62
Tabela 15 – Métrica de avaliação <i>WaterDetect</i> em relação aos dados <i>in situ</i> . . . . .	64
Tabela 16 – Métrica de avaliação MapBiomias em relação aos dados <i>in situ</i> e <i>WaterDetect</i>	64
Tabela 17 – Medidas estatísticas para <i>WaterDetect</i> e MapBiomias . . . . .	66
Tabela 18 – Comparação de valores de área <i>WaterDetect</i> e <i>in situ</i> . . . . .	67
Tabela 19 – Métricas de avaliação da RNA MLP aplicadas em produtos Sentinel 2 . . . .	69

## LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas e Saneamento Básico
ANA-SAR	Sistema de Acompanhamento de Reservatórios
ANEEL	Agência Nacional de Energia Elétrica
APAC	Agência Pernambucana de Águas e Clima
AWEI	Automated Water Extraction Index
CAV	cota-área-volume
CNES	Centre National d'Estudes Spatiales
ESA	European Space Agency
ETM+	Enhanced Thematic Mapper Plus
EW	Extra Wide-swath
GEE	Google Earth Engine
GRD	Ground Range Detected
gsh	grau de segurança hídrica
HAND	Height Above Nearest Drainage
IPCC	Intergovernmental Panel on Climate Change
IRD	Institut de Recherche pour le Développement
ISH	Índice de Segurança Hídrica
IW	Interferometric Wide-swath
KI	Kittler-Illingworth
MAE	Erro médio absolute
MBWI	Multi-Band Water Index
MDR	Ministério do Desenvolvimento Regional
MLP	Multilayer Perceptron
MNDWI	Modified Normalized Difference Water Index
MSE	Erro quadrático médio
MSI	Multispectral Instrument

MSS	Multispectral Scanner
NDWI	Normalized Difference Water Index
NEB	Nordeste do Brasil
NIR	near infra-red
OLI	Operational Land Imager
PERH	Plano Estadual de Recursos Hídricos
PNSH	Plano Nacional de Segurança Hídrica
ReLU	Função de unidades lineares retificadas
RF	Random Forest
RMSE	Raiz do erro quadrático médio
RNA	Rede Neural Artificial
RSF	Rio São Francisco
SAR	Synthetic Aperture Radar
SEEG/OC	Sistema de Estimativas de Emissões de Gases de Efeito Estufa do Observatório do Clima
SEMARH/AL	Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos de Alagoas
SM	Strip Map
SNAP	Sentinel Application Platform
SPOT	Satellite Pour l'Observation de la Terre
SWIR	short wave infra-red
TM	Thematic Mapper
UP	Unidade de Planejamento
VIS	Faixas visíveis
WV	Wave

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	OBJETIVOS	17
<b>2</b>	<b>REVISÃO DA LITERATURA</b>	<b>18</b>
2.1	SEGURANÇA HÍDRICA	18
2.2	SOBRE OS RESERVATÓRIOS EM PERNAMBUCO	21
2.3	DETECÇÃO DE ÁGUA VIA SENSORIAMENTO REMOTO	24
<b>2.3.1</b>	<b>Os sensores de radar e a missão Sentinel 1</b>	<b>24</b>
<b>2.3.2</b>	<b>Os sensores ópticos e a missão Sentinel 2</b>	<b>28</b>
<b>2.3.3</b>	<b>Dois algoritmos de detecção de água: <i>SurfWater</i> e <i>WaterDetect</i></b>	<b>32</b>
2.4	Redes Neurais Artificiais	33
<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	<b>35</b>
3.1	ABORDAGEM 1: IMAGENS DE RADAR	36
<b>3.1.1</b>	<b>Área de estudo</b>	<b>36</b>
<b>3.1.2</b>	<b>Dados utilizados</b>	<b>37</b>
<b>3.1.3</b>	<b>Algoritmo <i>SurfWater</i></b>	<b>37</b>
<b>3.1.4</b>	<b>Métodos de limiarização</b>	<b>40</b>
3.1.4.1	Método de limiarização predefinida	40
3.1.4.2	Método de Otsu	41
3.1.4.3	Método de Kittler-Illingworth	41
3.2	ABORDAGEM 2: IMAGENS ÓPTICAS	42
<b>3.2.1</b>	<b>Área de estudo</b>	<b>42</b>
<b>3.2.2</b>	<b>Dados utilizados</b>	<b>43</b>
<b>3.2.3</b>	<b>Algoritmo <i>WaterDetect</i></b>	<b>44</b>
3.3	AVALIAÇÃO E CORREÇÃO DOS DADOS CALCULADOS	46
<b>3.3.1</b>	<b>Métricas e estatísticas de avaliação</b>	<b>46</b>
<b>3.3.2</b>	<b>Correção dos dados calculados com RNA</b>	<b>47</b>
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>48</b>
4.1	ABORDAGEM 1: IMAGENS DE RADAR	48
<b>4.1.1</b>	<b>Algoritmo <i>SurfWater</i></b>	<b>48</b>
<b>4.1.2</b>	<b>Métodos de limiarização</b>	<b>51</b>

4.1.3	Comparação <i>SurfWater</i> × métodos de limiarização . . . . .	55
4.1.4	Dados MapBiomias . . . . .	58
4.1.5	Análise de ocorrência de água . . . . .	60
4.1.6	Correção dos dados calculados . . . . .	62
4.2	ABORDAGEM 2: IMAGENS ÓPTICAS . . . . .	63
4.2.1	Algoritmo <i>WaterDetect</i> . . . . .	64
4.2.2	Problemas com detecção de água em imagens ópticas . . . . .	66
4.2.3	Análise de ocorrência de água . . . . .	68
4.2.4	Correção dos dados calculados . . . . .	68
5	CONCLUSÕES E RECOMENDAÇÕES . . . . .	71
	REFERÊNCIAS . . . . .	74

## 1 INTRODUÇÃO

Com o surgimento das civilizações, o represamento e o armazenamento das águas superficiais em lagos e reservatórios serviu historicamente para regularizar a água temporal e espacialmente, uma vez que pôde manter o fornecimento de água sem ou quase nenhuma interrupção durante todo o ciclo hidrológico anual, mesmo em períodos secos, bem como serviu para a contenção de cheias e, mais recentemente, para a geração de energia. O acúmulo de água em uma dada área pode ocorrer de forma natural, como os lagos; ou de forma artificial pelo alagamento forçado pela alteração do curso de rios para fins de uso humano, como os reservatórios.

Chao, Wu e Li (2008) mostraram que na segunda metade do século XX houve um aumento significativo de reservatórios para armazenamento de água superficial. Essa abordagem "*hard path*" trouxe muitos benefícios para milhões de pessoas, reduziu a incidência de doenças de veiculação hídrica, expandiu a agricultura irrigada e moderou os riscos de inundações e secas severas (Gleick, 2003). Isso ocorreu no contexto em que a autossuficiência em relação à disponibilidade de água doce e geração de energia elétrica eram sinônimos de desenvolvimento econômico e soberania nacional dos países. Assim, o monitoramento dos corpos de água torna-se um elemento essencial para uma eficiente gestão dos recursos hídricos.

Com o índice de aridez, expresso como a relação entre a quantidade média de precipitação anual e a quantidade de evapotranspiração potencial, é possível estabelecer uma classificação de terra seca (Pereira; Cordery; Iacovides, 2009). Assim, Marengo, Torres e Alves (2017) mostraram que a região semiárida do Nordeste do Brasil (NEB) é a região de terra seca mais populosa do mundo, vulnerável aos extremos observados da variabilidade climática interanual, cuja intensificação das irregularidades espaço-temporais no regime de precipitação e pouca variação sazonal da radiação solar constituem características importantes. Além disso, estimativas recentes, como as estudadas por Vieira *et al.* (2015), mostraram que 94% da região do semiárido no NEB está suscetível à desertificação. A fim de prevenir-se dos efeitos dos longos períodos de estiagem na região semiárida – caracterizada principalmente por rios intermitentes, função da baixa capacidade de retenção dos solos e das condições climáticas e meteorológicas desfavoráveis –, o poder público fomentou desde o fim do século XIX políticas para armazenamento de água, com a construção e a operação de reservatórios focadas majoritariamente nos nove estados do NEB e na parte norte do estado de Minas Gerais (Collischonn; Clarke, 2016).

Observações por sensoriamento remoto no período entre as décadas de 1980 e 2000

mostraram que aproximadamente 29% da área total global de terras tem experienciado reduções na produtividade de biomassa. Da área total de degradação do solo, cerca de 9,2% de terras secas passam por processo de desertificação (Bai *et al.*, 2008). Nesse sentido, no contexto de mudanças climáticas, o estado de Pernambuco, como parte do NEB, é considerado um dos estados mais vulneráveis do Brasil, enfrentando eventos extremos de seca nas regiões do Sertão e Agreste, com mais de 135 municípios em áreas suscetíveis à desertificação, deixando em risco mais de 2,6 milhões de pessoas (Pernambuco, 2011). Devido ao papel exercido pelos corpos hídricos nessas regiões (em especial aqueles usados para suprimento de demanda de água), manter o monitoramento do nível da água e o respectivo volume armazenado é fator crucial de modo a refletir a disponibilidade hídrica.

Sistemas convencionais de monitoramento hidrológico dependem da disponibilidade de redes de estações de medição de chuva e vazão, que fornecem medidas de precipitação e altura de água em qualquer tempo. Isso os tornam importantes ferramentas para previsão e alarme de cheias e gestão de tráfego fluvial. No entanto, dados providos de estações de medição são observações pontuais, de uma única dimensão – isto é, fornecem informações em um único ponto do corpo de água, como, por exemplo, a altura de água à jusante –, que não podem representar totalmente a distribuição espacial da água de superfície. Nesse sentido, o sensoriamento remoto surge como uma alternativa para fornecer informações complementares na extensão e altura da água de superfície sobre grandes áreas geográficas, com resolução espacial e frequência temporal significativas. Portanto, o monitoramento de água baseado em satélite pode dar suporte às autoridades hídricas com informações hidrológicas relevantes em áreas com monitoramento *in situ* limitado ou até mesmo inexistente, auxiliar no desenvolvimento de projetos de infraestrutura ou ajudar a entender os impactos das mudanças da hidrologia no ambiente, na economia e na saúde humana (Wieland; Martinis, 2020).

Martins *et al.* (2019) observaram, com o uso do satélite Landsat 8, que secas persistentes por longos períodos, quando estendem-se por diversos anos, podem causar impactos consideráveis sobre o nível de água de grandes reservatórios, como o reservatório de Sobradinho, localizado na bacia do Rio São Francisco (RSF), de modo que a extensão da superfície de água pode reduzir em mais da metade de sua extensão total. Como resultado, as comunidades ribeirinhas locais podem ter dificuldade no acesso à água. Além disso, os autores mostraram que os níveis de turbidez da água aumentam em períodos de chuva, o que pode afetar a estética e a qualidade da água.

Cooley, Ryan e Smith (2021) quantificaram a influência humana sobre o armazenamento

global de água superficial usando observações de sensoriamento remoto a partir de um laser altímetro do satélite ICESat-2. A análise foi feita sobre um conjunto de dados que quantificou a variabilidade do nível de água para 227.386 corpos d'água no período de outubro de 2018 a julho de 2020. Os resultados mostraram que 57% da variabilidade de armazenamento de água sazonal na Terra ocorre em reservatórios sob gerência humana. A proporção da variabilidade do nível de água associada aos reservatórios é maior em regiões áridas e semiáridas. Por exemplo, os autores mostraram que, para a bacia do Rio São Francisco, parte integrante do NEB, essa variabilidade alcançou um patamar de 99,8% – isto é, a variabilidade total dos níveis de água da bacia considerando corpos d'água naturais (lagos) e artificiais (reservatórios) é influenciada quase que restritamente em função destes últimos. Da alta variabilidade de armazenamento predominante em reservatórios decorre-se que, de um lado, em situações de precipitação intensa o assoreamento do corpo hídrico causado pela erosão sedimentar pode limitar o acesso seguro à água, e, por outro lado, os baixos níveis do reservatório reduzem a capacidade de diluição da água; nos dois casos a qualidade da água pode ser comprometida (Martins *et al.*, 2019).

O armazenamento de água doce não é apenas sinônimo de benefício para localidades que adotam esse recurso. São muitos os impactos negativos decorrentes do represamento de água, podendo citar, por exemplo, a degradação do solo que será alagado e da qualidade da água, riscos à fauna e à flora locais, desalojamento de comunidades ribeirinhas, aumento da evapotranspiração etc. Isso foi percebido ainda no período de expansão do número de reservatórios na segunda metade do século XX no cenário das discussões sobre mudanças climáticas, de tal modo que no mesmo período diversas obras de represamento foram desfeitas (Chao; Wu; Li, 2008). Uma vez reconhecido o limite da expansão dos reservatórios artificiais, as estratégias operacionais não-infraestruturais, chamadas também de "*soft path*", começaram a receber mais atenção nas últimas décadas, com destaque àquelas com foco na otimização da operação de reservatórios (He *et al.*, 2022; Yang *et al.*, 2023; Luo *et al.*, 2023).

Dado o contexto traçado até aqui, é possível concluir que as águas superficiais são recursos altamente dinâmicos que tanto respondem quanto trazem impacto às mudanças de uso do solo e da variabilidade climática e são parte inerente do ciclo hidrológico. Mudanças na extensão das águas superficiais podem ocorrer quando uma determinada área armazena temporariamente água sobre sua superfície após eventos de precipitação intensa ou aumento da vazão de rios, ou apresentam mudanças nas bordas de corpos d'água, fazendo-os expandir ou contrair sobre um tempo determinado (Vanderhoof *et al.*, 2023).

Considerando a importância do papel dos reservatórios no NEB, as limitações dos

sistemas convencionais de monitoramento de corpos hídricos e o potencial do uso de produtos de satélite para mapeamento de água superficial, é de importância significativa a busca por uma operacionalização abrangente do monitoramento dos reservatórios com a aplicação de sensoriamento remoto de modo a trazer melhorias para a gestão dos recursos hídricos e agilizar a tomada de decisão em situações de eventos extremos, como secas e cheias.

## 1.1 OBJETIVOS

O objetivo geral a que se pretendeu este trabalho foi analisar o uso de imagens de satélite de radar e óptico dos Sentinel 1 e Sentinel 2, respectivamente, no monitoramento de reservatórios em regiões semiáridas e de mata atlântica de Pernambuco. Para alcançar o objetivo geral proposto, fez-se necessário atingir os seguintes objetivos específicos:

- Investigar a viabilidade e aplicar algoritmos de detecção de água para extração da extensão de água superficial aos reservatórios selecionados no estado de Pernambuco;
- Avaliar a acurácia dos resultados da extensão de água superficial obtidos com as abordagens de detecção comparando os dados de área calculados com os dados observados de monitoramento *in situ* dos reservatórios;
- Desenvolver um método para correção de viés dos dados de área de água calculados.

## 2 REVISÃO DA LITERATURA

### 2.1 SEGURANÇA HÍDRICA

A água é essencial para todos os aspectos da vida. Tanto é verdade que os ecossistemas relacionados à água e ao meio ambiente historicamente forneceram locais para assentamentos humanos e tornaram-se, desse modo, berço para as primeiras civilizações (UN, 2018). Uma vez que a água é determinante para o pleno desenvolvimento das sociedades, as águas superficiais e subterrâneas próprias para o benefício humano direto e indireto são denominadas recursos hídricos. Se apenas sob o viés de consumo já era importante compreender a dinâmica cíclica desse recurso natural, agora, quando levado em conta o contexto de mudanças climáticas, torna-se ainda mais crucial o seu entendimento.

O ponto de partida é, portanto, entender no que consiste o ciclo da água, caracterizado em termos gerais como um sistema complexo e interconectado que representa a circulação da água pelos meios atmosférico, terrestre e marinho em suas diferentes fases, composto não apenas pela parte física, mas também por subsistemas biogeoquímicos, ecológicos e humanos cujas interações contribuem para a formação da Terra e para a manutenção da vida (Wagener *et al.*, 2010; Bogardi *et al.*, 2012).

O grande debate acerca das mudanças climáticas está relacionado ao aquecimento do planeta, com projeções futuras no intervalo de  $1,5^{\circ}\text{C}$  e  $2,0^{\circ}\text{C}$  para o aumento da temperatura média global. Entretanto, esse aumento não acontece de maneira uniforme, como mostrado por Lickley e Solomon (2018), em que as tendências de aquecimento em terras secas são o dobro da média global, ocasionando o aumento da frequência de eventos extremos de seca e cheia, com intensidade e duração maiores. Esse conjunto de fatores pode sobrecarregar a habilidade do solo em se recuperar, causando degradação. Gedney *et al.* (2006) mostraram que o aumento da concentração de dióxido de carbono  $\text{CO}_2$  e de outros gases do efeito estufa (decorrentes de atividades humanas) e o aumento associado de temperatura, bem como as mudanças de uso do solo, impactam diretamente o balanço hídrico, com mudanças nos padrões de precipitação, aumentando sua intensidade e variabilidade, alterando os fluxos e armazenamento de água superficiais e subterrâneos.

Um dos principais problemas paralelos e em constante relação com as mudanças climáticas são as formas do desenvolvimento socioeconômico e a crescente demanda por água, energia e alimento em função do contínuo crescimento populacional, cuja taxa de aumento

está na ordem de 80 milhões de pessoas ao ano (Falkenmark, 2013). Ambos os fenômenos, as mudanças climáticas e o crescimento populacional, exercem pressão sobre os recursos hídricos e constituem as forças motrizes para a escassez de água. Além da dinâmica natural peculiar do ciclo hidrológico de cada região do globo e das alterações provenientes das mudanças climáticas, o que também têm contribuído para os riscos de escassez hídrica são as especulações financeiras e os conflitos em torno dos recursos naturais que estão cada vez mais em disputa. Problemas esses já apontados pelo relatório do *Intergovernmental Panel on Climate Change* (IPCC, 2013), cujas projeções climáticas indicam um declínio dos recursos renováveis de águas superficiais e subterrâneas.

A crescente demanda hídrica agrava as condições de escassez nas regiões áridas e semiáridas, onde a baixa precipitação e a alta evaporação limitam a disponibilidade de água superficial e aumentam o risco de não conseguir manter a produção sustentável de alimentos e o desenvolvimento econômico. Nessas regiões, a disponibilidade de recursos hídricos superficiais frequentemente é insuficiente para atender as atividades intensas de irrigação, particularmente durante os períodos de crescimento da colheita (Wada *et al.*, 2016).

Todas essas questões em torno da água – dinâmica natural, demanda crescente, mudanças climáticas, conflitos etc. – levaram à necessidade de conceituar a forma de garantir o seu acesso universal. Assim, o conceito de segurança hídrica surgiu como uma resposta a essa natureza multifacetada da crise hídrica global e implica na capacidade de uma população salvaguardar o acesso à água em quantidade e qualidade aceitáveis para saúde, meios de subsistência, ecossistemas e produção, bem como o pleno controle dos riscos associados para as pessoas, meio ambiente e economia. Além disso, a segurança hídrica também está associada à capacidade de adaptação, incluindo previsão e resiliência, a eventos extremos e períodos de escassez, que serão cada vez mais frequentes (UN-Water, 2013; Grey; Sadoff, 2007; Scott *et al.*, 2013; Taffarello *et al.*, 2016).

A abordagem convencional para a segurança hídrica conforme conceituada e implementada por agências e instituições internacionais é estabelecer padrões sobre quanta água precisa estar disponível para atender às necessidades de saúde, meios de subsistência e ecossistemas, criar índices apropriados e, em seguida, acompanhar o progresso em relação a eles. Srinivasan, Konar e Sivapalan (2017) mostraram que, apesar do tratamento cada vez mais sofisticado das necessidades humanas e ambientais em relação à água, muitas definições e tentativas de quantificação têm sido inadequadas de várias maneiras. De maneira geral, muitos índices utilizados erram em levar em conta apenas o comportamento restrito das variáveis em análise, ignorando as

possíveis e prováveis interconexões entre os elementos. Portanto, um bom indicador deve ter em conta a interconectividade entre os sistemas humanos e hídricos e que caminhos essa relação pode levar, de modo a representar as diferenças climáticas, sociais e econômicas das regiões.

Nesse contexto, em 2019, no Brasil, foi divulgado o Plano Nacional de Segurança Hídrica (PNSH) (ANA, 2019), fruto de uma parceria entre o Ministério de Desenvolvimento Regional (MDR) e a Agência Nacional de Águas e Saneamento Básico (ANA). O PNSH definiu as principais intervenções em infraestrutura hídrica de natureza estratégica e relevância regional, necessárias para o abastecimento humano, para o uso em atividades produtivas e para melhorar a gestão dos riscos associados a eventos críticos (secas e cheias).

No arcabouço do PNSH foi elaborado o Índice de Segurança Hídrica (ISH) de forma a representar as quatro dimensões da segurança hídrica abordadas: (1) humana; (2) econômica; (3) ecossistêmica; e (4) resiliência. Cada uma dessas dimensões é formada por indicadores que combinam variáveis mensuráveis de modo a compor o índice global para o Brasil e representar da melhor forma a diversidade do território nacional. As dimensões e os indicadores utilizados na composição do ISH estão representados na Tabela 1.

Tabela 1 – Dimensões e indicadores do ISH

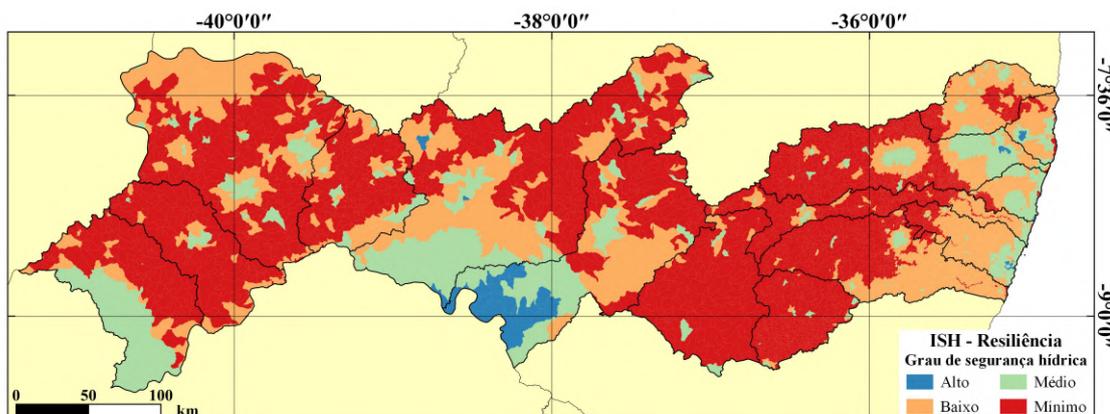
<b>Dimensão</b>	<b>Indicador</b>
<b>Humana</b>	Garantia de água para abastecimento humano
<b>Econômica</b>	Garantia de água para irrigação e pecuária Garantia de água para atividade industrial
<b>Ecossistêmica</b>	Quantidade adequada de água para usos naturais Qualidade adequada de água para usos naturais Segurança das barragens de rejeito de mineração
<b>Resiliência</b>	Reservação artificial Reservação natural Potencial de armazenamento subterrâneo Variabilidade pluviométrica

Fonte: ANA (2019).

Para o objetivo a que se pretende este trabalho, torna-se importante desenvolver mais o conceito da dimensão de resiliência, uma vez que esta expressa o potencial dos estoques de água naturais e artificiais para suprimento de demandas considerando eventos extremos de seca, que podem ser agravados pelas mudanças climáticas. Os quatro indicadores do ISH agregados a essa dimensão servem para avaliar o potencial de resiliência de uma dada região em função da soma total dos volumes de água disponíveis – rios, aquíferos e reservatórios.

A Figura 1 apresenta a distribuição espacial dos graus de segurança hídrica da dimensão de resiliência para o estado de Pernambuco.

Figura 1 – Dimensão resiliência do ISH para o Estado de Pernambuco



Fonte: ANA (2019), adaptado.

O grau de segurança hídrica (*gsh*) medido pelo ISH apresenta cinco níveis, sendo eles máximo, alto, médio, baixo e mínimo. Entretanto, nenhuma região do estado de Pernambuco foi classificada com grau máximo para a dimensão resiliência, conforme pode ser visto no mapa. Cerca de 81,5% do território pernambucano apresenta *gsh* de baixo à mínimo, enquanto apenas 2,6% é classificado com *gsh* alto.

As pequenas ilhas de mancha cujo *gsh* varia entre médio e alto observadas no mapa representam as localidades que contém reservatórios que resistem à variabilidade pluviométrica e que recebem suprimento de água nos períodos chuvosos e, portanto, permanecem operacionais, mesmo durante os períodos mais prolongados de estiagem. Nota-se ainda uma região considerável com *gsh* alto na região limítrofe ao estado da Bahia. Isso se deve à disponibilidade hídrica muito superior à demanda em função do Rio São Francisco, que é a principal fonte de abastecimento das regiões do Sertão e do Agreste, como mencionado pelo Plano Estadual de Recursos Hídricos (PERH) de Pernambuco (SEINFRA-PE, 2022).

## 2.2 SOBRE OS RESERVATÓRIOS EM PERNAMBUCO

O estado de Pernambuco é abastecido por mananciais predominantemente superficiais, com 85% das sedes urbanas atendidas nessa modalidade. A oferta de água no estado provém de mananciais estratégicos, sendo o RSF a principal solução para atendimento às cidades localizadas na região semiárida, que, além de atender aos municípios ribeirinhos, também abastece várias sedes municipais por meio de sistemas adutores integrados. Na região próxima ao litoral, destaca-

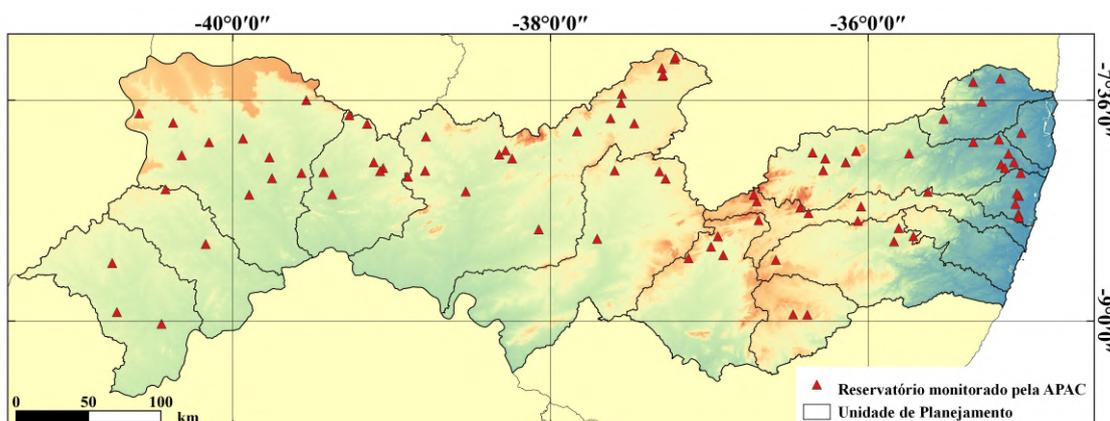
se o emprego de pequenos rios perenes e açudes como os de Pirapama, Gurjaú, Botafogo e Tapacurá, que abastecem cidades da Região Metropolitana de Recife (ANA, 2021).

De acordo com a mais recente atualização do PERH de Pernambuco (SEINFRA-PE, 2022), a responsabilidade pela fiscalização das barragens no estado de Pernambuco é dividida entre quatro autarquias:

- Agência Nacional de Águas e Saneamento Básico (ANA);
- Agência Nacional de Energia Elétrica (ANEEL);
- Agência Pernambucana de Águas e Clima (APAC);
- Secretaria de Estado do Meio Ambiente e dos Recursos Hídricos de Alagoas (SEMARH/AL);

O conhecimento da quantidade de água armazenada nos reservatórios de forma precisa e atualizada fornece dados e informações essenciais para auxiliar na gestão efetiva dos recursos hídricos. Nesse sentido, o volume de água acumulado é uma das variáveis mais importantes para a tomada de decisão, e pode ser obtido indiretamente, por meio de informações da batimetria do reservatório (características geométricas) e do nível de água em um dado tempo (ANA, 2016). Em Pernambuco, a APAC é responsável pela construção e atualização das curvas cota-área-volume (CAV) que facilitam a obtenção da informação da quantidade de água acumulada apenas pela leitura do nível de água. A Figura 2 apresenta a distribuição espacial dos reservatórios monitorados pela APAC em Pernambuco.

Figura 2 – Reservatórios monitorados pela APAC



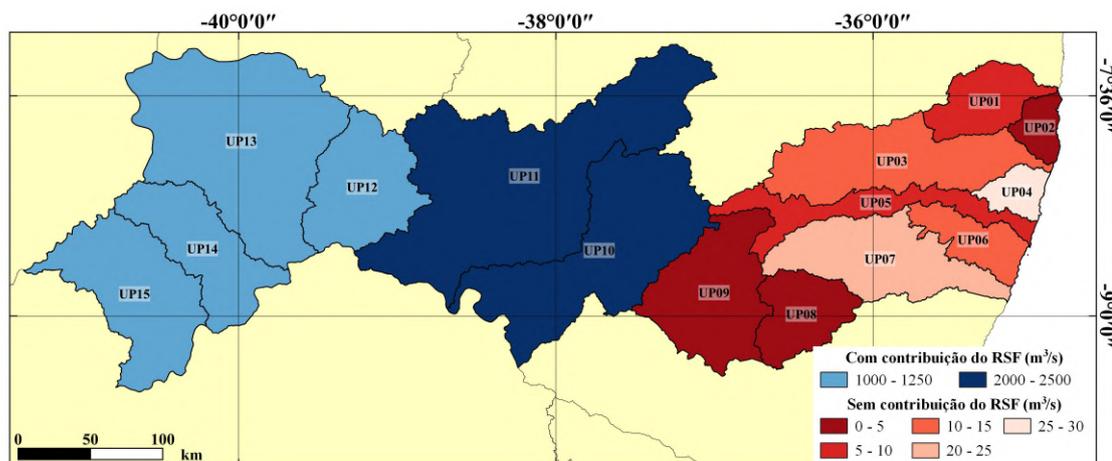
Fonte: Seinfra-PE (2022), adaptado.

Os dados e as informações de reservatórios são compilados no Sistema de Acompanhamento de Reservatórios<sup>1</sup>, citado daqui em diante como ANA-SAR, permitindo consultas, espacialização da informação e análise da operação de diversos reservatórios. Em Pernambuco, a ANA trabalha em parceria com a APAC no monitoramento de reservatórios.

Segundo ANA (2021), em uma avaliação dos mananciais e sistemas produtores em Pernambuco, 63% das sedes urbanas apresentam mananciais vulneráveis. A grande maioria dos municípios classificados como não vulneráveis são os abastecidos pelo RSF. Nas regiões do Agreste e do Sertão, mesmo com o aumento do número de reservatórios implantados, o que promove a segurança hídrica são as transferências de água entre os reservatórios e os pontos de demanda e, em especial, do RSF para os reservatórios existentes ou diretamente para os locais de demanda (SEINFRA-PE, 2022).

A Figura 3 apresenta a diferença de disponibilidade hídrica entre as unidades de planejamento (UP) com e sem contribuição do RSF em seus territórios.

Figura 3 – Disponibilidade Hídrica no estado de Pernambuco



Fonte: Seinfra-PE (2022), adaptado.

É possível notar que as disponibilidades hídricas do RSF são altas, muito superiores às dos demais rios no estado de Pernambuco. Nas UPs de rios que não têm o RSF em seus territórios, as disponibilidades hídricas são bem menores, com destaque às UPs 08 e 09, Rios Mundaú e Ipanema, respectivamente, que apresentam uma drástica redução, comparadas às suas vizinhas (SEINFRA-PE, 2022). Das UPs sem contribuição do RSF, têm destaque as UPs 04 e 07, Metropolitana Sul e Rio Una, respectivamente.

<sup>1</sup>Disponível em: <<https://www.ana.gov.br/sar/>>.

## 2.3 DETECÇÃO DE ÁGUA VIA SENSORIAMENTO REMOTO

Na medida em que as limitações das redes de medição *in situ* existentes possuem em fornecer uma base de conhecimento global das mudanças do volume de água armazenado nos diferentes corpos d'água foram reconhecidas (Alsdorf; Rodriguez; Lettenmaier, 2007), a tecnologia de sensoriamento remoto oferece caminhos mais efetivos e eficientes para observar a dinâmica da água superficial, pela sua habilidade de monitorar continuamente a superfície da Terra em múltiplas escalas (Huang, C. *et al.*, 2018).

O aumento do número de satélites usados hoje em dia em sensoriamento remoto permite o acesso fácil a um número extraordinário de observações (denominadas imagens ou cenas) com alta resolução temporal e espacial. A abordagem geral para extrair qualquer tipo de informação de cobertura da Terra por meio de uma imagem é baseada na capacidade de um objeto em refletir a energia radiante dentro de um determinado espectro. Uma vez definido o espectro da água e diferenciado dos demais espectros chamados de "não água", a comparação dos limites dos corpos de água superficial pode ser usada corretamente para mapear áreas com água (Condeça; Nascimento; Barreiras, 2022).

Existem geralmente duas categorias de sensores que podem servir ao propósito de medição de água superficial: o sensor óptico e o sensor de radar de abertura sintética (SAR – do inglês *Synthetic Aperture Radar*). Junto aos dois tipos de sensores, a maioria dos métodos automáticos de detecção de água via sensoriamento remoto podem também ser divididos em duas categorias: segmentação de limiar e classificação de imagem. A abordagem de segmentação usa principalmente observações de sensores ópticos a fim de construir modelos de classificação e índices de água/vegetação (Tulbure *et al.*, 2016). Enquanto a abordagem de classificação de imagem se apoia em observações de sensores SAR e utiliza o conhecimento do espectro, da textura e das características espaciais para extrair informações dos corpos d'água (Morandeira *et al.*, 2016).

### 2.3.1 Os sensores de radar e a missão Sentinel 1

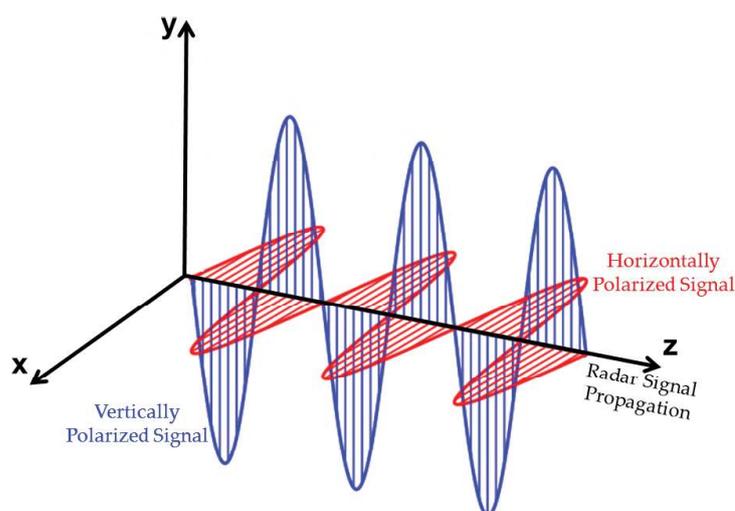
Os sensores de radar de abertura sintética são sistemas ativos de sensoriamento remoto e são capazes de medir com precisão a quantidade de energia retornada – isto é, o retroespalhamento –, e podem, assim, delinear com precisão o terreno, independentemente do tempo e do clima. A utilização do SAR para o mapeamento da superfície da água torna-se possível porque o retroespalhamento SAR da água é muito baixo uma vez que a superfície desse recurso natural é

lisa. Como resultado, as áreas inundadas aparecem em tons escuros devido à baixa resposta de retroespalhamento, enquanto a superfície terrestre aparece em tons brilhantes porque a superfície de geometria irregular e áspera do solo e da vegetação produzem reflexão difusa, resultando em um forte retroespalhamento (Manjusree *et al.*, 2012).

Os sistemas SAR transmitem micro-ondas eletromagnéticas de sua antena de radar e registram o sinal de retroespalhamento. A sensibilidade dos sensores SAR é uma função de dois conjuntos de fatores. O primeiro conjunto é referente às características do sensor – banda, polarização e ângulo de incidência do sinal eletromagnético transmitido. Enquanto o segundo conjunto refere-se às propriedades geométricas e dielétricas do alvo a ser observado pelo radar. Os alvos de radar podem ser discriminados em uma imagem SAR se seus componentes de retroespalhamento forem diferentes e se a resolução espacial do radar for suficiente para fazer a distinção dos alvos (Schumann; Moller, 2015; Dabboor; Brisco, 2018).

Os sistemas convencionais de sensoriamento remoto do tipo SAR transmitem sinal de radar polarizado horizontal e/ou verticalmente e recebem os componentes do sinal de retroespalhamento polarizado horizontal e/ou vertical. Em sistemas SAR a polarização refere-se à orientação do campo elétrico da onda eletromagnética (Dabboor; Brisco, 2018) e, como citam Schumann e Moller (2015), descreve a direção na qual os materiais refletem os sinais e o sensor SAR os recebem. A Figura 4 representa de modo cartesiano a propagação do sinal de radar.

Figura 4 – Polarização do sinal de radar



Fonte: Dabboor e Brisco (2018).

Existem três tipos de sensor SAR com diferenças na configuração da polarização que podem ser simples, dupla e totalmente polarimétrica. Um sistema SAR de polarização simples transmite um sinal polarizado horizontal ou verticalmente e recebe o componente polarizado

horizontal ou vertical do sinal de retorno. Um sistema SAR de polarização dupla transmite um sinal polarizado horizontal ou verticalmente e recebe ambos os componentes polarizados horizontal e vertical do sinal retornado. Um sistema SAR de polarização simples ou dupla adquire informações parciais com relação ao estado polarimétrico completo do alvo do radar. Um sistema SAR totalmente polarimétrico transmite sinal polarizado alternadamente na horizontal e na vertical e recebe retornos em ambas as polarizações ortogonais, permitindo informações completas do alvo do radar (Dabboor; Brisco, 2018). Na literatura, o sinal polarizado horizontalmente é representado com a letra *H*, enquanto o sinal polarizado verticalmente é representado com a letra *V*.

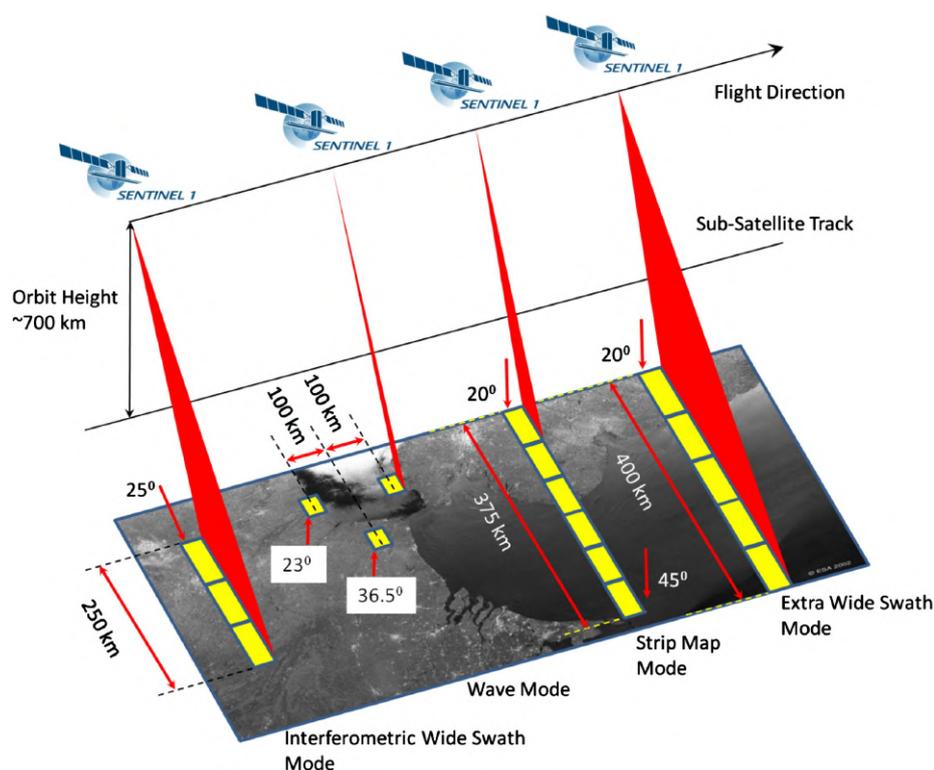
Os sensores SAR têm sido amplamente usados para mapeamento e monitoramento de água superficial, indo desde à observação de reservatórios até o monitoramento de áreas suscetíveis à inundação. Martinis, Twele e Voigt (2009) apresentaram uma abordagem de detecção de cheia com o uso de dados SAR de polarização simples do satélite TerraSAR-X para regiões da Inglaterra. Bolanos *et al.* (2016) usaram dados SAR do satélite Radarsat 2 para mapeamento automático de água nas pradarias canadenses sem a necessidade de dados auxiliares. A fim de demonstrar a utilidade de dados multi-temporais SAR para caracterização da superfície terrestre, especialmente para a detecção de corpos d'água, Santoro e Wegmüller (2014) usaram um conjunto de dados de imagens Envisat Advanced SAR (*Envisat ASAR*) aplicados a paisagens bastante diversas e em diferentes condições sazonais e ambientais.

Existem diversos métodos na literatura para detecção e mapeamento de água com o uso de imagens SAR. Dentre esses, pode-se citar limiarização de histograma (Manjusree *et al.*, 2012; Santoro *et al.*, 2015), lógica fuzzy (Martinis; Plank; Ćwik, 2018), abordagens de classificação (Morandeira *et al.*, 2016; Dabboor; Brisco, 2018). As técnicas mais bem estabelecidas e usadas, como as de limiarização de histograma, por exemplo, permitem separar o baixo retroespalhamento da água superficial usando um valor de limiar. Entretanto, o sinal de retroespalhamento pode ser afetado por águas com aparência rugosa movimentadas pelo vento, por vegetações flutuantes e de borda, ou ainda pelo ângulo de incidência do sensor. Em casos desse gênero, o valor de limiar do método precisa ser modificado cena por cena (Brisco *et al.*, 2009; White *et al.*, 2014).

Além dos satélites mencionados, existe também o satélite Sentinel 1 – tido como uma continuação do Envisat ASAR –, lançado pela missão de mesmo nome e operado pela Agência Espacial Europeia (ESA – do inglês *European Space Agency*) no quadro do Programa Copernicus da União Europeia. O Sentinel 1 consiste de dois sensores de satélite de aquisição sistemática

(Sentinel 1A e Sentinel 1B<sup>2</sup>) com um ciclo de repetição de 6 dias para a constelação final. Os sensores Sentinel 1A e 1B são equipados com uma carga útil SAR de Banda C operando em uma frequência central de 5,405 GHz. Os sensores Sentinel 1 suportam operações em polarização dupla ( $HH/HV$ ,  $VV/VH$ ) implementada através de uma cadeia de transmissão (podendo ser  $H$  ou  $V$ ) e duas cadeias de recepção paralelas para polarização  $H$  e  $V$  – ou seja, serão geradas duas imagens em cada data de aquisição: para produtos do tipo  $HH/HV$  serão geradas imagens em que o sinal  $H$  foi transmitido e foram retornadas e recebidas sinais  $H$  e  $V$ ; a mesma situação acontece para produtos do tipo  $VV/VH$ , com o sinal  $V$  transmitido e os sinais  $V$  e  $H$  retornados e recebidos. Os produtos Sentinel 1 podem ser adquiridos em quatro modos: (1) o modo interferométrico de faixa ampla (IW – do inglês *Interferometric Wide-swath*); (2) o modo de onda (WV – do inglês *Wave*); (3) o modo mapa de faixas (SM – do inglês *Strip Map*); e (4) o modo de faixa extra larga (EW – do inglês *Extra Wide-swath*) (Torres *et al.*, 2012). A Figura 5 apresenta os modos do Sentinel 1.

Figura 5 – Modos do Sentinel 1



Fonte: Torres *et al.* (2012).

Para observações terrestres, o modo IW é o tipo de imagem operacional principal, usado por padrão, adquirindo dados SAR de polarização dupla com polarização  $VV/VH$ . Ele adquire

<sup>2</sup>O satélite Sentinel 1B apresentou problemas operacionais em dezembro de 2021, culminando em sua inativação. A partir dessa data, os produtos Sentinel 1 passaram a ter ciclo de repetição de 12 dias (ESA, 2022).

dados com uma faixa de 250 km com resolução espacial de 5 m por 20 m, equivalente a um *pixel*. Os dados Sentinel 1 no modo IW foram aplicados em diversos estudos no campo da hidrologia. Por exemplo, Twele *et al.* (2016) apresentaram uma abordagem automatizada para detecção e monitoramento de cheia em tempo quase real na fronteira entre a Grécia e a Turquia. Por sua vez, Conde e Muñoz (2019) avaliaram o potencial do uso de imagens Sentinel 1 para o mapeamento da extensão de cheias em tempo real, essencial para a tomada de decisão e mitigação de riscos. Huang, W. *et al.* (2018) descreveram uma abordagem de árvore de classificação totalmente automática para mapeamento da extensão da superfície de água.

Mudanças contínuas na extensão da água superficial necessitam de produtos de satélite confiáveis, precisos e de alta resolução espacial e temporal. Os lançamentos dos Sentinel 1A e 1B melhoraram muito as oportunidades para observações de dinâmicas de inundação, incluindo melhorias na detecção de cheias, e mapeamento aprimorado de pântanos ( $< 1$  ha) e riachos menores (Vanderhoof *et al.*, 2023). A facilidade com que a superfície de água pode ser mapeada vai depender do tipo de cobertura do solo, do tamanho do corpo d'água e da estrutura da vegetação. Entretanto, enquanto os produtos do satélite Sentinel 1 se mostraram efetivos para o mapeamento de águas profundas e abertas, a presença de águas rasas, bem como vegetação, tanto emergente quanto florestal, diminui a precisão com que a água pode ser mapeada (Leeuwen; Tobak; Kovács, 2020).

### 2.3.2 Os sensores ópticos e a missão Sentinel 2

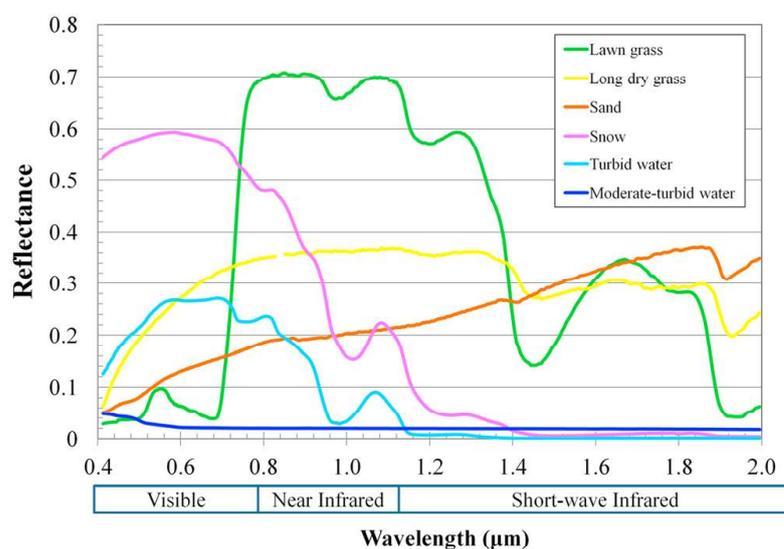
As imagens ópticas são parte do sensoriamento remoto passivo, que obtêm o espectro de objetos terrestres pelo recebimento da luz solar refletida, principalmente nas bandas visíveis e infravermelho. Dados ópticos são as fontes primárias usadas atualmente para extração de informações de corpos d'água (Li *et al.*, 2022). Comparando com outros objetos terrestres, a água possui uma baixa refletividade nas bandas visíveis e próximas ao infravermelho, e essa característica constitui o princípio para o mapeamento e a extração de água superficial (Huang, C. *et al.*, 2018). Uma vez que os sensores ópticos capturam informações de maneira passiva, a resolução espacial constitui fator determinante para a qualidade da imagem e o nível de detalhes capturados pelo sensor.

Os satélites de sensores ópticos podem ser classificados de acordo com sua resolução espacial: (a) baixa ( $> 200$  m); (b) média (10–200 m); e (c) alta ( $< 10$  m). Os sensores de baixa resolução têm como característica um alto nível de generalização de informação, embora geralmente possuam alta resolução temporal e ampla cobertura, podendo citar como exemplo os

satélites NOAA/AVHRR e MODIS. Já a série de sensores Landsat de scanner multiespectral (MSS – do inglês *Multispectral Scanner*), mapeador temático (TM – do inglês *Thematic Mapper*), mapeador temático aprimorado (ETM+ – do inglês *Enhanced Thematic Mapper Plus*) e imageador terrestre operacional (OLI – do inglês *Operational Land Imager*) é caracterizada como média resolução espacial (Huang, C. *et al.*, 2018).

Diversas abordagens foram desenvolvidas a fim de extrair a área de água em imagens ópticas. Por exemplo, a água pode ser detectada e extraída pela escolha de um valor de limiar que segmente os *pixels* de água – uma vez que possuem baixa reflectância, especialmente nas faixas do infravermelho próximo e do infravermelho de ondas curtas (Figura 6) – das demais classes de *pixels* aplicado em uma banda espectral ou em um conjunto de bandas espectrais. O método de detecção de água mais utilizado em imagens ópticas é aquele que combina duas ou mais bandas espectrais. Isso porque a abordagem de segmentação utilizando apenas uma banda, apesar de sua simplicidade e facilidade de implementação, possui baixa precisão, já que as imagens apresentam características multifacetadas do solo (sombras de montanhas, concreto, asfalto etc.) (Li *et al.*, 2022).

Figura 6 – Reflectância de diversos tipos de objetos da cobertura terrestre



Fonte: Huang, C. *et al.* (2018).

As imagens Landsat têm sido amplamente utilizadas para geração de mapas de cobertura e uso do solo e, principalmente, para mapeamento de água superficial. É o caso, por exemplo, do MapBiomass, uma iniciativa do Sistema de Estimativas de Emissões de Gases de Efeito Estufa do Observatório do Clima (SEEG/OC) e produzido por uma rede colaborativa formada por universidades, empresas de tecnologia e ONGs em 2015 para desenvolver um método de baixo

custo de produção de séries temporais anuais de cobertura e uso do solo no Brasil com imagens Landsat processadas pela plataforma *Google Earth Engine* (GEE) com resolução espacial de 30 m inicialmente no período 1985–2017 (Souza *et al.*, 2020). Os produtos MapBiomás já estão em sua Coleção 8, que incluem mapas de água superficial nas escalas anual e mensal geradas para o período 1985–2022 em todo o território brasileiro (SEEG/OC, 2022).

Na classe dos sensores ópticos de média resolução espacial está o satélite Sentinel 2, lançado pela missão de mesmo nome e, assim como o Sentinel 1, operado pela ESA no quadro do Programa Copernicus da União Europeia. A missão Sentinel 2 foi projetada de tal modo que, com um sistema operacional multiespectral de observação terrestre, complementa as observações nos quadros das missões Landsat e do Satélite de Observação da Terra (SPOT – do francês *Satellite Pour l’Observation de la Terre*). Portanto, o Sentinel 2 fornece uma continuidade aos serviços que dependem de observações ópticas multiespectrais de alta resolução espacial sobre a superfície da Terra (Drusch *et al.*, 2012).

A missão Sentinel 2 é composta por dois satélites: o Sentinel 2A, lançado em 2015; e o Sentinel 2B, lançado em 2017. Os dois satélites foram colocados na mesma órbita, com fases de 180° entre si. Essa estratégia permitiu o aumento do tempo de revisita de 10 dias, quando utilizado apenas um satélite, para 5 dias, com a utilização de dois satélites em fases opostas. Os satélites da missão Sentinel 2 foram equipados com um sensor de Instrumento MultiEspectral (MSI – do inglês *MultiSpectral Instrument*), para detectar radiações eletromagnéticas em 13 bandas espectrais nas faixas visíveis (VIS), infravermelho próximo (NIR – do inglês *near infra-red*) e infravermelho de ondas curtas (SWIR – do inglês *short wave infra-red*), operando em diferentes resoluções espaciais no intervalo 10–60 m (Drusch *et al.*, 2012; Filippucci *et al.*, 2022). Para que as observações Sentinel 2 adquiram as qualidades para as quais foram projetadas, os produtos básicos de Nível 1 passam por registros geométricos e calibração radiométrica. Os produtos Sentinel 2 passam, então, por uma série de refinamentos, de modo que os níveis de qualidade das imagens disponibilizadas aos usuários são os seguintes (ESA, 2015):

- Nível 1B: é o menor produto disponível, em uma grade de tamanho  $25 \times 23 \text{ km}^2$ . O Nível 1B fornece imagens corrigidas radiometricamente nos valores de radiância do topo da atmosfera;
- Nível 1C: resultado do uso de um modelo digital de elevação para projetar a imagem em coordenadas cartográficas. Esse nível fornece imagens de reflectância do topo da atmosfera projetadas em UTM/WGS84. Máscaras de solo/água e nuvem estão associadas ao produto.

Possui uma grade de tamanho equivalente a  $100 \text{ km}^2$ ;

- Nível 2A: Esse nível fornece imagens de reflectância do fundo da atmosfera derivadas dos produtos de Nível 1C. Os produtos de Nível 2A não são gerados sistematicamente no segmento terrestre; são, portanto, imagens de Nível 1C pós-processadas.

Os produtos Sentinel 2 de níveis 1C e 2A são os mais utilizados para observações terrestres, especialmente em estudos hidrológicos e hidrodinâmicos. Filippucci *et al.* (2022) usaram as bandas do espectro NIR de observações Sentinel 2 de Nível 1C para identificar *pixels* de água em torno da seção de um rio e estimar seu volume de descarga. Du *et al.* (2016) utilizaram produtos de Nível 1C para testar diferentes índices espectrais com diferentes combinações de bandas nas faixas VIS e SWIR para avaliar o mapeamento de corpos d'água. Por sua vez, Yang *et al.* (2018) usaram produtos de Nível 2A gerados a partir de produtos de Nível 1C pelo modelo oficial de correção atmosférica Sen2Cor. Os autores apresentaram um método para correção de detecção de água em aplicações de área urbana, em situações em que corpos de “não água” são classificados como “água”.

As imagens multiespectrais do Sentinel 2 são usadas principalmente através da aplicação de um limiar em índices espectrais para detecção de água. É o caso, por exemplo, do Índice de Água de Diferença Normalizada (NDWI – do inglês *Normalized Difference Water Index*), do NDWI Modificado (MNDWI – do inglês *Modified NDWI*), do Índice de Água Multi-Banda (MBWI – do inglês *Multi-Band Water Index*), do Índice de Extração de Água Automatizado (AWEI – do inglês *Automated Water Extraction Index*) (McFeeters, 1996; Xu, 2006; Wang *et al.*, 2018; Feyisa *et al.*, 2014). Esses índices geralmente são empregados com um procedimento de calibração para cada data de aquisição e área de cobertura, como a limiarização de Otsu, que divide os valores dos índices em um histograma bimodal nas classes "água" e "não água" (Otsu, 1979).

Mesmo com métodos bem definidos e leitura de dados disponíveis de sensores ópticos para aplicações de mapeamento de superfície de água, seu uso é limitado por nuvens e sombras que obscurecem as observações da superfície (Alsdorf; Rodriguez; Lettenmaier, 2007; Huang, W. *et al.*, 2018; Li *et al.*, 2022); a extensão máxima da água em lagos e reservatórios pode ocorrer durante eventos de cheia enquanto há cobertura de nuvens, resultando em lacuna de dados e uma incapacidade de capturar a magnitude precisa de tais eventos. Dados SAR, por outro lado, podem preencher essas lacunas, uma vez que imagens de radar podem ser adquiridas para todas as condições climáticas, seja dia ou noite (Markert *et al.*, 2018).

Para superar as limitações inerentes aos sensores ópticos, os produtos Sentinel 2 podem ser utilizados em conjunto com produtos de outros satélites. É o caso do estudo feito por Martinis *et al.* (2022), no qual propuseram uma metodologia em que combinam programas de processamento já existentes para detecção de cheias baseados em dados Sentinel 1 e Sentinel 2 para geração de máscaras de água permanentes e sazonais em um período de tempo de referência ajustável. Nesse estudo, a fim de desenvolver uma ferramenta automatizada para aplicações em monitoramento de cheias, as máscaras de água são primariamente baseadas em produtos Sentinel 2 e são, então, complementadas pela análise de dados Sentinel 1 em regiões escassas de dados ópticos. Rättich, Martinis e Wieland (2020) também apresentaram um método de geração de máscaras de água para monitoramento de cheias usando dados dos satélites Sentinel 1, Sentinel 2, Landsat-8 e TerraSAR-X.

### 2.3.3 Dois algoritmos de detecção de água: *SurfWater* e *WaterDetect*

Como já citado, os algoritmos de detecção de água podem combinar diferentes tipos de observações – sejam elas provenientes de sensores ópticos ou de radar – dentro de uma janela de tempo para produzir mapas mais precisos para uma data específica. É o caso do algoritmo *SurfWater*, desenvolvido por Peña-Luque *et al.* (2021), do Centro Nacional de Estudos Espaciais da França (CNES – do francês *Centre National d'Etudes Spatiales*), que pode ser usado com observações Sentinel 1 e Sentinel 2, de modo restrito ou simultâneo. O algoritmo é complementado ainda com dois conjuntos de dados auxiliares, usados para selecionar automaticamente amostras de aprendizado ou para aplicar correções sobre as máscaras de água derivadas de imagens de radar ou ópticas. São eles: (a) dados de ocorrência de superfície de água global (Pekel *et al.*, 2016), escolhido para identificar as águas globalmente permanentes, usados como dados de treino para detecções de água de radar por amostragem de nível de *pixel*; e (b) dados de relevo acima de área de drenagem mais próxima (HAND – do inglês *Height Above Nearest Drainage*) (Nobre *et al.*, 2011) derivado do MERIT DEM (Yamazaki *et al.*, 2019), usado para identificar áreas livres de inundação, de modo que essas zonas sempre serão detectadas como “não-água”.

A abordagem de detecção de água *WaterDetect*, desenvolvido por Cordeiro, Martinez e Peña-Luque (2021), consiste em um algoritmo automático não-supervisionado e não-paramétrico para identificação de *pixels* de água em grandes cenários a partir de uma única imagem proveniente de sensores ópticos das missões Sentinel 2 e Landsat 8 utilizando métodos automáticos para processamento de imagens sem a necessidade do uso de dados auxiliares ou mosaico de séries temporais. Diferente de outras abordagens de limiarização que usam apenas uma dimensão,

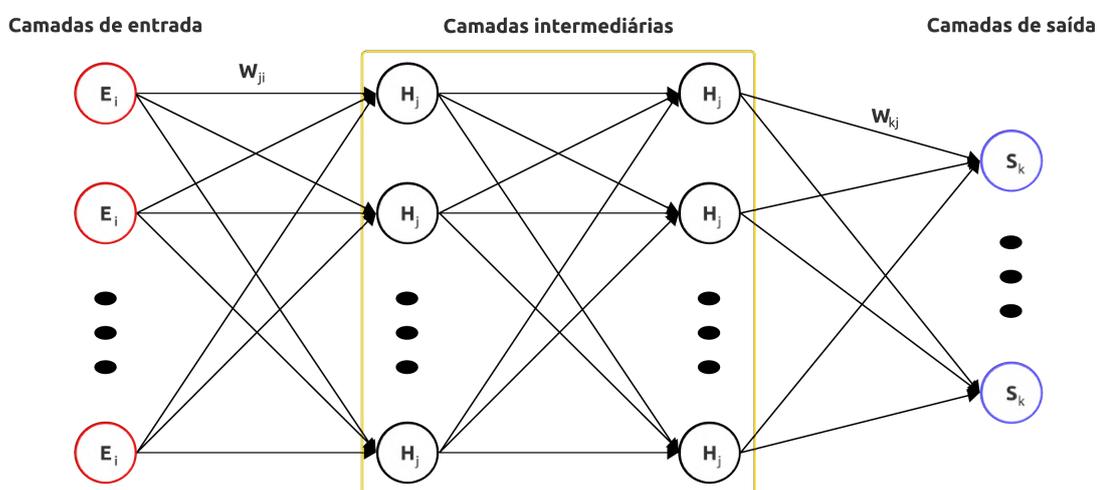
como a utilização de um índice de água, esse algoritmo combina diferentes índices de água e bandas espectrais em agrupamentos hierárquicos multidimensionais.

## 2.4 REDES NEURAIS ARTIFICIAIS

O aprendizado de máquina (*Machine Learning*) é um subcampo da inteligência artificial que se preocupa com o *design* e o desenvolvimento de algoritmos que permitem que os computadores aprendam empiricamente o comportamento de conjuntos de dados. Neste subcampo existe a chamada Rede Neural Artificial (RNA), um sistema de processamento de informações que replica o comportamento do cérebro humano pela imitação das operações e conectividade dos neurônios biológicos (Lary *et al.*, 2009; Chung *et al.*, 2022).

As RNAs, conhecidas como neurônios artificiais, executam funções matemáticas e são dispostas em uma ou mais camadas interligadas por um grande número de conexões com pesos associados, que ponderam a entrada recebida por cada neurônio da rede (Faceli *et al.*, 2019). Em uma RNA, funções complexas e não lineares com muitos parâmetros são ajustadas no estágio de treinamento para fazer com que as saídas da RNA sejam similares ao conjunto de dados observado (Chung *et al.*, 2022). A estrutura de uma RNA típica inclui camada de entrada, camada intermediária (que pode ser uma ou mais camadas intermediárias) e camada de saída. A Figura 7 apresenta um exemplo de uma RNA. Aqui,  $i$ ,  $j$  e  $k$  são os índices dos nós para as camadas de entrada, intermediárias e de saída, respectivamente,  $E_i$  é a variável de entrada,  $S_k$  é a variável de saída,  $W_{ji}$  é o peso que conecta a camada de entrada à camada intermediária e  $W_{kj}$  é o peso que conecta a camada intermediária à camada de saída.

Figura 7 – Rede Neural Artificial



Fonte: O autor (2023).

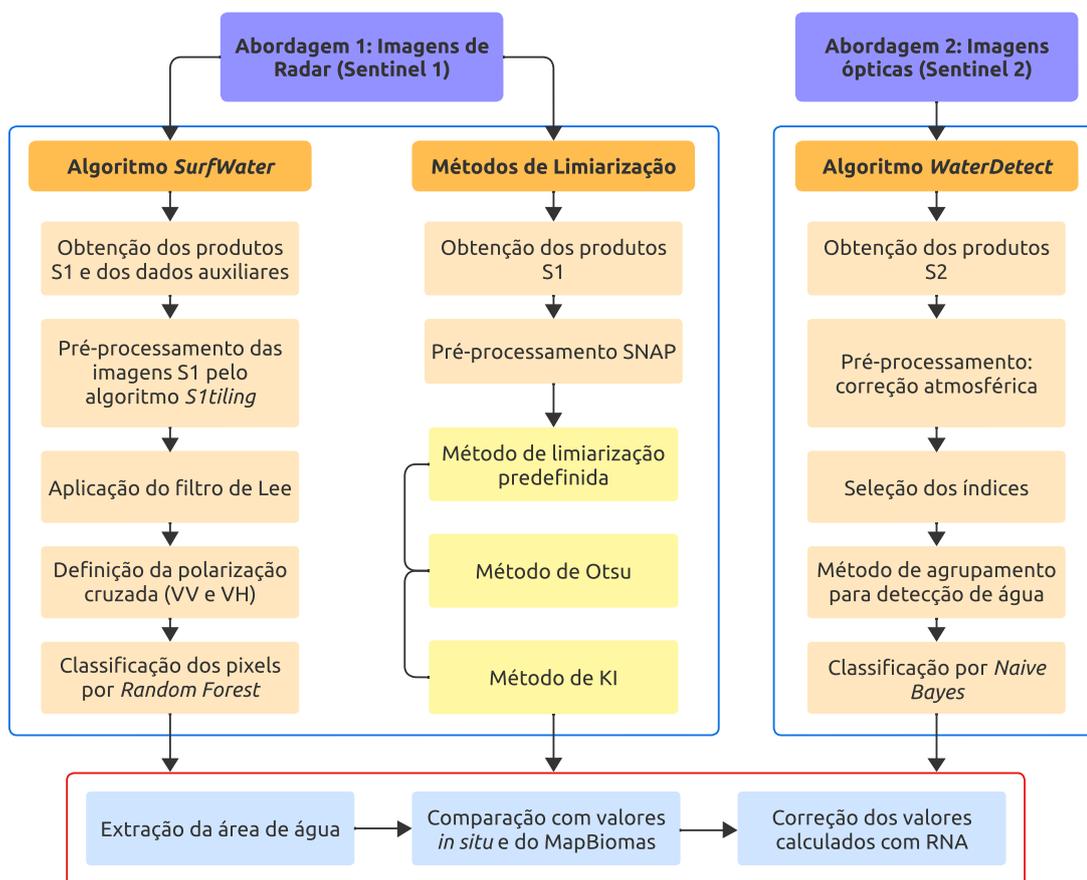
A RNA é caracterizada pelos processos de simulação e resposta para aprender a resposta correta para cada entrada por meio de treinamento. A função geral entre a entrada e a saída é chamada de função de ativação, que pode ser tanto uma função linear quanto uma função não linear (Jabbari; Bae, 2018).

As RNAs têm sido amplamente usadas para diversos propósitos, como, por exemplo, estimativa de precipitação (Tapiador *et al.*, 2004; Pan *et al.*, 2019), modelagem hidrológica (Aichouri *et al.*, 2015; Peng *et al.*, 2017), previsão de cheias (Tayfur *et al.*, 2018; Tien Bui *et al.*, 2018), estimativa de umidade do solo (Said; Kothyari; Arora, 2008; Paloscia *et al.*, 2013). Mais recentemente, as RNAs foram aplicadas para correção de viés em dados provenientes de satélites (Moghim; Bras, 2017; Le *et al.*, 2020; Han, L. *et al.*, 2021; Han, G. *et al.*, 2022), entretanto tais aplicações ainda estão em estado de primeiros passos.

### 3 MATERIAIS E MÉTODOS

Para alcançar o propósito deste trabalho, foram adotadas duas abordagens metodológicas. A primeira abordagem consistiu no uso de imagens de radar da missão Sentinel 1 seguindo dois caminhos: (1) aplicação do algoritmo *SurfWater*; e (2) aplicação de métodos de limiarização. A segunda abordagem consistiu na utilização de imagens ópticas da missão Sentinel 2 para detecção de água com o algoritmo *WaterDetect*. Os algoritmos *SurfWater* e *WaterDetect* detectam a água de maneira automática. Em contrapartida, os três métodos de limiarização selecionados para análise – predefinida, Otsu e Kittler-Illingworth (KI) – foram aplicados de maneira manual por meio de rotinas. A Figura 8 apresenta o fluxograma da metodologia utilizada.

Figura 8 – Fluxograma da metodologia adotada neste trabalho



Fonte: O autor (2023).

Após a detecção e geração das máscaras de água em cada uma das duas abordagens, foram calculadas as áreas de água e comparadas com os valores de monitoramento *in situ* obtidos pelo ANA-SAR e com os valores de área de água superficial em escala mensal calculados pelo MapBiomas para cada um dos reservatórios selecionados. Além disso, foi aplicado um modelo

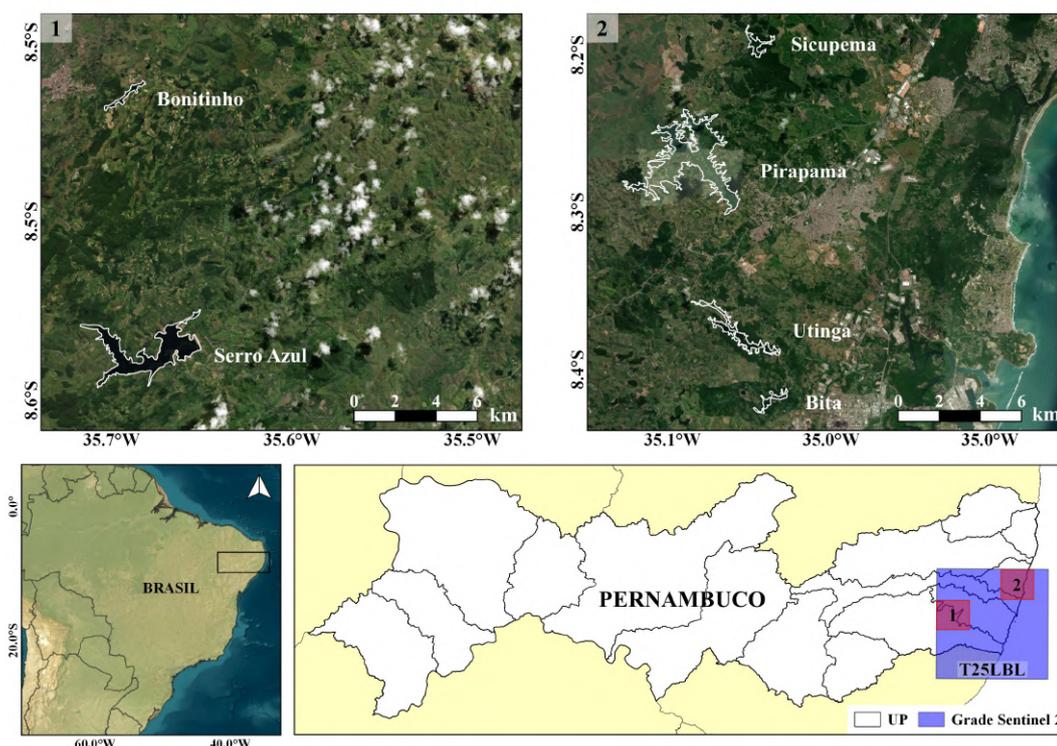
de RNA para correção dos dados de área de água extraídos dos produtos de satélite. Foi utilizada a linguagem de programação Python 3 em todas as etapas de detecção, extração e correção da área de água.

### 3.1 ABORDAGEM 1: IMAGENS DE RADAR

#### 3.1.1 Área de estudo

A primeira abordagem metodológica desenvolvida no âmbito deste trabalho foi aplicada no estado de Pernambuco, localizado no NEB. A seleção dos reservatórios para aplicação e avaliação das abordagens propostas deveu-se a dois fatores. O primeiro fator está relacionado a uma limitação da disponibilidade de dados de sensoriamento remoto utilizados pelo algoritmo *SurfWater*, que será tratado em seção posterior. O segundo fator levou em conta apenas os reservatórios monitorados pelo ANA-SAR. Foram escolhidos, portanto, seis reservatórios na zona da Mata do estado e Região Metropolitana de Recife considerando a quadrícula T25LBL da grade Sentinel 2: Sicupema, Pirapama, Utinga, Bitá, Bonitinho e Serro Azul. A Figura 9 apresenta a configuração espacial da área de estudo e a localização dos reservatórios que serão analisados. A Tabela 2 apresenta dados fornecidos pela APAC com as características de área superficial máxima e capacidade de armazenamento máxima dos reservatórios selecionados.

Figura 9 – Configuração espacial da área de estudo (Abordagem 1)



Fonte: O autor (2023).

Tabela 2 – Características dos reservatórios (Abordagem 1)

Reservatório	Área superficial máxima (km <sup>2</sup> )	Capacidade máxima (hm <sup>3</sup> )
Sicupema	0,114	3,20
Pirapama	12,780	60,88
Utinga	1,662	10,43
Bitá	0,823	2,77
Bonitinho	0,727	1,84
Serro Azul	9,263	303,12

Fonte: O autor (2023).

### 3.1.2 Dados utilizados

A detecção de água em reservatórios nesta abordagem com o algoritmo *SurfWater* e com os métodos de limiarização foi feita utilizando imagens de radar do satélite Sentinel 1 no período de 1º de janeiro de 2016 a 30 de abril de 2023. Os produtos foram obtidos com tempo de revisita de aproximadamente 12 dias. No modo de aquisição principal (IW), o produto de Alcance de Solo Detectado (GRD – do inglês *Ground Range Detected*) em alta resolução de Nível 1 possui resolução de  $20,4 \times 22,5 m$  e espaçamento de *pixel*, a distância entre *pixels* adjacentes em uma imagem, equivalente a  $10 \times 10 m$  na polarização dupla VV/VH. Para a aplicação do *SurfWater* foram utilizadas 365 imagens obtidas da base de dados PEPS, a plataforma francesa de distribuição dos dados Sentinel 1 e 2. Para a aplicação dos métodos de limiarização, foram utilizadas 122 imagens obtidas da base de dados Copernicus.

Para os dados auxiliares utilizados pelo *SurfWater*, os dados de ocorrência de água superficial foram adquiridos da plataforma *Global Surface Water*<sup>3</sup> (Pekel *et al.*, 2016) na grade 40W 0N. Os dados HAND foram obtidos da base de dados MERIT *Hydro*<sup>4</sup> na grade S30 W060. Por fim, foram obtidas informações topográficas de inclinação do solo da base de dados SRTM<sup>5</sup>.

### 3.1.3 Algoritmo *SurfWater*

Para que as imagens de radar possam ser processadas pelo *SurfWater*, é necessário que os dados Sentinel 1 sejam reprojatados para a grade e resolução dos produtos Sentinel 2 de Nível 2A. Esse pré-processamento dos dados de entrada é feito pela biblioteca S1tiling<sup>6</sup>, implementada em Python 3, que faz a calibração, projeção e concatenação das imagens de radar.

<sup>3</sup>Disponível em: <<https://global-surface-water.appspot.com>>.

<sup>4</sup>Disponível em: <[https://hydro.iis.u-tokyo.ac.jp/~yamada/MERIT\\_Hydro](https://hydro.iis.u-tokyo.ac.jp/~yamada/MERIT_Hydro)>.

<sup>5</sup>Disponível em: <<https://www2.jpl.nasa.gov/srtm>>.

<sup>6</sup>Disponível em: <<https://s1-tiling.pages.orfeo-toolbox.org/s1tiling>>.

Todo o processamento do algoritmo *SurfWater* foi realizado em um *cluster* de alta performance dentro da infraestrutura computacional do CNES, cujo acesso foi disponibilizado para uso restrito neste trabalho. Como já citado, o *SurfWater* pode ser usado para processar imagens provenientes tanto do Sentinel 1 quanto do Sentinel 2. Entretanto, no âmbito desta abordagem foram utilizados somente produtos Sentinel 1, uma vez que os reservatórios analisados estão localizados na região litorânea do estado de Pernambuco, caracterizada por uma extensa cobertura de nuvens durante todo o período do ano. Essa limitação dá-se pelo fato de que o servidor CNES usa como referência imagens Sentinel 2 Nível 2A geradas pelo processador MAJA (Hagolle *et al.*, 2010), disponibilizadas pelo centro de dados THEIA<sup>7</sup>, para a etapa de pré-processamento dos produtos Sentinel 1 pelo algoritmo S1tiling. Esses produtos Sentinel 2 da base THEIA estão disponíveis apenas para a região do litoral pernambucano na grade T25LBL.

Uma etapa importante no tratamento de dados Sentinel 1 é a filtragem *Speckle*. O *Speckle* é um ruído granular comum em imagens do tipo SAR, e ocorre em função da interferência de uma grande quantidade de dispersores. A filtragem, portanto, aumenta a qualidade da imagem de radar reduzindo o ruído. Neste algoritmo foi utilizado o filtro de Lee, aplicado individualmente a cada uma das polarizações em cada data, devido à sua capacidade de preservação das bordas.

O *SurfWater* propõe três alternativas de métodos para detecção de água com imagens de radar Sentinel 1: (1) limiar de histograma; (2) *Random Forest*; e (3) limiar duplo. Neste trabalho foi utilizado apenas o método *Random Forest*. A abordagem *Random Forest* (RF) – Floresta Aleatória, em tradução direta –, desenvolvido por Breiman (2001), é um método de aprendizado em conjunto que combina uma determinada quantidade de árvores (*n\_estimators*) de classificação e regressão binárias. Cada árvore é construída executando um algoritmo de aprendizagem individual que divide as variáveis de entrada em subconjuntos baseados em um teste de valor atribuído. As árvores RF são construídas selecionando aleatoriamente em cada nó um subconjunto de variáveis de entrada. O número de variáveis usado para dividir um nó RF corresponde à raiz quadrada do número de variáveis de entrada (Liaw; Wiener *et al.*, 2002). Esse processo é repetido recursivamente em cada subconjunto derivado até que o nó contenha amostras muito similares, ou quando a divisão não agregar mais valor às previsões. Para propósitos de implementação, a construção da árvore pode ser parada quando uma profundidade máxima (*max\_depth*) de subconjuntos derivados for atingida, ou quando o número de amostras no nó estiver abaixo de um limite mínimo (*min\_samples*).

Os dados de ocorrência de água foram usados como dados de treinamento, em que 2000

---

<sup>7</sup>Disponível em: <<https://theia.cnes.fr/atdistrib/rocket/#/home>>.

amostras (pixels) de água são obtidas de águas permanentes (ocorrência > 75%, de modo que o parâmetro de entrada *pekel\_threshold* = 75) e 10000 amostras de solo de áreas onde a água nunca foi detectada (ocorrência = 0%). Por fim, foi feito um processo de regularização, para remover *pixels* isolados detectados como "água", utilizando a aplicação "ClassificationMapRegularization" da ferramenta de aplicações em sensoriamento remoto *OrpheoToolBox*<sup>8</sup>. O processo de regularização leva em conta um valor de raio (*radius*) do *pixel* a ser removido.

Foram testados diferentes cenários em apenas um único ano no período de análise com os parâmetros de entrada mencionados a fim de encontrar os melhores resultados para detecção de água. A Tabela 3 apresenta o conjunto de cenários testados.

Tabela 3 – Cenários testados para os parâmetros de entrada

Cenário	radius	pekel_threshold	n_estimators	max_depth
<b>0 (Padrão)</b>	2	75	100	3
<b>1</b>	1	80	100	3
<b>2</b>	1	80	50	2
<b>3</b>	1	90	50	2
<b>4</b>	1	90	100	3

Fonte: O autor (2023).

Uma vez encontrado o melhor cenário do conjunto de testes apresentado na Tabela 3, os parâmetros de entrada desse cenário foram usados para compor um conjunto de testes de diferentes alterações no próprio código do algoritmo *SurfWater*. As alterações foram feitas na composição das polarizações *VV* e *VH* implementada pelo algoritmo no RF, responsável pela normalização dos *pixels* de água detectados – ou seja, a composição de polarização deve ser tal que apresente a menor variação possível (sem saltos significativos) de *pixels* detectados como "água" em datas próximas. A Tabela 4 apresenta os diferentes cenários testados para a composição de polarização do *SurfWater*.

Tabela 4 – Cenários testados para a composição de polarização

Cenário	Composição de polarizações
<b>0 (Padrão)</b>	$VV, VH, VV/(VV + VH)$
<b>1</b>	$VV, VH, VV - VH$
<b>2</b>	$VV, VH, (VV + VH)/2$

Fonte: O autor (2023).

<sup>8</sup>Disponível em: <<https://www.orfeo-toolbox.org>>.

### 3.1.4 Métodos de limiarização

Para os métodos de limiarização, o conjunto de imagens Sentinel 1 de polarização VV foi pré-processado usando a Plataforma de Aplicação Sentinel (SNAP – do inglês *Sentinel Application Platform*), destinada à manipulação e tratamento de imagens das missões Sentinel 1, 2 e 3. O *software* SNAP é livre e aberto e inclui uma variedade de ferramentas que permitem visualizar, processar e analisar os dados de satélite. Como mostrado por Filipponi (2019), para que os dados Sentinel 1 estejam aptos para a detecção de água pela abordagem proposta é necessário a realização de um processamento que consiste em um conjunto padrão de correções aplicadas:

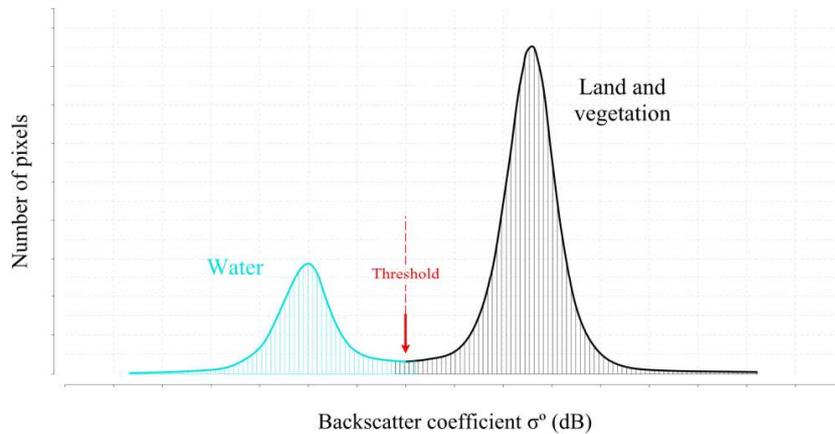
- a) Aplicação e atualização de arquivos de órbita;
- b) Remoção de ruído térmico;
- c) Remoção de ruído de borda;
- d) Calibração radiométrica;
- e) Filtragem *Speckle*;
- f) Correção geométrica do terreno.

#### 3.1.4.1 Método de limiarização predefinida

A intensidade do retroespalhamento SAR foi analisada para detectar água por meio de valores negativos referentes às características dos *pixels* por meio da aplicação de um histograma bimodal. Isso é possível porque a superfície plana da água age como um espelho e reflete quase toda a energia que chega na direção especular, fornecendo, portanto, um baixo retroespalhamento (Pham-Duc; Prigent; Aires, 2017).

Baseado nesse princípio físico, um processo de limiarização do coeficiente de retroespalhamento  $\sigma^\circ$  SAR baseado na distribuição do histograma bimodal foi conduzido em um conjunto limitado de observações Sentinel 1 de maneira supervisionada em um algoritmo simplificado. Foi desenvolvida uma rotina em Python 3 para a automatização da interpretação gráfica para cada uma das imagens Sentinel 1 para selecionar o melhor valor de limiar a fim de separar os *pixels* de "água" dos *pixels* de "não água". A Figura 10 apresenta um exemplo de um histograma bimodal de intensidade do retroespalhamento SAR em trabalho realizado por Souza *et al.* (2022) em um reservatório em Pernambuco.

Figura 10 – Histograma bimodal de intensidade do retroespalhamento SAR



Fonte: Souza *et al.* (2022).

#### 3.1.4.2 Método de Otsu

O algoritmo de limiarização de Otsu é uma abordagem não paramétrica e não supervisionada para seleção automática do limite ótimo para segmentação de imagem (Otsu, 1979). Em métodos de limiarização, é conveniente representar a distribuição dos níveis de cinza na imagem na forma de um histograma que fornece a frequência de ocorrência de cada nível de cinza. O método de Otsu assume que o histograma da imagem é bimodal, de tal modo que sejam definidas apenas duas classes. O método do limite de Otsu tem sido demonstrado como uma abordagem simples e eficiente para mapeamento de água superficial (Tran; Menenti; Jia, 2022). A Equação 1 representa o método de Otsu em que os *pixels* de água em cada imagem Sentinel 1 serão detectados:

$$\sigma^2(t) = P_{Otsu,w}(t) \times \sigma_{Otsu,w}^2(t) + P_{Otsu,nw}(t) \times \sigma_{Otsu,nw}^2(t) \quad (1)$$

onde  $\sigma^2$  é a soma ponderada das variâncias das classes “água” e “não água”.  $P$  e  $\sigma$  são as funções de probabilidade e variância calculadas para cada uma das classes “água” ( $w$ ) e “não água” ( $nw$ ). Baseado no histograma da imagem Sentinel 1 pré-processada, o algoritmo busca iterativamente o valor do limite  $t$  que minimize a variância intraclasse  $\sigma$ . O método de limiarização de Otsu foi implementado a partir da biblioteca SciKit Image (van der Walt *et al.*, 2014).

#### 3.1.4.3 Método de Kittler-Illingworth

A abordagem de KI desenvolvida por Kittler e Illingworth (1986) otimiza uma função de critério relacionada à taxa média de classificação de *pixel* em uma função de histograma para estimar o valor ótimo do limite  $t$ . Essa abordagem também considera que o histograma da

imagem pode ser modelado estatisticamente em duas distribuições normais, ou seja, duas classes, “água” e “não água”. A Equação 2 representa o método de KI em que os *pixels* de água em cada imagem Sentinel 1 serão detectados:

$$J(t) = 1 + 2 [P_{KI,w}(t) \ln \sigma_{KI,w}^2(t) + P_{KI,nw}(t) \ln \sigma_{KI,nw}^2(t)] - 2 [P_{KI,w}(t) \ln P_{KI,w}(t) + P_{KI,nw}(t) \ln P_{KI,nw}(t)] \quad (2)$$

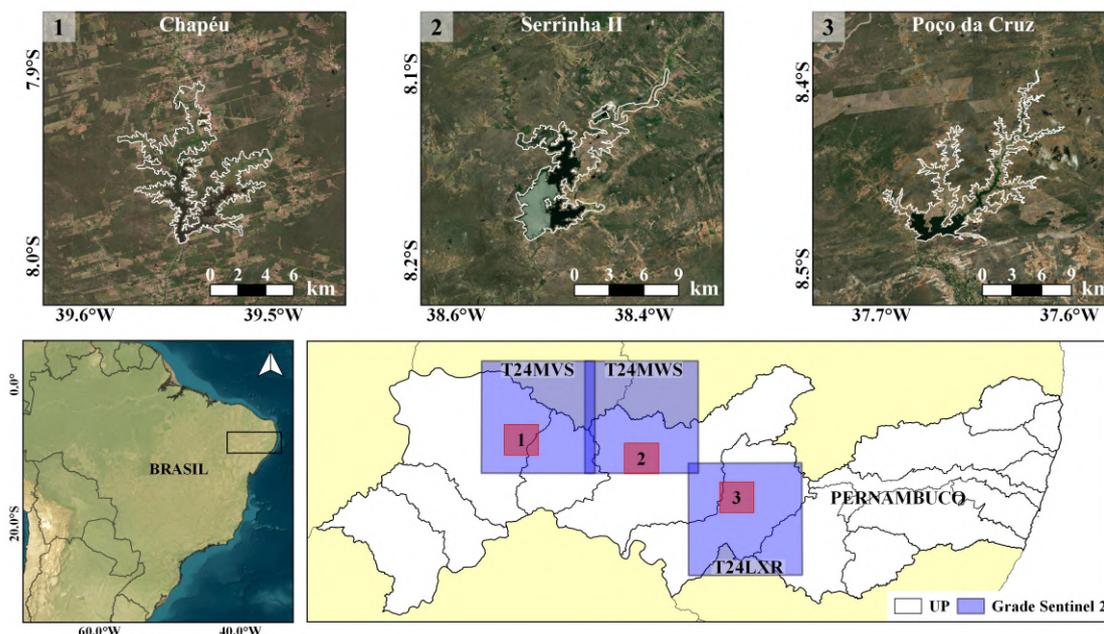
onde  $J$  é uma função de critério de ajuste. Aqui novamente o algoritmo busca o valor limite  $t$  de modo que minimize o valor de  $J$ . Até o momento não existe biblioteca apropriada para a aplicação do método de KI. Portanto, foi desenvolvida pelos pesquisadores Thibault Catry e Renaud Hostache do Instituto de Pesquisa para o Desenvolvimento da França (IRD – do francês *Institut de Recherche pour le Développement*) uma rotina de função a partir das equações matemáticas apresentadas por Kittler e Illingworth (1986).

## 3.2 ABORDAGEM 2: IMAGENS ÓPTICAS

### 3.2.1 Área de estudo

A segunda abordagem metodológica desenvolvida no âmbito deste trabalho foi aplicada no estado de Pernambuco, localizado no NEB. A seleção dos reservatórios para aplicação e avaliação das abordagens propostas deveu-se a dois fatores. O primeiro fator é a preferência dada aos grandes reservatórios da região Sertão do estado de Pernambuco, visto que o algoritmo *WaterDetect* foi desenvolvido para detecção de água em grandes cenários. O segundo fator levou em conta apenas os reservatórios monitorados pelo ANA-SAR. Foram escolhidos, portanto, três reservatórios na região semiárida do estado considerando as quadriculas T24MVS, T24MWS e T24LXR da grade Sentinel 2: Chapéu, Serrinha II e Poço da Cruz. A Figura 11 apresenta a configuração espacial da área de estudo e a localização dos reservatórios que serão analisados. A Tabela 5 apresenta dados fornecidos pela APAC com as características de área superficial máxima e capacidade de armazenamento máxima dos reservatórios selecionados.

Figura 11 – Configuração espacial da área de estudo (Abordagem 2)



Fonte: O autor (2023).

Tabela 5 – Características dos reservatórios (Abordagem 2)

Reservatório	Área superficial máxima (km <sup>2</sup> )	Capacidade máxima (hm <sup>3</sup> )
Chapéu	26,605	187,69
Serrinha II	44,228	311,08
Poço da Cruz	53,336	483,72

Fonte: O autor (2023).

### 3.2.2 Dados utilizados

Diferentes processadores foram desenvolvidos para gerar os produtos Sentinel 2 Nível 2A, que fornecem imagens corrigidas para condições atmosféricas, além de implementarem reflectância de superfície. Um importante subproduto desse processo é a classificação de *pixel*, que fornece máscaras de Nuvens, Sombras, Solo e Água. A detecção de água nesta abordagem com o algoritmo *WaterDetect* foi feita utilizando imagens ópticas do satélite Sentinel 2 de Nível 2A geradas pelo processador Sen2Cor (Mueller-Wilm; Devignot; Pessiot, 2016) no período 1º de janeiro de 2019 a 31 de dezembro de 2022 adquiridas na base de dados Copernicus, de modo que foram coletadas 37 imagens para Chapéu, 78 imagens para Serrinha II e 36 imagens para Poço da Cruz.

### 3.2.3 Algoritmo *WaterDetect*

O método utilizado pelo algoritmo *WaterDetect* combina um agrupamento aglomerativo multidimensional com um classificador de aprendizado de máquina para tornar a detecção de água eficaz e rápida ao mesmo tempo. A análise de agrupamento é uma técnica que é usada para identificar amostras similares em um espaço multidimensional. A principal ideia do algoritmo é a combinação de índices de água (NDWI, MNDWI, MBWI) com bandas de reflectância (VIS, NIR, SWIR) em um processo de agrupamento automatizado. Os índices de água tendem a ter valores altos em águas superficiais, mas apenas um único índice associado a um limiar pode apresentar falsos negativos ou falsos positivos e o valor ótimo de limiar pode ser difícil de definir dependendo da cena (Feyisa *et al.*, 2014; Wieland; Martinis, 2019). Nesse sentido, o agrupamento multidimensional aplicado pelo algoritmo combina as bandas de reflectância favoráveis à detecção de água com índices para uma melhor discriminação de *pixel*.

Um importante passo no aprendizado de máquina é chamado de engenharia de recursos, no qual os recursos são as informações de entrada fornecidas ao algoritmo. Para o desenvolvimento do *WaterDetect*, foram selecionadas cinco bandas ópticas espectrais e três índices de água, de modo que possam ser combinadas de diferentes maneiras a fim de encontrar os melhores resultados para detecção de *pixels* de água (Cordeiro; Martinez; Peña-Luque, 2021). A Tabela 6 apresenta o conjunto e as características desses recursos que podem ser combinados.

Tabela 6 – Recursos e métodos de cálculo dos índices considerados pelo *WaterDetect*

Recurso	Resolução	Notação	Equação
Verde VIS (537–582 nm)	10 m	B3	-
Vermelho VIS (646–685 nm)	10 m	B4	-
NIR (767–908 nm)	10 m	B8	-
SWIR (1539–1681 nm)	20 m	B11	Amostragem média
SWIR (2072–2312 nm)	20 m	B12	Amostragem média
Índice de Água de Diferença Normalizada	10 m	NDWI	$NDWI = \frac{B3-B8}{B3+B8}$
NDWI Modificado	10 m	MNDWI	$MNDWI = \frac{B3-B11}{B3+B11}$
Índice de Água Multi-Banda	10 m	MBWI	$MBWI = 3 \cdot B3 - B4 - B8 - B11 - B12$

Fonte: Cordeiro, Martinez e Peña-Luque (2021), tradução nossa.

Para este trabalho foi adotada a combinação [MNDWI, NDWI, B12], visto que, segundo Cordeiro, Martinez e Peña-Luque (2021), apresentou o melhor balanço entre robustez e precisão.

O método de agrupamento utilizado pelo algoritmo, o agrupamento aglomerativo, particiona os *pixels* em um dado número de conjuntos (*clusters*), de modo a separar os *pixels* de "água" dos *pixels* de "não água". Essa abordagem não possui nenhuma restrição em relação ao tamanho dos *clusters* resultantes. Tal característica é importante, uma vez que, dependendo do tamanho do cenário trabalhado, as bandas incluídas na análise e o número de *pixels* de "água" comparado ao de *pixels* de "não água" podem implicar em tamanhos muito diferentes de *clusters*. O agrupamento aglomerativo é um subtipo de agrupamento hierárquico que segue uma abordagem inferior-superior, em que cada *pixel* começa em seu próprio *cluster* e é então mesclado iterativamente até que o número desejado de *clusters*  $K$  seja alcançado (Nielsen, 2016).

Durante cada iteração, o algoritmo mescla os dois *clusters*, entre todos os *clusters*, que estão mais próximos entre si. A iteração continua até que seja alcançado o melhor valor de  $K$ . Para isso, é empregado o coeficiente de Critério de Razão de Variância, conhecido como Índice de Calinsk-Harabasz (Caliński; Harabasz, 1974), que mede se os *clusters* obtidos são densos e bem separados. Esse índice considera as variâncias intracluster (Equação 3) e intercluster (Equação 4), representadas por  $W_k$  e  $V$ , respectivamente, e é definido como  $S_{CH}$  na Equação 5:

$$W_k = \frac{1}{|k|} \sum_{x \in k} ED_{x\mu_k} \quad (3)$$

$$V = \frac{1}{|k|} \sum_{k=1}^K |k| ED_{\mu_k \mu} \quad (4)$$

$$S_{CH} = \frac{(N - K)V}{(K - 1) \sum_{k=1} W_k} \quad (5)$$

onde  $x$  é um ponto no *cluster*  $k$ ,  $|k|$  é o número de amostras no *cluster*  $k$ ,  $\mu_k$  é o centroide do *cluster*  $k$ ,  $ED_{x\mu_k}$  é a distância euclidiana entre  $x$  e  $\mu_k$ ,  $\mu$  é o centroide de todos os *clusters*,  $N$  é o número total de pontos e  $K$  é o número total de *clusters*. Neste trabalho, o Índice de Calinsk-Harabasz foi avaliado para múltiplos experimentos com o valor  $K$  variando de 2 a 10, cujo intervalo foi definido empiricamente pelos autores do algoritmo. Para identificar qual *cluster* contem os pontos de água, o MBWI é calculado para os centroides de cada *cluster*. O *cluster* que apresentar o valor MBWI mais alto é selecionado como o *cluster* de água, os demais *clusters* são rotulados como "não água".

Considerando que cada cena Sentinel 2 possui aproximadamente 120 milhões de *pixels* ( $10.980 \times 10.980$  *pixels*), torna-se inviável aplicar o método de agrupamento aglomerativo para toda a cena de uma vez, pois necessitaria de uma grande quantidade de tempo e memória. O *WaterDetect* seleciona aleatoriamente um subconjunto de *pixels* na cena para aplicar o agrupamento até que o melhor valor de  $K$  seja encontrado e o *cluster* de água seja identificado. A solução é, então, generalizada para todos os *pixels* na cena por meio do classificador Naïve Bayes, um classificador de aprendizado de máquina supervisionado.

O *WaterDetect* foi desenvolvido na linguagem de programação Python 3.7. Neste trabalho, o algoritmo foi executado no sistema operacional Linux Ubuntu 20.04. Para a geração das máscaras de água, foram selecionadas cenas Sentinel 2 sem cobertura de nuvem sobre os reservatórios da análise.

### 3.3 AVALIAÇÃO E CORREÇÃO DOS DADOS CALCULADOS

#### 3.3.1 Métricas e estatísticas de avaliação

Os dados de área de água obtidos dos métodos de detecção empregados serão comparados com os dados de monitoramento *in situ* obtidos da base de dados SAR. A avaliação será realizada usando o erro médio absoluto (MAE – do inglês *Mean Absolute Error*, Equação 6), a raiz do erro quadrático médio (RMSE – do inglês *Root Mean Squared Error*, Equação 7) e a raiz relativa do erro quadrático médio (RRMSE – do inglês *Relative Root Mean Squared Error*, Equação 8).

$$MAE = \frac{1}{N} \sum_{i=1}^N |X_{ref,i} - X_i| \quad (6)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_{ref,i} - X_i)^2} \quad (7)$$

$$RRMSE (\%) = \sqrt{\frac{\frac{1}{N} \sum_{i=1}^N (X_{ref,i} - X_i)^2}{\sum_{i=1}^N (X_i)^2}} \cdot 100 \quad (8)$$

onde  $X_{ref}$  e  $X$  são os valores da área de água observados por medições *in situ* e calculados dos produtos de satélite, respectivamente, e  $N$  é a quantidade de dias com dados observados e

calculados. Uma vez que a Equação 8 é uma medida relativa, seus valores podem variar entre 0 e 100%, de modo que quanto mais próximo de zero, melhor será a acurácia do valor calculado em relação ao valor observado.

Foram selecionadas as estatísticas de média ( $\bar{X}$ ), desvio padrão (DP), coeficiente de variação (CV) e coeficiente de correlação de Pearson ( $\rho$ ). As estatísticas de CV e  $\rho$  foram medidas em relação aos dados *in situ*.

### 3.3.2 Correção dos dados calculados com RNA

Neste trabalho foi utilizado a RNA de tipo Perceptron Multicamadas (MLP – do inglês *Multilayer Perceptron*) de Regressão para correção dos dados de área calculados. Esse tipo de RNA apresenta uma ou mais camadas intermediárias de neurônios e uma camada de saída, em que os neurônios de uma dada camada  $l$  estão conectados a todos os neurônios da camada  $l + 1$ , tornando-a completamente conectada. Assim, a função de unidades lineares retificadas (ReLU) foi usada como função de ativação para as camadas ocultas. A função ReLU permite o treinamento de redes neurais profundas, visto que propaga de modo idêntico todas as entradas positivas e atribui zero às entradas negativas. A Equação 9 representa a função ReLU:

$$f(x) = \arg \max_{i \in \{1, \dots, N\}} \max(0, x) \quad (9)$$

onde  $x$  é uma variável de entrada. De modo simplificado, a função ReLU funciona limitando valores em 0, ou seja,  $f(x) = 0$  quando  $x < 0$  e, inversamente, gera uma função linear quando  $x \geq 0$ . A otimização dos pesos associados a cada variável foi feita pelo método de Adam, apresentado por Kingma e Ba (2017), definido como um otimizador estocástico baseado em gradiente.

A RNA MLP de Regressão foi implementada a partir da biblioteca SciKit Learn (Pedregosa *et al.*, 2011) na linguagem de programação Python 3. Foram utilizadas três camadas ocultas com 150 neurônios na camada 1, 100 neurônios na camada 2 e 50 neurônios na camada 3. Foram testados diferentes tamanhos de amostra de teste no intervalo [0.1, 0.2, 0.3, 0.4, 0.5] para o treinamento e calibração e diferentes valores para número máximo de iterações no intervalo [200, 205, 210, ..., 400] até que fossem encontrados os parâmetros do modelo com os melhores resultados para as métricas MAE, RMSE e RRMSE, das Equações 6, 7 e 8, respectivamente.

## 4 RESULTADOS E DISCUSSÕES

Este Capítulo apresenta os resultados obtidos a partir da metodologia proposta descrita no Capítulo 3, assim como as principais discussões acerca dos resultados alcançados.

### 4.1 ABORDAGEM 1: IMAGENS DE RADAR

Esta Seção apresenta os resultados obtidos do processamento e detecção de água superficial por meio de imagens de radar provenientes do satélite Sentinel 1, conforme metodologia descrita na Seção 3.1.

#### 4.1.1 Algoritmo *SurfWater*

Inicialmente, os cenários propostos na Tabela 3 para os parâmetros de entrada do algoritmo *SurfWater* foram testados para o ano de 2018, uma vez que esse ano apresentou uma quantidade significativa de dados observados de monitoramento *in situ* necessária para a comparação dos cenários. A Tabela 7 apresenta os resultados da métrica RMSE calculada a partir da Equação 7 para os cenários testados com os valores mínimos em destaque.

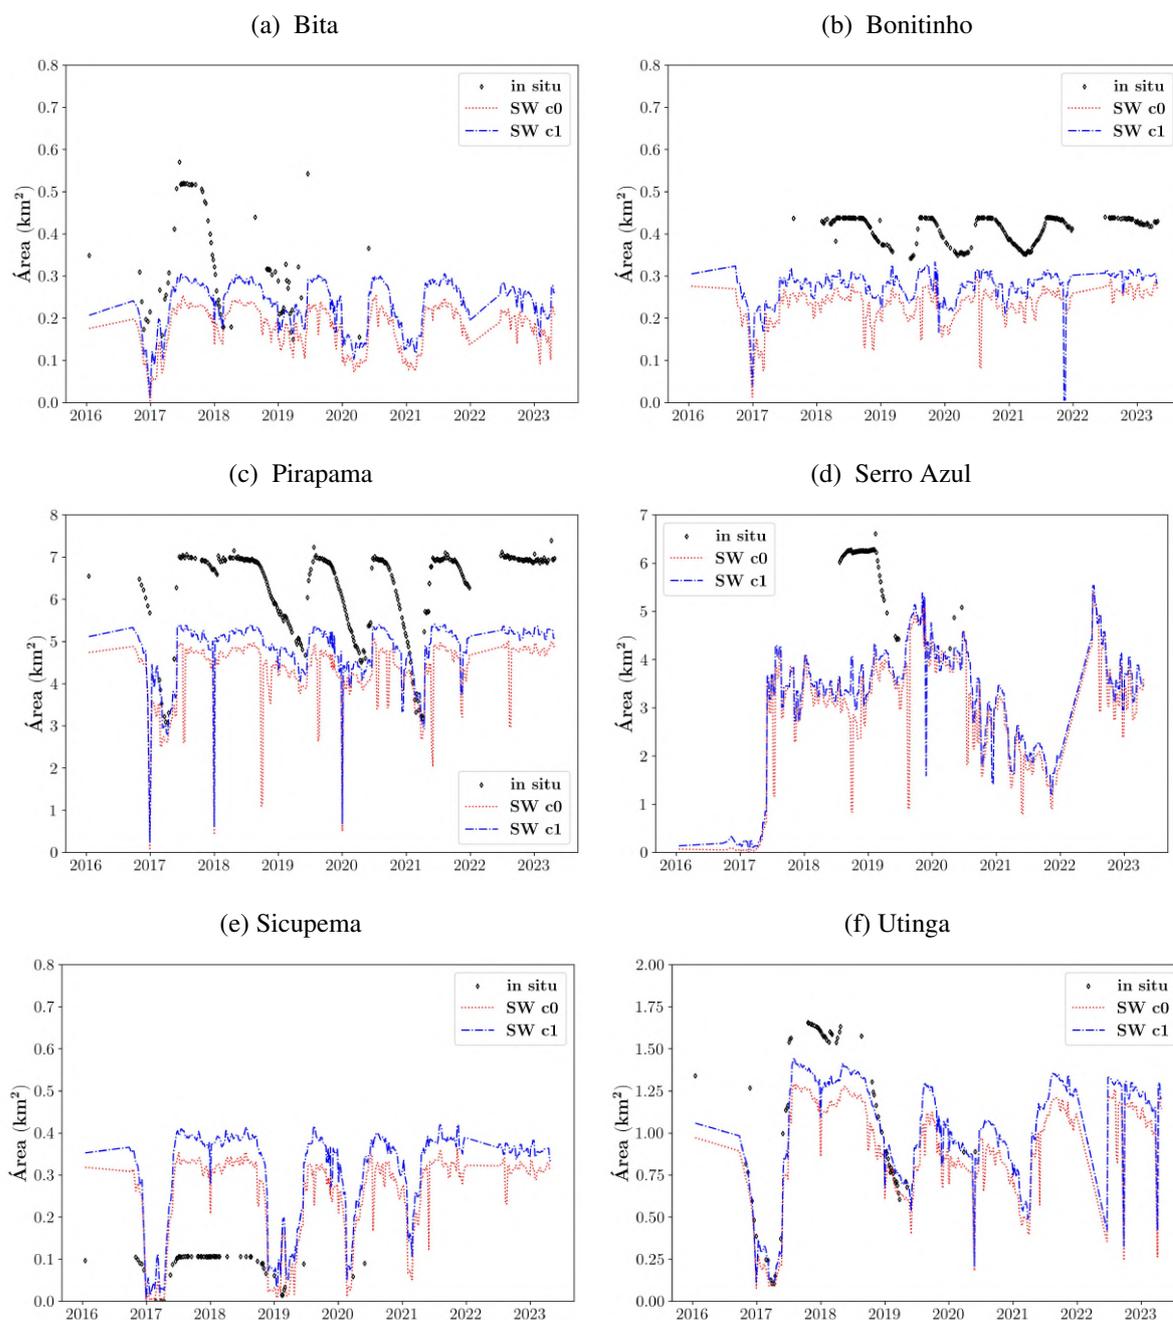
Tabela 7 – Métrica RMSE para os cenários de parâmetros de entrada do *SurfWater*

Reservatório	RMSE (km <sup>2</sup> )				
	c0	c1	c2	c3	c4
Bitá	0,116107	<b>0,116107</b>	0,075998	0,076824	0,076337
Bonitinho	0,196121	<b>0,143859</b>	0,167434	0,170477	0,145206
Pirapama	2,441609	<b>1,789409</b>	1,902179	1,970645	1,810330
Serro Azul	3,515728	<b>2,842266</b>	3,066317	3,220476	2,889708
Sicupema	<b>0,202542</b>	0,267935	0,267541	0,263057	0,266147
Utinga	0,400747	<b>0,258689</b>	0,488920	0,487112	0,261090

Fonte: O autor (2023).

Nota-se, portanto, que o cenário 1 apresentou os melhores resultados, seguido do cenário 4. A exceção é o reservatório de Sicupema, cujo cenário 0, cenário padrão do algoritmo, apresentou melhor resultado, comparado aos demais cenários testados. Assim, o cenário 1 foi selecionado para o processamento das imagens Sentinel 1 em todo o período de análise. A Figura 12 apresenta os gráficos de área de água observada (*in situ*) e calculada considerando os parâmetros de entrada do *SurfWater* para os cenários 0 e 1.

Figura 12 – Área de água observada e calculada considerando os parâmetros de entrada do *SurfWater*



Fonte: O autor (2023).

Da Figura 12 nota-se uma melhoria considerável na detecção de água do cenário 1, comparado ao cenário 0. Além disso, os valores de área de água detectados pelo algoritmo acompanham, até certo ponto, as tendências de aumento e queda da área de água dos dados observados. Entretanto, existe uma diferença considerável entre os valores observados e calculados, com estes últimos apresentando um comportamento de subestimação, com a exceção do reservatório de Sicupema, Figura 12e, em que ocorre o comportamento inverso dos demais reservatórios, com uma superestimação dos valores calculados.

Visto que, considerando os diferentes cenários para os parâmetros de entrada apresentados na Tabela 3, o cenário 1 apresentou os melhores resultados, sua configuração de entrada foi utilizada para testar diferentes composições de polarização, conforme os cenários apresentados na Tabela 4. Novamente, os cenários propostos para a composição de polarização do *SurfWater* foram testados para o ano de 2018. O cenário 0 da Tabela 4 refere-se à composição de polarização padrão do algoritmo que foi utilizada para os testes dos parâmetros de entrada. A Tabela 8 apresenta os resultados da métrica RMSE para os cenários testados com os valores mínimos em destaque.

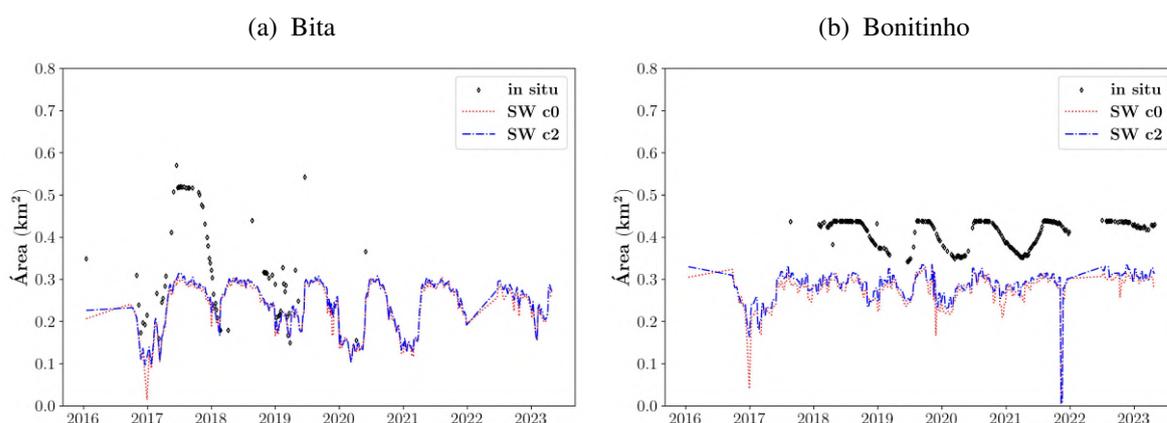
Tabela 8 – Métrica RMSE para os cenários de composição de polarização do *SurfWater*

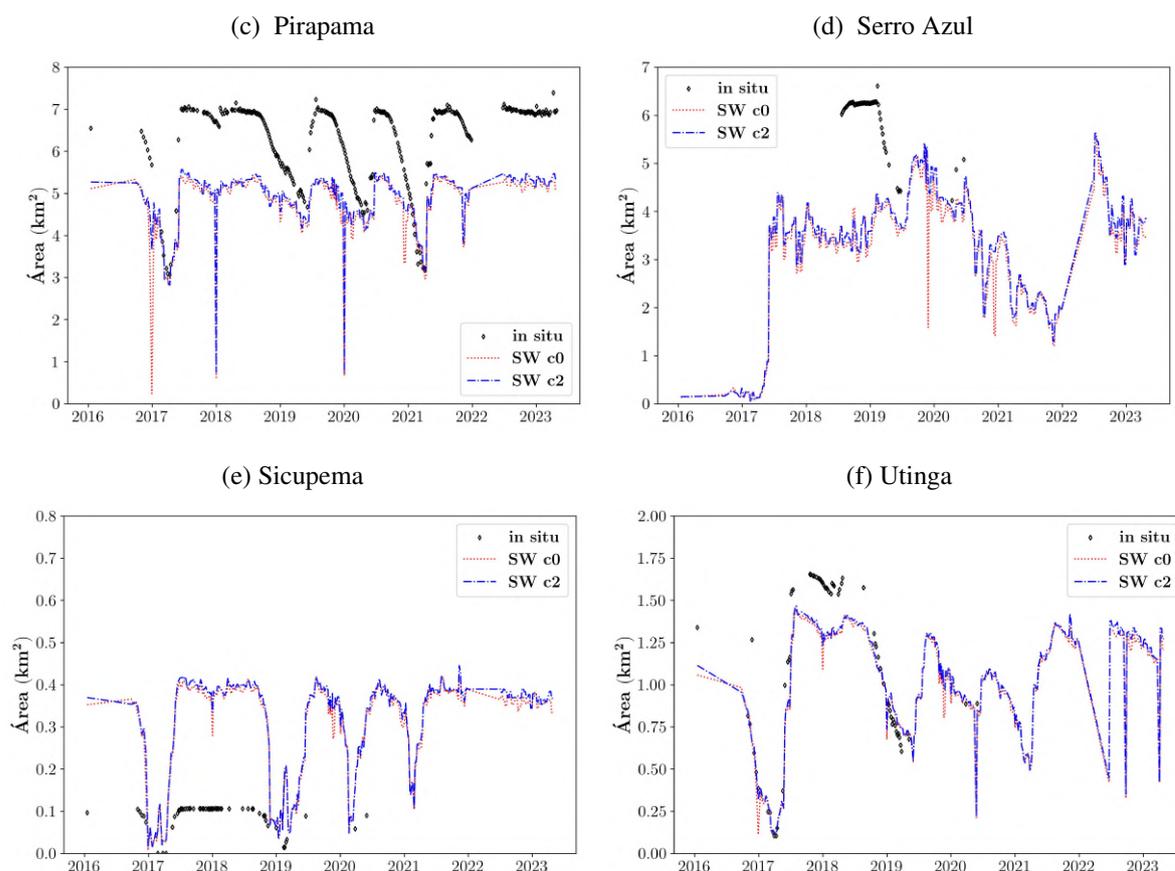
Reservatório	RMSE (km <sup>2</sup> )		
	c0	c1	c2
Bitá	0,075364	0,077088	<b>0,071657</b>
Bonitinho	0,143859	0,149347	<b>0,135903</b>
Pirapama	1,789409	1,798343	<b>1,739537</b>
Serro Azul	2,842267	2,859811	<b>2,744467</b>
Sicupema	0,267935	<b>0,267008</b>	0,276658
Utinga	0,258688	0,483943	<b>0,234578</b>

Fonte: O autor (2023).

Dos cenários de composição de polarização testados para o ano de 2018 nota-se que o cenário 2 apresentou os melhores resultados para todos os reservatórios, com a exceção, novamente, do reservatório de Sicupema, em que, para este, o cenário 1 obteve destaque. Desse modo, o cenário 2 foi selecionado para o processamento das imagens Sentinel 1 em todo o período de análise. A Figura 13 apresenta os gráficos de área de água observada e calculada considerando a composição de polarização do *SurfWater* para os cenários 0 e 2.

Figura 13 – Área de água observada e calculada considerando diferentes composições de polarização do *SurfWater*





Fonte: O autor (2023).

Para esse conjunto de testes, em que foram consideradas diferentes composições de polarização, os resultados obtidos mostraram que a diferença entre os cenários 0 e 2 não é significativa. Entretanto, o cenário 2 se sobressai, uma vez que é possível notar, a partir da Figura 13, uma diminuição de quedas bruscas entre valores, podendo citar, como exemplos, os casos dos reservatórios de Bonitinho, Figura 13b, para o valor apresentado em 30/12/2016, e de Serro Azul, Figura 13d, para os valores apresentados nas datas 28/11/2019, 09/12/2020 e 16/12/2020.

#### 4.1.2 Métodos de limiarização

Considerando os métodos de limiarização apresentados na Seção 3.1.4, após o pré-processamento das imagens Sentinel 1 pelo SNAP, foram aplicados os métodos de limiar pré-definido, Otsu e KI para a geração de máscaras de água e posterior cálculo de área de água superficial. A Tabela 9 apresenta os resultados da métrica RMSE entre os métodos de limiarização e os dados observados de monitoramento *in situ* com os valores mínimos em destaque.

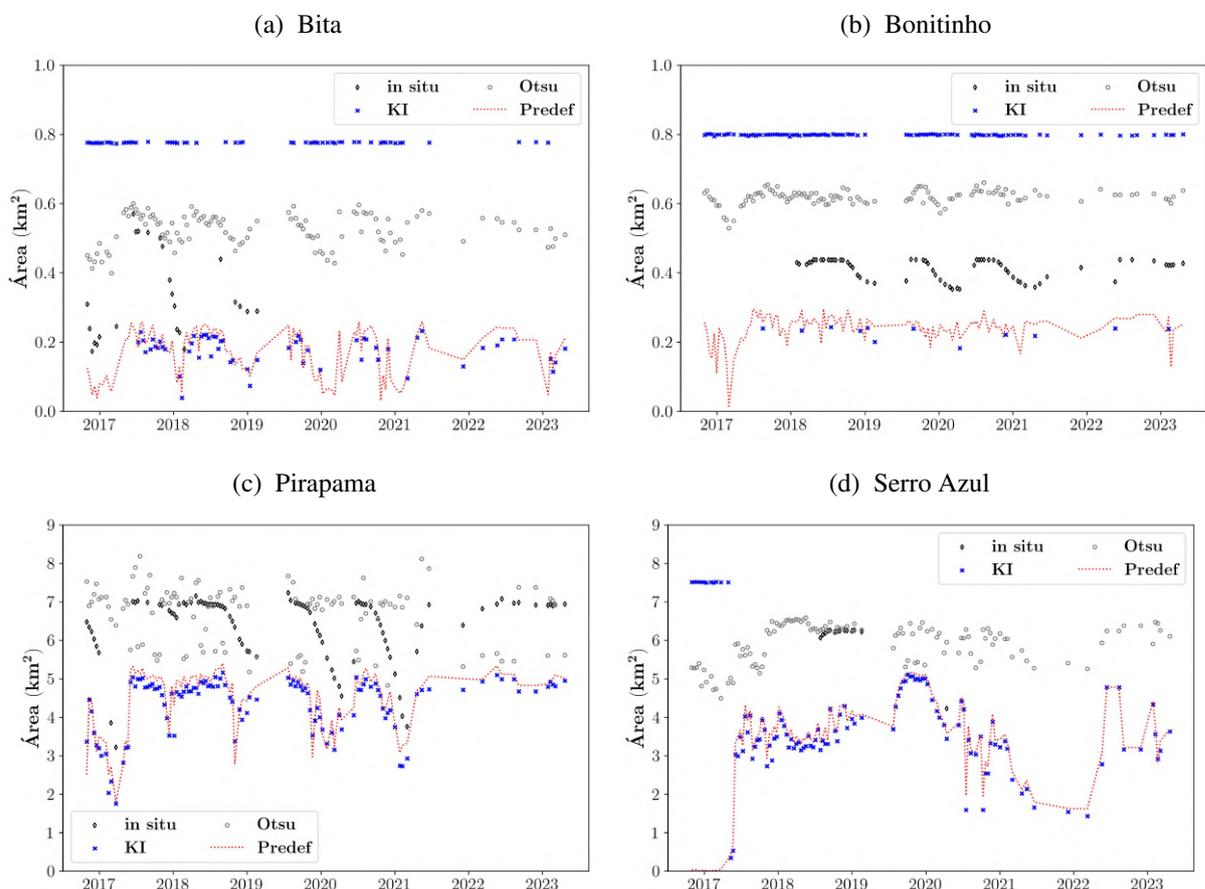
Tabela 9 – Métrica RMSE para os métodos de limiar predefinido, Otsu e KI

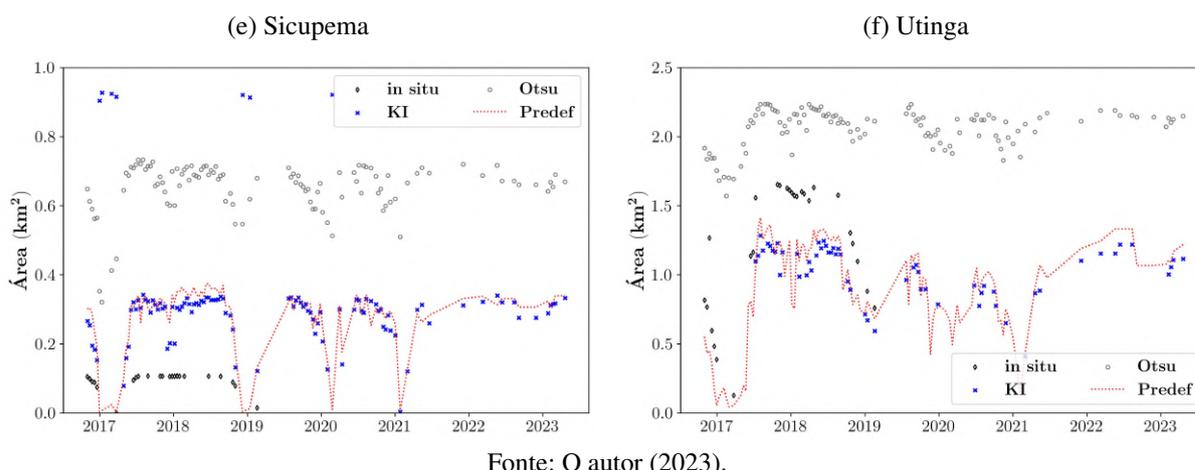
Reservatório	RMSE (km <sup>2</sup> )		
	PreDef	Otsu	KI
Bitá	0,200458	<b>0,198732</b>	0,426604
Bonitinho	<b>0,168265</b>	0,210329	0,360938
Pirapama	1,886061	<b>1,234338</b>	2,053949
Serro Azul	2,283154	<b>0,476309</b>	2,444134
Sicupema	<b>0,200805</b>	0,555965	0,256007
Utinga	<b>0,423678</b>	0,892759	1,297922

Fonte: O autor (2023).

Em uma primeira observação, considerando apenas os valores da métrica RMSE, notou-se que os métodos de limiar predefinido e Otsu alcançaram os melhores resultados. Entretanto, quando levada em conta também a análise visual dos valores de área obtidos pelos métodos testados, surgem novas questões para a discussão. A Figura 14 apresenta os gráficos de área de água observada e calculada considerando as metodologias de limiar predefinido, Otsu e KI para detecção de água.

Figura 14 – Área de água observada e calculada considerando os métodos de limiarização predefinido, Otsu e KI

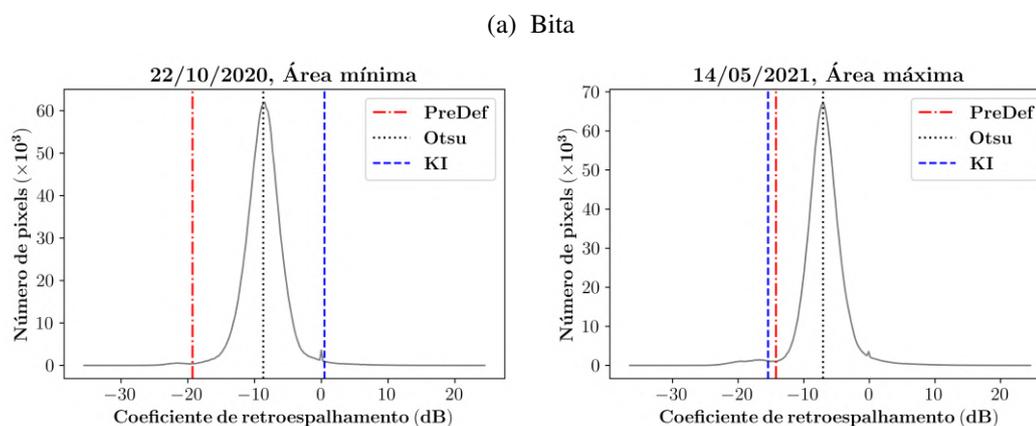




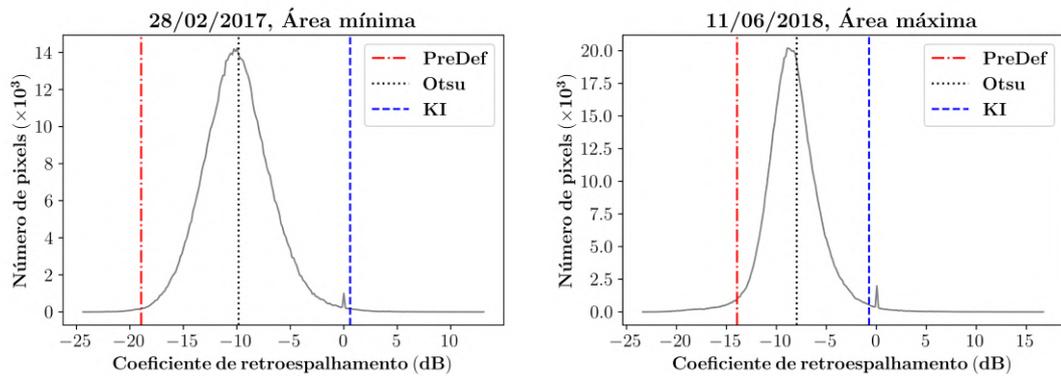
Fonte: O autor (2023).

Da Figura 14 é possível notar que o método de limiar predefinido acompanhou as tendências de aumento e queda da área de água dos valores *in situ*. O método de KI também apresentou esse comportamento até certo ponto, entretanto a detecção de água mostrou-se insatisfatória nas situações em que os valores de área são muito baixos (aproximadamente  $< 0,2 \text{ km}^2$ ), o que pode ser visto com facilidade nos casos dos reservatórios de Bita e Bonitinho, Figuras 14a e 14b, respectivamente. Em relação ao método de Otsu, este mostrou um comportamento de subestimação da área de água detectada, notado principalmente nos reservatórios com espelho d'água inferiores a  $0,5 \text{ km}^2$ , como Bita, Bonitinho, Sicupema e Utinga, Figuras 14a, 14b, 14e e 14f, respectivamente. A deficiência na detecção de água apresentada pelos métodos de Otsu e KI pode ser resultado de erros na escolha dos valores de limiar de segmentação. A fim de verificar a qualidade da escolha desse limiar, os histogramas bimodais das áreas mínima e máxima detectadas para cada um dos seis reservatórios foram plotados, conforme ilustrados na Figura 15.

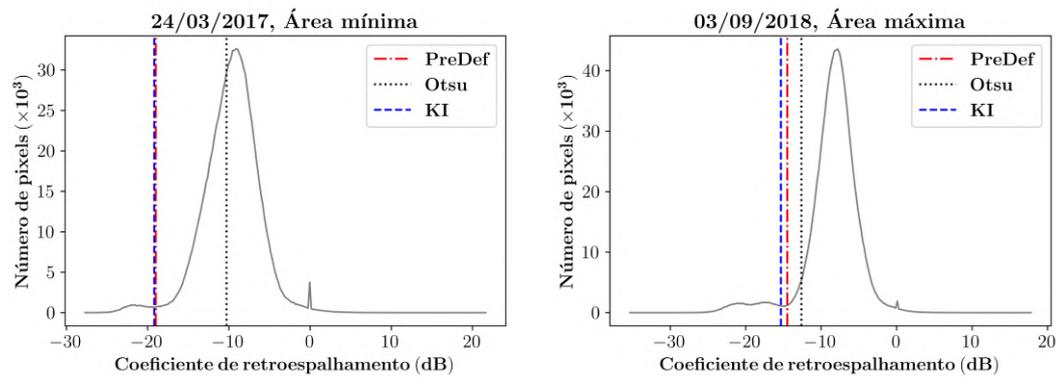
Figura 15 – Avaliação do histograma bimodal para os métodos de limiarização



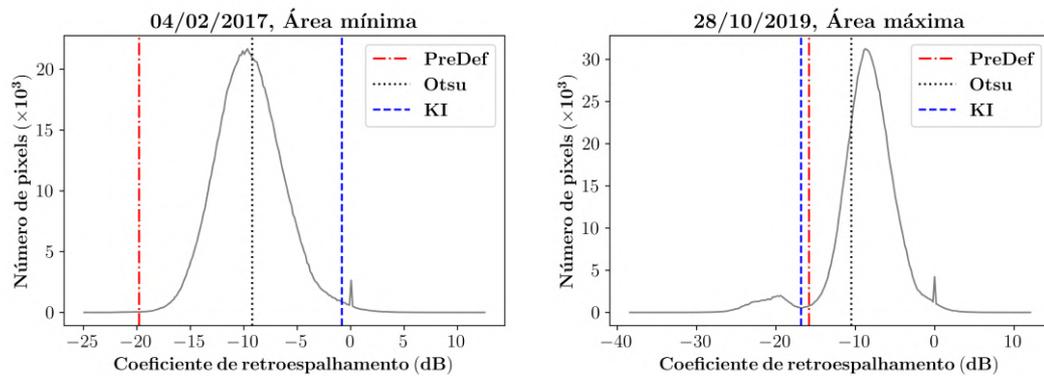
(b) Bonitinho



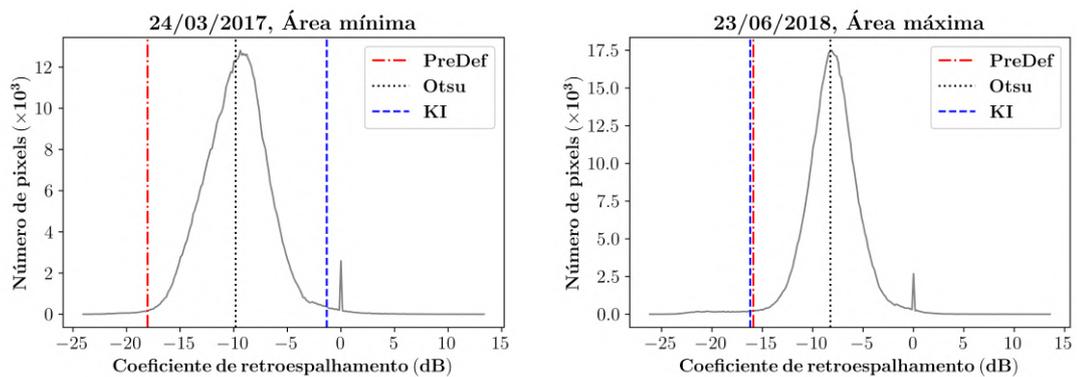
(c) Pirapama



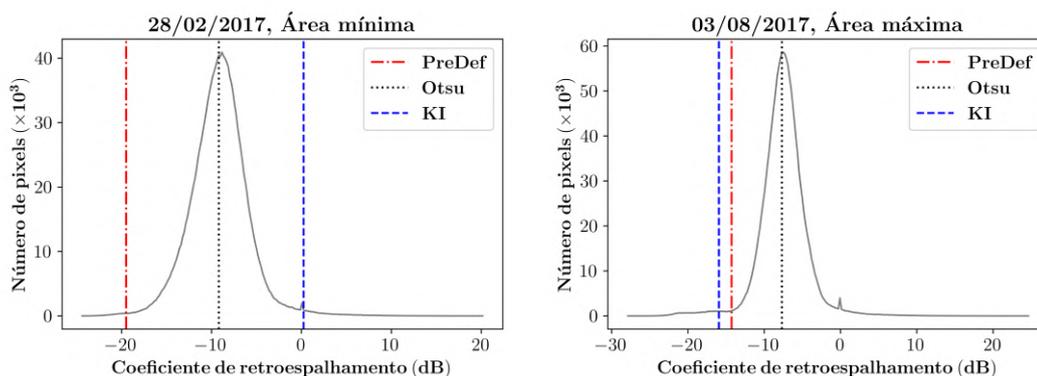
(d) Serro Azul



(e) Sicupema



(f) Utinga



Fonte: O autor (2023).

Uma vez que o alvo a ser detectado pelos métodos testados é a água superficial, especialmente a água de reservatórios, nas imagens do Sentinel 1 os *pixels* que podem ser considerados como "água" constituem a menor parte da cena, enquanto os *pixels* de "não água" constituem a ampla maioria. Conforme ilustrado na Figura 10, o valor ótimo do limiar para segmentar os *pixels* de "água" encontra-se imediatamente antes do conjunto de *pixels* que compõem solo, vegetação, construções etc. Então, da Figura 15 é possível notar que o método de Otsu selecionou valores errados de limiar em todos os casos demonstrados, com exceção apenas do valor de área máxima do reservatório de Pirapama, Figura 15c, mas que, mesmo na exceção, o limiar escolhido superestima o valor ideal. Do mesmo modo, o método de KI também selecionou valores errados de limiar, principalmente nas situações em que os valores de área são muito baixos, como já observado na análise da Figura 14. Os métodos de Otsu e de KI possuem poucas aplicações em reservatórios, uma vez que são utilizados geralmente para monitoramento de cheias e inundações, além de terem apresentado eficiência inferior a métodos mais sofisticados na segmentação de água (Liang; Liu, 2020). Portanto, o método de limiar predefinido é a melhor escolha, uma vez que a seleção do valor de limiar é determinada pela análise do histograma considerando as curvas dos montantes de *pixel* de "água" e "não água".

#### 4.1.3 Comparação *SurfWater* × métodos de limiarização

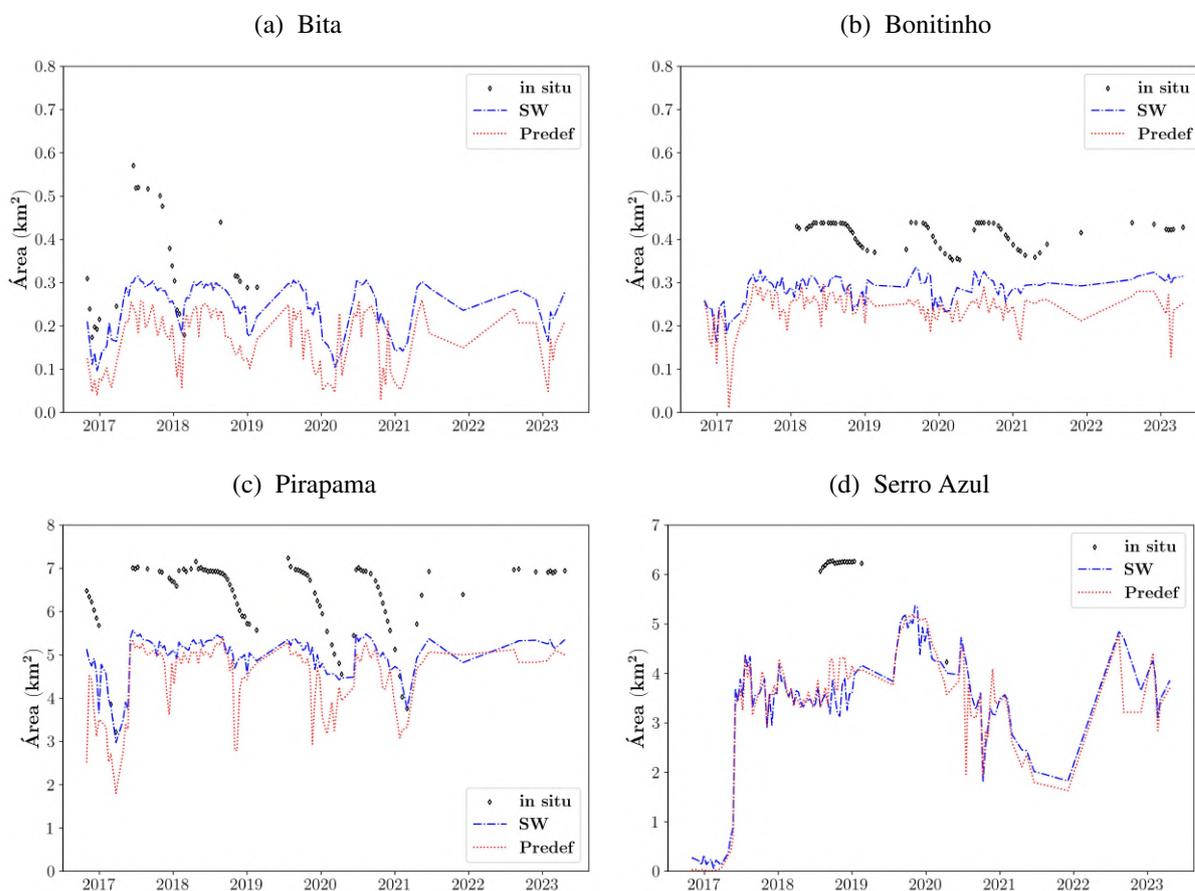
Considerando que a melhor configuração dentre as alternativas testadas do *SurfWater* foi encontrada e o método de limiar predefinido é a melhor opção dentre os três métodos de limiarização testados, os resultados dessas duas metodologias foram comparados. As métricas de avaliação apresentadas na Seção 3.3.1 foram aplicadas para avaliar a qualidade da detecção de água do *SurfWater* e do método de limiar predefinido em relação aos valores observados de monitoramento *in situ* e são mostradas na Tabela 10.

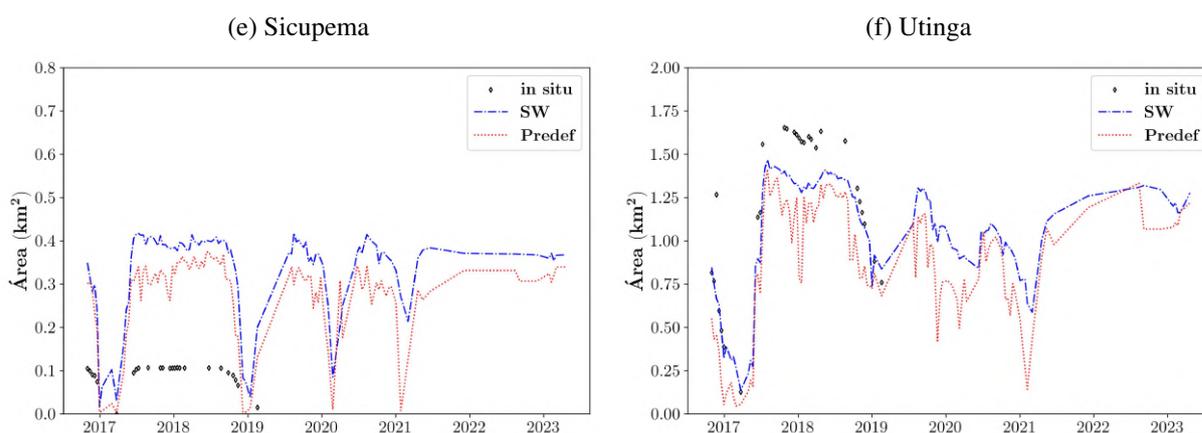
Tabela 10 – Métricas de avaliação para *SurfWater* e método de limiar predefinido

Reservatório	MAE (km <sup>2</sup> )		RMSE (km <sup>2</sup> )		RRMSE (%)	
	SW	PreDef	SW	PreDef	SW	PreDef
Bitá	0,111980	0,184024	0,129942	0,199672	6,45	25,45
Bonitinho	0,120239	0,165489	0,123045	0,168997	2,78	8,46
Pirapama	1,359740	1,823971	1,438520	1,904242	1,70	4,20
Serro Azul	2,523487	2,201381	2,603731	2,253555	8,63	15,79
Sicupema	0,253838	0,189394	0,261191	0,198695	9,76	14,17
Utinga	0,184447	0,378617	0,228996	0,422136	2,36	8,88

Fonte: O autor (2023).

Dos valores de MAE e RMSE alcançados notou-se que o *SurfWater* apresentou melhores resultados para os reservatórios de Bitá, Bonitinho, Pirapama e Utinga. Enquanto o método de limiar predefinido sobressaiu-se com os reservatórios de Serro Azul e Sicupema. Entretanto, quando analisado os resultados de RRMSE, o *SurfWater* obteve melhor ajuste em todos os reservatórios. A Figura 16 apresenta os gráficos de área de água calculados obtidos com *SurfWater* e método de limiar predefinido e área de água observada.

Figura 16 – Comparação entre *SurfWater* e método de limiar predefinido



Fonte: O autor (2023).

Partindo de uma análise visual dos gráficos mostrados na Figura 16, foi possível notar que a diferença dos valores de área de água obtidos pelos dois métodos é pequena para os reservatórios de Pirapama e Serro Azul, Figuras 16c e 16d, respectivamente, que são os reservatórios com maior espelho d'água nessa abordagem. Além disso, o método de limiar predefinido apresentou valores bastante similares aos apresentados pela configuração padrão do *SurfWater*, a saber, o cenário 0 da Tabela 3. Essa similaridade torna-se mais clara quando comparados os valores de RMSE da Tabela 7 para o cenário 0 com os valores de RMSE da Tabela 10 para o método de limiar predefinido. Os resultados obtidos com o *SurfWater* são semelhantes aos obtidos por Peña-Luque *et al.* (2021) para as configurações utilizadas neste trabalho. Para o método de limiar predefinido, os resultados obtidos estão em consonância com os apresentados por Souza *et al.* (2022), entretanto, é importante notar que os métodos de limiarização são bastante afetados por ruído, e que, mesmo com o tratamento das imagens pelo SNAP, a precisão da detecção de água pode não ser alta (Chen; Ming; Menenti, 2020). A Tabela 11 apresenta as medidas estatísticas para cada um dos reservatórios.

Tabela 11 – Medidas estatísticas para *SurfWater* e método de limiar predefinido

Reservatório	<i>SurfWater</i>				Predefinido			
	$\bar{X}$	DP	CV	$\rho$	$\bar{X}$	DP	CV	$\rho$
Bitá	0,230	0,055	0,24	0,86	0,149	0,059	0,40	0,81
Bonitinho	0,294	0,029	0,10	0,37	0,247	0,028	0,11	0,28
Pirapama	4,944	0,612	0,12	0,74	4,573	0,724	0,16	0,79
Serro Azul	3,729	0,351	0,09	-0,30	3,851	0,331	0,09	0,30
Sicupema	0,332	0,104	0,31	0,93	0,283	0,085	0,30	0,92
Utinga	0,974	0,366	0,37	0,96	0,834	0,384	0,46	0,91

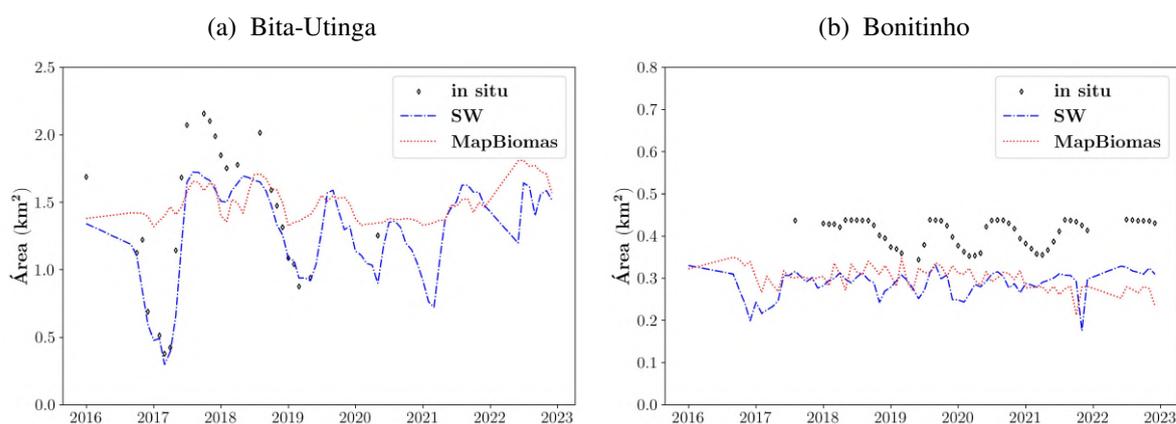
Fonte: O autor (2023).

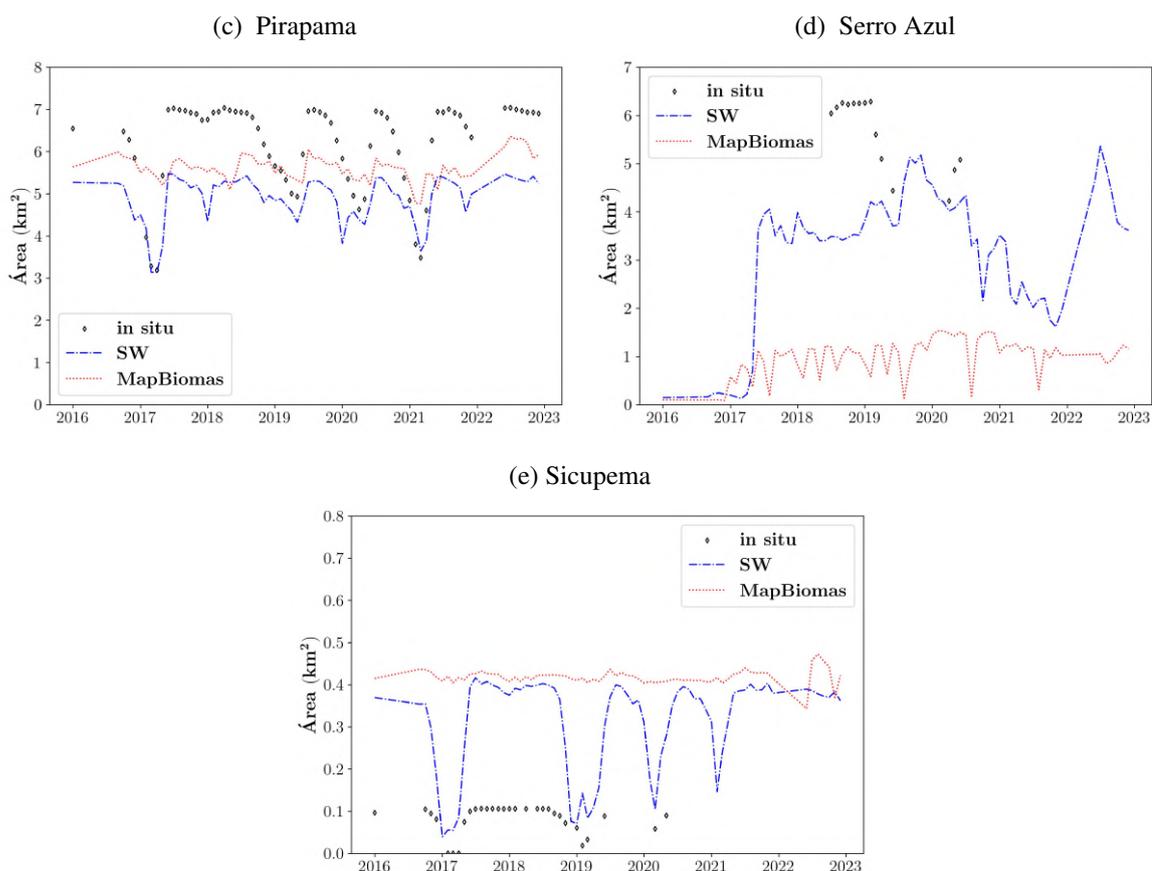
As estatísticas indicam que os reservatórios de Bonitinho e Serro Azul possuem uma baixa correlação com os valores *in situ*. Em contrapartida, os demais reservatórios apresentaram bons valores de  $\rho$ , com destaque para os reservatórios de Utinga e Sicupema, expresso na capacidade do *SurfWater* e do método de limiar predefinido em refletir bem as tendências da série observada. Vale notar que os valores de CV foram proporcionais aos valores de  $\rho$ .

#### 4.1.4 Dados MapBiomias

Considerando que o cenário 2 de composição de polarização da Tabela 4 com os parâmetros de entrada do cenário 1 referente à Tabela 3 apresentou os melhores resultados, este cenário foi comparado aos valores de área de água superficial gerados pelo MapBiomias. Além disso, os valores obtidos pelo MapBiomias também foram avaliados comparando-os com os valores de monitoramento *in situ*, de modo a verificar a possibilidade de usá-los como uma alternativa para base de dados de referência. Dois pontos importantes devem ser destacados: (1) como já mencionado no Capítulo 3, a comparação foi feita para a escala mensal, visto que o MapBiomias gera dados apenas nas escalas mensal e anual; e (2) o MapBiomias considera os reservatórios de Bitá e Utinga como um corpo hídrico único, então para esta comparação, os valores de área obtidos pelo *SurfWater* para esses dois reservatórios foram somados. A Figura 17 apresenta os gráficos de área de água observada, calculada e obtidas do MapBiomias.

Figura 17 – Área de água observada, calculada e do MapBiomias





Fonte: O autor (2023).

Com base em uma análise visual dos gráficos apresentados na Figura 17, notou-se que em todos os reservatórios, com exceção de Serro Azul, os valores calculados do *SurfWater* ficaram bastante próximos aos valores obtidos do MapBiomias. Destaca-se o caso do reservatório de Sicupema, Figura 17e, em que os valores do *SurfWater* e do MapBiomias apresentaram um comportamento de superestimação em relação aos valores *in situ*, o que, por sua vez, pode ser um indicativo ou de erros de medição ou de CAV desatualizada dos valores obtidos pelo ANA-SAR. Entretanto, em algumas situações, como as apresentadas pelos reservatórios de Bitá-Utinga e de Sicupema, Figuras 17a e 17e, respectivamente, o MapBiomias superestimou os valores mínimos. Em todos os casos analisados, com exceção do reservatório de Sicupema, Figura 17e, o MapBiomias subestimou os valores máximos de área do monitoramento *in situ*.

As métricas de avaliação apresentadas na Seção 3.3.1 foram aplicadas para avaliar a qualidade da detecção de água do *SurfWater* com produtos Sentinel 1 em relação aos valores obtidos do MapBiomias e para avaliar a qualidade de estimativa de área do MapBiomias em relação aos valores *in situ*. Os valores das métricas são mostradas na Tabela 12.

Da comparação dos valores de área de água superficial obtidos pelo MapBiomias com aqueles obtidos pelo ANA-SAR e pelo *SurfWater*, os reservatório de Pirapama e Bonitinho

Tabela 12 – Métricas de avaliação para *SurfWater* × MapBiomias

Reservatório	MB × <i>in situ</i>			SW × MB		
	MAE	RMSE	RRMSE	MAE	RMSE	RRMSE
Bitá-Utinga	0,405397	0,481792	4,40	0,259267	0,361171	3,38
Bonitinho	0,111508	0,119427	3,59	0,034701	0,044976	1,90
Pirapama	0,940551	1,062382	2,30	0,730570	0,851664	2,08
Serro Azul	4,516408	4,612275	10,96	2,222070	2,514191	32,21
Sicupema	0,338118	0,339583	50,99	0,105409	0,150325	4,66

MAE e RMSE medidos em  $km^2$  e RRMSE medido em %.

Fonte: O autor (2023).

alcançaram os melhores resultados, respectivamente. Por outro lado, as piores métricas de avaliação ficaram com os reservatórios de Serro Azul e Sicupema, o que já era perceptível apenas pela análise visual dos gráficos mostrados na Figura 17, de modo que ocorreu uma subestimação dos valores obtidos pelo *SurfWater* e pelo MapBiomias. A Tabela 13 apresenta as medidas estatísticas para cada um dos reservatórios.

Tabela 13 – Medidas estatísticas para MapBiomias

Reservatório	$\bar{X}$	DP	CV	$\rho$
Bitá-Utinga	1,462	0,107	0,07	0,63
Bonitinho	0,297	0,027	0,09	-0,08
Pirapama	5,611	0,307	0,05	0,53
Serro Azul	1,129	0,262	0,23	-0,74
Sicupema	0,419	0,008	0,02	0,49

Fonte: O autor (2023).

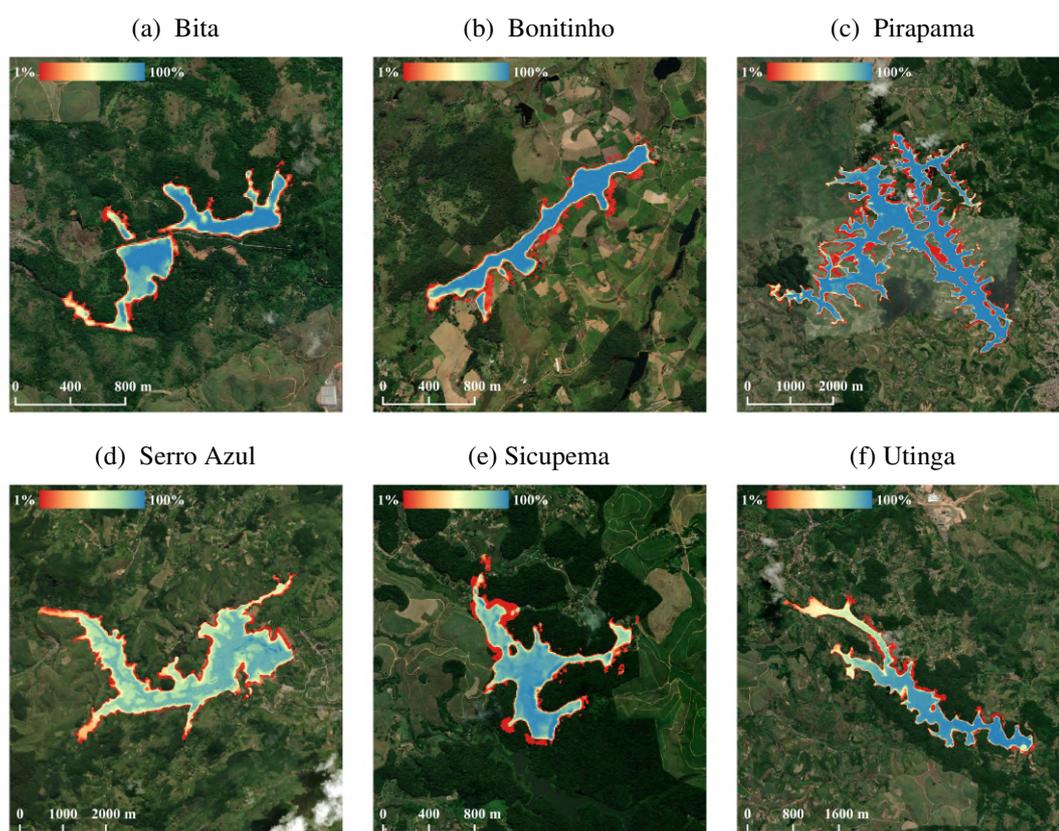
Os reservatórios de Bonitinho e Serro Azul alcançaram valores negativos de  $\rho$ , refletido na tendência inversa do MapBiomias em relação aos valores *in situ*. Os resultados de CV foram baixos, de modo geral, indicando a homogeneidade da série histórica do MapBiomias. Todas essas questões puderam ser visualizadas graficamente pela Figura 17.

#### 4.1.5 Análise de ocorrência de água

Problemas de detecção de água nas bordas dos reservatórios pela presença de árvores são agravadas devido ao intervalo de variação dos altos valores do ângulo de incidência do Sentinel-1 ( $29,1^\circ - 46^\circ$ ) comparado ao Sentinel-2 ( $0^\circ - 10,1^\circ$ ). Quando as bordas de um corpo d'água estão muito próximas a objetos de alta reflectância (árvores, pontes, muros etc.), o sinal difuso desses elementos pode afetar as zonas adjacentes de baixo sinal da água superficial, de modo que os

*pixels* de “água” nas bordas podem ser classificados como “não água”, resultando em uma perda da área inundada do reservatório (Peña-Luque *et al.*, 2021). Alguns dos problemas mencionados podem ser observados nos mapas de ocorrência de água de imagens Sentinel 1 processadas pelo *SurfWater* mostrados na Figura 18.

Figura 18 – Mapas de ocorrência de água de observações Sentinel 1 processadas pelo *SurfWater*



Fonte: O autor (2023).

Da Figura 18 é possível notar que os reservatórios de Bitá e Bonitinho, Figuras 18a e 18b, respectivamente, são afetados por discontinuidades nas formas de seus espelhos d’água, observando-se claramente que o reservatório de Bitá é cortado por uma estrada. Existe uma cobertura de vegetação considerável no entorno dos reservatórios de Bitá, Sicupema e Utinga, Figuras 18a, 18e e 18f, respectivamente, e em menor parte nos reservatórios de Bonitinho e Pirapama, Figuras 18b e 18c, respectivamente. Vale destacar ainda o reservatório de Pirapama, Figura 18c, pela sua forma complexa com diversas ramificações e braços estreitos. Todos esses pontos levantados podem afetar a qualidade da detecção de água e, por conseguinte, os valores de área de água superficial, visto que os algoritmos de detecção de água são muito afetados em áreas com vegetação densa em imagens ópticas e de radar (Catry *et al.*, 2018). Além disso, como citado por Peña-Luque *et al.* (2021), os algoritmos também têm dificuldade em detectar água em reservatórios com formato de espelho d’água complexo e braços estreitos, especialmente em

bordas com limites sinuosos.

#### 4.1.6 Correção dos dados calculados

Por fim, foi aplicada a RNA de tipo MLP aos valores de área obtidos pelo *SurfWater* para correção de viés. Os resultados mostraram que o tamanho de amostra necessário para o treinamento e calibração do modelo foi equivalente a 20% da série temporal para três dos seis reservatórios. A Tabela 14 apresenta as métricas de avaliação de calibração e validação associadas para cada reservatório.

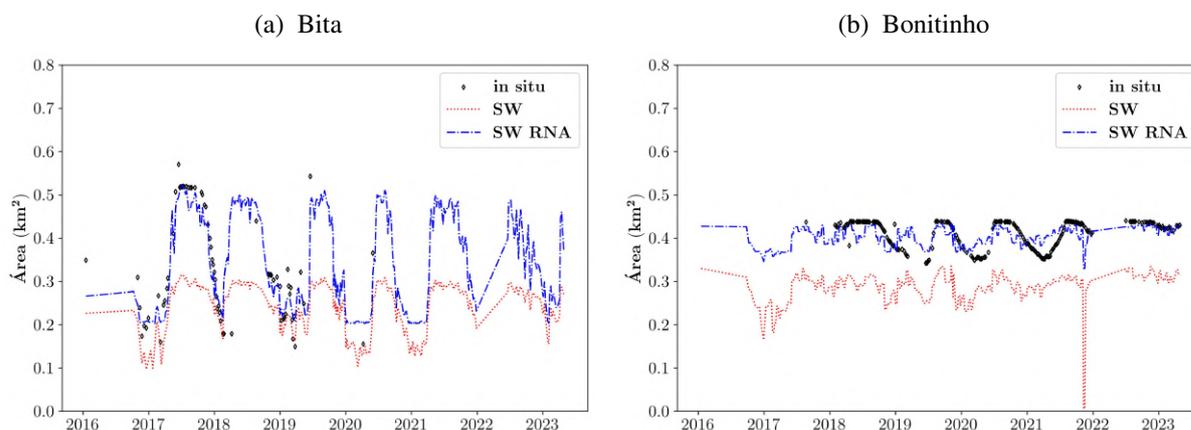
Tabela 14 – Métricas de avaliação da RNA MLP aplicadas em produtos Sentinel 1

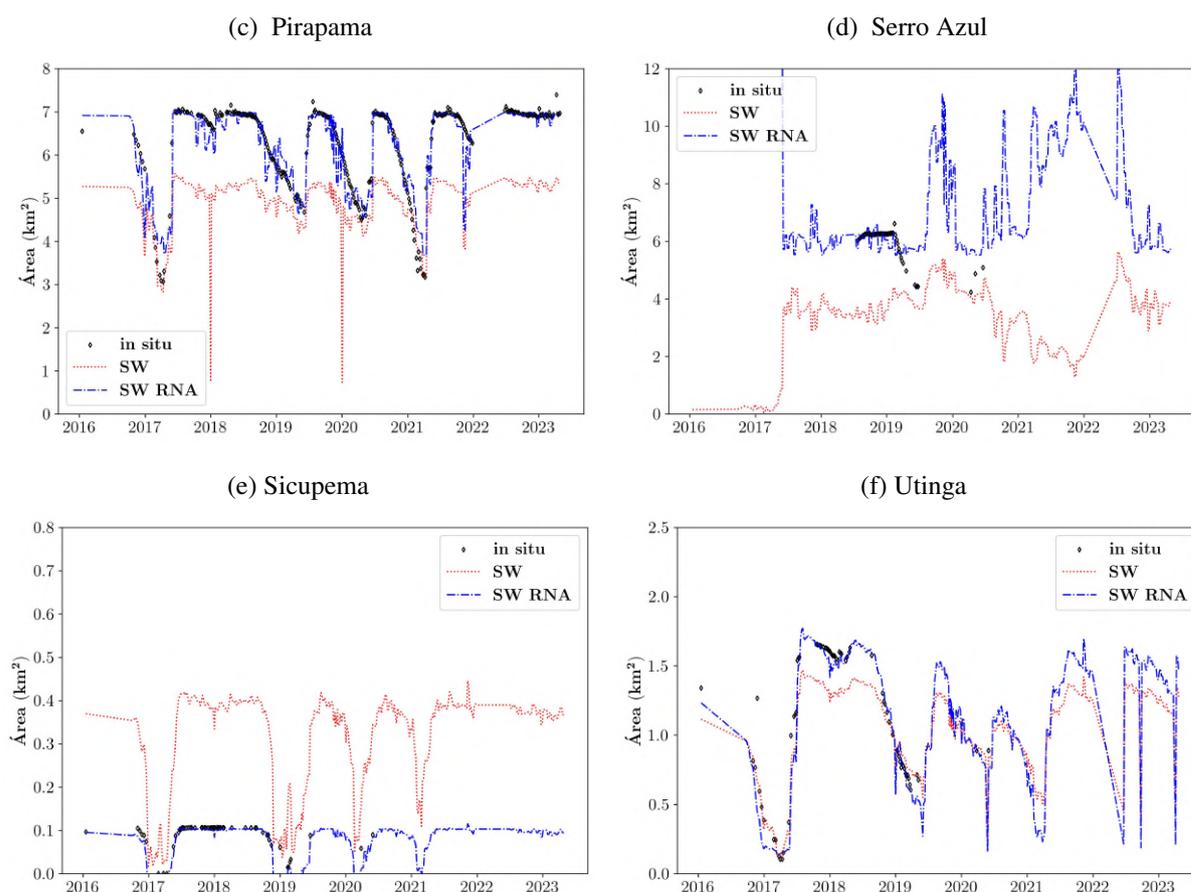
Reservatório	MAE (km <sup>2</sup> )		RMSE (km <sup>2</sup> )		RRMSE (%)	
	Cal	Val	Cal	Val	Cal	Val
Bitá	0,026221	0,035715	0,029930	0,053464	2,27	1,82
Bonitinho	0,017895	0,021436	0,024088	0,029658	0,86	0,49
Pirapama	0,211797	0,252665	0,308977	0,413424	0,61	0,37
Serro Azul	0,300711	0,502112	0,388903	0,621667	1,96	1,47
Sicupema	0,005469	0,007845	0,007138	0,012275	1,71	1,76
Utinga	0,052084	0,068940	0,064279	0,118958	1,10	1,18

Fonte: O autor (2023).

Da Tabela 14, nota-se que, de modo geral, todos os reservatórios alcançaram valores satisfatórios. Entretanto, para uma melhor avaliação do método de correção proposto é importante também a análise dos gráficos. A Figura 20 apresenta os valores de área de água calculada com viés corrigido pela RNA MLP.

Figura 20 – Área de água observada, calculada e corrigida via RNA MLP com produtos Sentinel 1





Fonte: O autor (2023).

A partir da análise visual dos gráficos apresentados na Figura 20, é possível notar que a correção de viés alcançou um bom ajuste aos valores de referência (valores *in situ*) para todos os reservatórios tratados, com exceção do reservatório de Serro Azul, Figura 20d. O modelo de RNA ajustado ao reservatório de Serro Azul não foi satisfatório, visto que os valores corrigidos apresentaram um comportamento de tendência de inverter os valores calculados, obtendo uma espécie de curva espelho, como pode ser visualizado pelo gráfico. O baixo desempenho apresentado pelo reservatório de Serro Azul pode ser decorrente do tamanho de amostra de teste muito pequeno utilizado para o treinamento e calibração do modelo, pois este reservatório possui uma série histórica de monitoramento *in situ* relativamente curta, uma vez que para a construção de modelos RNA, quanto mais longa a série temporal utilizada para o treinamento, melhor será a acurácia alcançada (Han, G. *et al.*, 2022).

## 4.2 ABORDAGEM 2: IMAGENS ÓPTICAS

Esta Seção apresenta os resultados obtidos do processamento e detecção de água superficial por meio de imagens ópticas provenientes do satélite Sentinel 2, conforme metodologia descrita na Seção 3.2.

#### 4.2.1 Algoritmo *WaterDetect*

A aplicação do algoritmo *WaterDetect* foi feita para o mapeamento de água sobre os três reservatórios considerados: Chapéu, Serrinha II e Poço da Cruz. As métricas de avaliação apresentadas na Seção 3.3.1 foram aplicadas para avaliar a qualidade da detecção de água do algoritmo em relação à série histórica de referência de monitoramento *in situ* e são mostradas na Tabela 15.

Tabela 15 – Métrica de avaliação *WaterDetect* em relação aos dados *in situ*

Reservatório	Métricas		
	MAE	RMSE	RRMSE
Chapéu	6,876516	7,129475	36,42
Serrinha II	12,106997	13,148357	12,69
Poço da Cruz	3,402684	3,811909	2,86

MAE e RMSE medidos em  $km^2$  e RRMSE medido em %.

Fonte: O autor (2023).

Analisando os valores apresentados na Tabela 15, nota-se que as métricas alcançadas em relação aos dados *in situ* foram muito inferiores às alcançadas pela metodologia aplicada às imagens Sentinel 1. Entretanto, o reservatório de Poço da Cruz conseguiu os melhores resultados de RRMSE, enquanto o reservatório de Chapéu foi o pior resultado alcançado. Para avaliar a qualidade dos resultados obtidos com o algoritmo *WaterDetect* em relação aos valores de área obtidos do MapBiomas, as métricas de avaliação foram aplicadas. Além disso, também foi feita uma avaliação da estimativa de área do MapBiomas em relação aos valores *in situ*. Os valores das métricas para as duas avaliações são mostradas na Tabela 16.

Tabela 16 – Métrica de avaliação MapBiomas em relação aos dados *in situ* e *WaterDetect*

Reservatório	MB $\times$ <i>in situ</i>			WD $\times$ MB		
	MAE	RMSE	RRMSE	MAE	RMSE	RRMSE
Chapéu	6,147570	6,362760	13,64	0,572618	0,136422	4,99
Serrinha II	12,176945	14,313235	8,77	2,396424	3,644779	3,61
Poço da Cruz	5,514679	8,711999	6,94	4,057808	7,203456	6,82

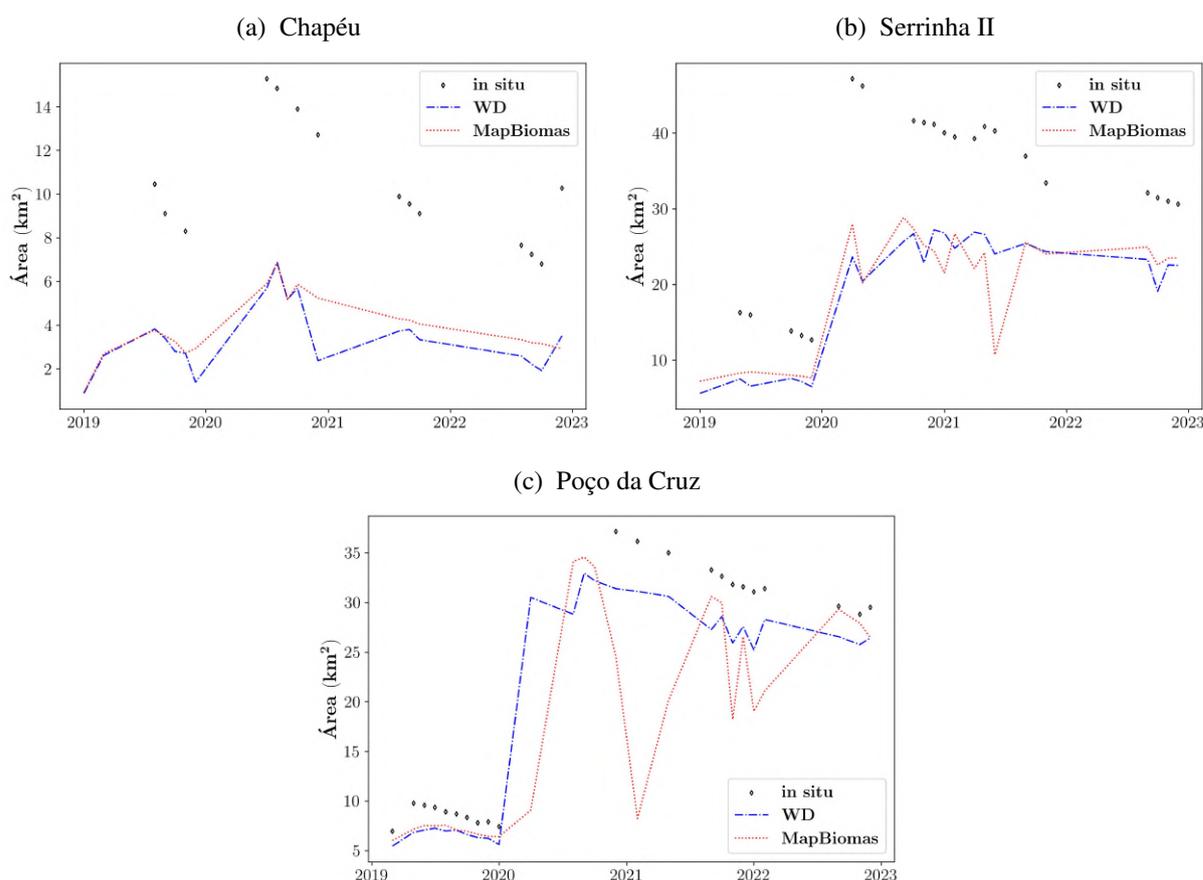
MAE e RMSE medidos em  $km^2$  e RRMSE medido em %.

Fonte: O autor (2023).

Para a avaliação dos resultados obtidos com o *WaterDetect* comparados com os valores de área obtidos com o MapBiomas, houve uma melhoria considerável dos valores de métrica alcançados, de modo que, para esse caso, o reservatório de Serrinha II alcançou os melhores

valores de métrica, seguido de Chapéu, com Poço da Cruz ficando com os resultados inferiores. Entretanto, as métricas alcançadas pelo MapBiomias em relação aos valores de monitoramento *in situ* foram insatisfatórias para o reservatório de Chapéu. A Figura 21 apresenta os gráficos de área de água observada, calculada e obtidas do MapBiomias.

Figura 21 – Área de água observada *in situ* e MapBiomias e calculada pelo *WaterDetect*



Fonte: O autor (2023).

Com base em uma análise visual dos gráficos apresentados na Figura 21, é possível notar uma diferença considerável entre os valores de área obtidos pelo algoritmo e aqueles das observações *in situ*, mas que, mesmo assim, os valores calculados ainda conseguiram refletir as tendências de aumento e diminuição da área de água, com o reservatório de Poço da Cruz, Figura 21c, obtendo destaque. Por outro lado, comparando os valores obtidos pelo algoritmo e os valores do MapBiomias, nota-se que são resultados com similaridade considerável, o que pode refletir problemas na detecção de água tanto pelo *WaterDetect* quanto pela metodologia utilizada pelo MapBiomias, dada a diferença entre esses valores e os valores *in situ*. A Tabela 17 apresenta

as medidas estatísticas para cada um dos reservatórios.

Tabela 17 – Medidas estatísticas para *WaterDetect* e MapBiomias

Reservatório	<i>WaterDetect</i>				MapBiomias			
	$\bar{X}$	DP	CV	$\rho$	$\bar{X}$	DP	CV	$\rho$
Chapéu	3,697	1,529	0,41	0,66	4,212	1,223	0,29	0,91
Serrinha II	20,376	7,461	0,37	0,90	19,743	7,351	0,37	0,82
Poço da Cruz	18,531	10,497	0,57	0,99	15,966	9,446	0,59	0,83

Fonte: O autor (2023).

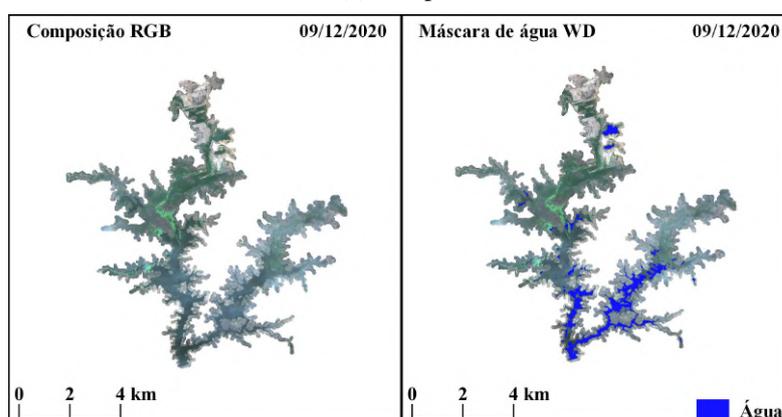
Para o *WaterDetect*, o reservatório de Poço da Cruz obteve o melhor valor de  $\rho$ , indicando uma correlação ótima com os valores *in situ*. Em relação ao MapBiomias, o reservatório de Chapéu obteve alcançou o melhor valor de  $\rho$ . No geral, *WaterDetect* e MapBiomias alcançaram valores semelhantes de CV.

#### 4.2.2 Problemas com detecção de água em imagens ópticas

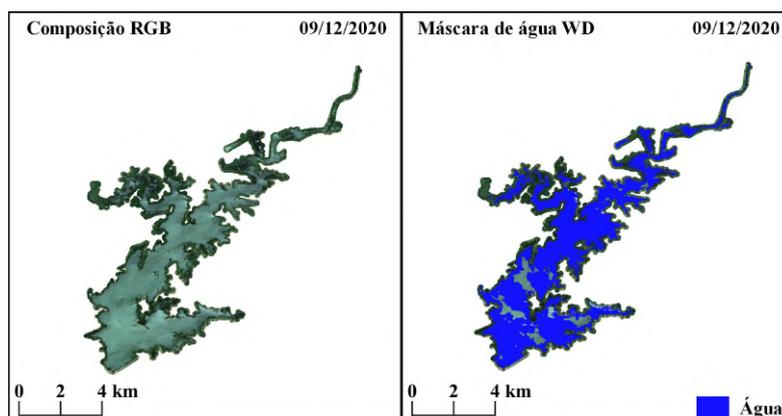
Para verificar a qualidade da detecção dos *pixels* de água do *WaterDetect*, as máscaras de água geradas foram analisadas e comparadas com a composição RGB e com o valor de área de água de referência. A título de exemplo, a Figura 22 apresenta um caso de erros na classificação de *pixels* de água para cada reservatório.

Figura 22 – Composição RGB de imagens Sentinel 2 e *pixels* de água detectadas pelo *WaterDetect*

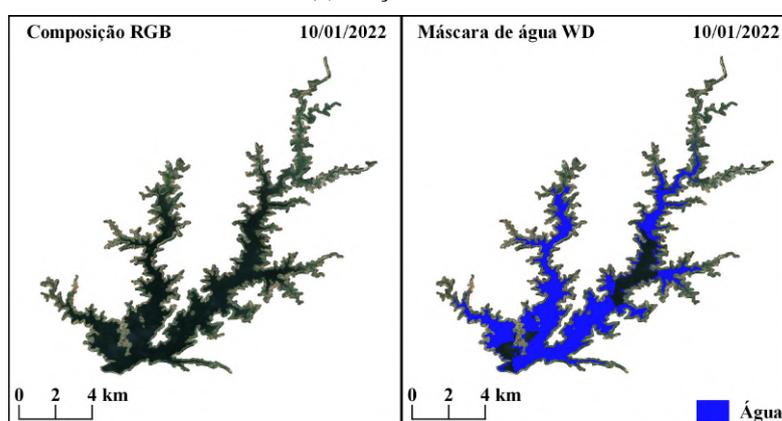
(a) Chapéu



(b) Serrinha II



(c) Poço da Cruz



Fonte: O autor (2023).

Uma vez que a água em sensores ópticos é capturada pelo recebimento da luz solar refletida, pode ocorrer problemas na detecção em função de cobertura e sombra de nuvens e da direção da luz solar refletida e recebida pelo sensor do satélite (Harmel; Chami, 2013). Para as datas referentes a cada reservatório dos casos apresentados na Figura 22 não houve cobertura de nuvem, mas é possível notar falhas na composição da máscara de água, com *pixels* de "água" classificados como *pixels* de "não água". Erros de detecção como esses podem causar grandes diferenças entre os valores de água calculados e os de referência *in situ*, como mostrado na Tabela 18.

Tabela 18 – Comparação de valores de área *WaterDetect* e *in situ*

Reservatório	Área (km <sup>2</sup> )		Data
	WD	<i>in situ</i>	
Chapéu	2,566	12,780	09/12/2020
Serrinha II	25,905	41,483	09/12/2020
Poço da Cruz	22,609	31,063	10/01/2022

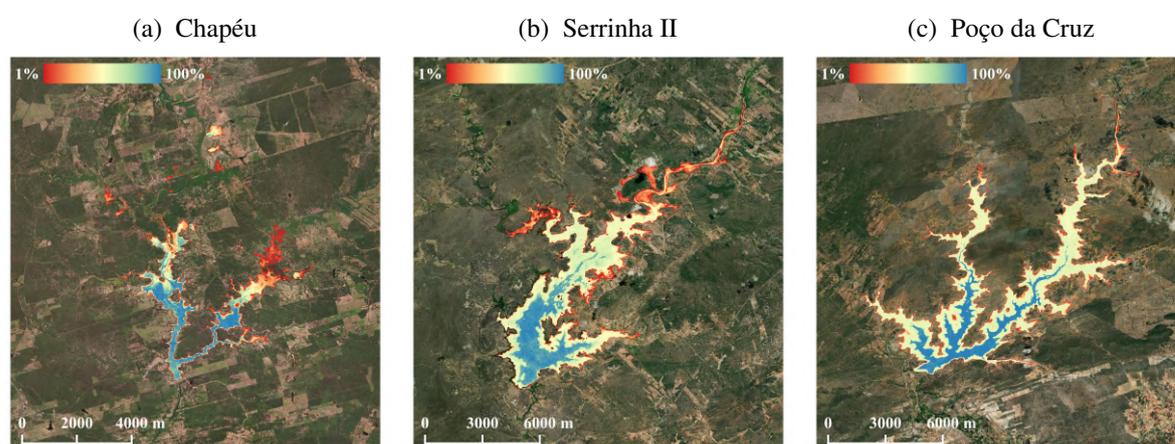
Fonte: O autor (2023).

Os resultados encontrados neste trabalho pela aplicação de produtos Sentinel 2 com o uso do algoritmo *WaterDetect* divergem daqueles obtidos por Cordeiro, Martinez e Peña-Luque (2021), visto que o autor obteve bons resultados de detecção de água com o algoritmo, especialmente em grandes reservatórios. Além disso, não foram mencionados pelo autor erros de classificação de *pixels*, como os observados nos exemplos apresentados na Figura 22.

### 4.2.3 Análise de ocorrência de água

A Figura 23 apresenta os mapas de ocorrência de água de imagens Sentinel 2 processadas pelo *WaterDetect*.

Figura 23 – Mapas de ocorrência de água de observações Sentinel 2 processadas pelo *WaterDetect*



Fonte: O autor (2023).

Da Figura 23 é possível notar que os três reservatórios possuem forma complexa com diversas ramificações e braços estreitos. Além disso, pode haver ainda a ocorrência de vegetação na margem dos corpos d'água. Todos esses pontos levantados, juntamente com os problemas de classificação de *pixels* mencionados acima, podem afetar a qualidade da detecção de água e, por conseguinte, os valores de área de água superficial, mesmo em reservatórios de grande dimensão, como os analisados no âmbito dessa abordagem.

### 4.2.4 Correção dos dados calculados

Por fim, foi aplicada a RNA de tipo MLP aos valores de área obtidos pelo *WaterDetect* para correção de viés. Os resultados mostraram que o tamanho de amostra necessário para o treinamento e calibração do modelo foi equivalente a 20% da série temporal para os três reservatórios considerados. A Tabela 19 apresenta as métricas de avaliação de calibração e

validação associadas para cada reservatório.

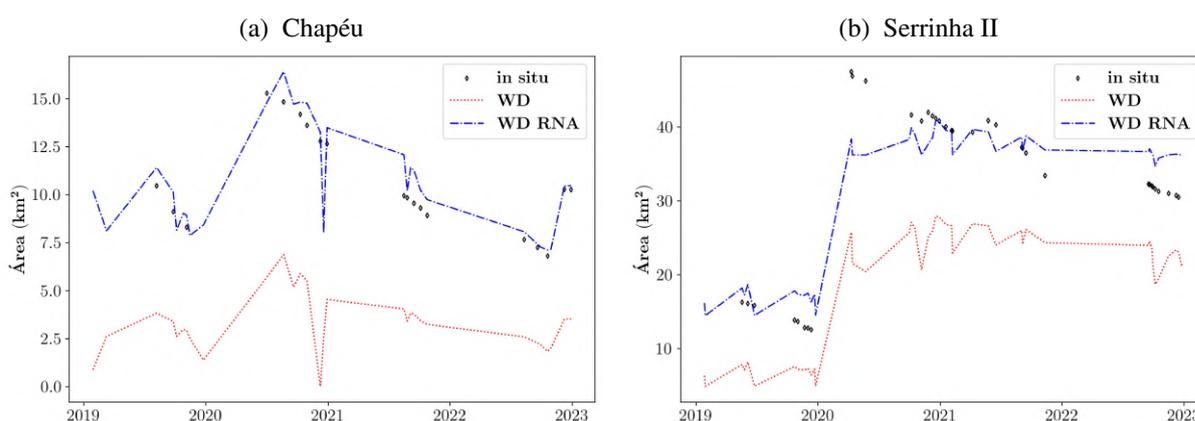
Tabela 19 – Métricas de avaliação da RNA MLP aplicadas em produtos Sentinel 2

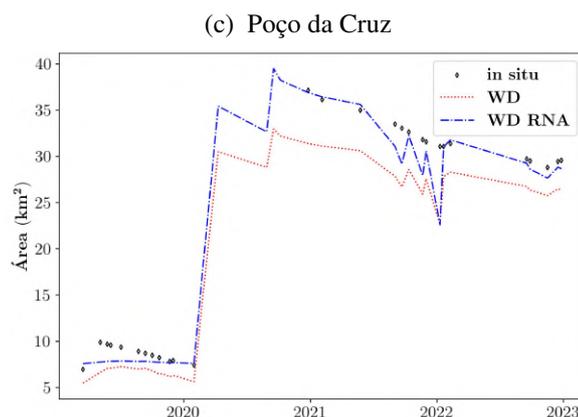
Reservatório	MAE (km <sup>2</sup> )		RMSE (km <sup>2</sup> )		RRMSE (%)	
	Cal	Val	Cal	Val	Cal	Val
Chapéu	0,133178	0,672927	0,142634	0,903481	0,53	1,80
Serrinha II	1,566387	3,204256	1,830185	4,688994	1,81	2,38
Poço da Cruz	0,374398	1,131829	0,418639	1,898316	0,75	1,46

Fonte: O autor (2023).

Da Tabela 19, nota-se que, em relação às métricas de avaliação associadas aos modelos de RNA, o reservatório de Chapéu alcançou os resultados mais satisfatórios, seguido do reservatório de Poço da Cruz, com Serrinha II ficando com os resultados menos satisfatórios. Entretanto, as métricas apresentadas na Tabela 16 referem-se às etapas de calibração e validação do modelo RNA, de modo que os valores de métrica alcançados na validação podem não refletir a mesma acurácia dos valores alcançados no treinamento e calibração (Moghim; Bras, 2017), o que é o caso, por exemplo, dos reservatórios de Serrinha II e Poço da Cruz, dada a diferença das métricas nas duas etapas. A Figura 24 apresenta os valores de área de água calculada com viés corrigido pela RNA MLP.

Figura 24 – Área de água observada, calculada e corrigida via RNA MLP com produtos Sentinel 2





Fonte: O autor (2023).

A partir da análise visual dos gráficos apresentados na Figura 24, é possível notar que a correção de viés alcançou um bom ajuste aos valores de referência (*in situ*) para os reservatórios de Chapéu e Serrinha II, Figuras 24a e 24b, respectivamente. O ajuste da curva para o reservatório de Poço da Cruz, Figura 24c, não foi satisfatório, visto que a curva resultante do modelo de RNA aplicado superestimou os valores de referência. De modo geral, a qualidade da correção aplicada aos três reservatórios considerados nessa abordagem ficou abaixo da apresentada na correção aplicada às imagens Sentinel 1, isso pode ser resultado do tamanho de amostra reduzido para o treinamento da RNA.

## 5 CONCLUSÕES E RECOMENDAÇÕES

O monitoramento contínuo de reservatórios para uma gestão eficiente dos recursos hídricos é considerado essencial, dada a sua relevância socioeconômica em cenários de grande demanda e de escassez de água. A metodologia proposta dividiu-se em duas abordagens: a primeira, com o uso de imagens de radar do satélite Sentinel 1, foi aplicada em um conjunto de seis reservatórios na Zona da Mata e Região Metropolitana do Recife no estado de Pernambuco; a segunda, com o uso de imagens ópticas do satélite Sentinel 2, foi aplicada em um conjunto de três reservatórios no sertão pernambucano. Os resultados das duas abordagens foram comparados com a base de dados de referência de monitoramento *in situ* e com a coleção MapBiomas.

De modo geral, a detecção de água utilizando produtos de radar Sentinel 1 mostrou-se satisfatória, visto que seus resultados mostraram que é possível acompanhar as tendências de aumento e queda do nível da água através do cálculo da área superficial da água nos reservatórios. Entretanto, existem limitações com a detecção de *pixels* de água próximos aos limites dos reservatórios, refletido na dificuldade dos valores de área calculados em aproximar-se dos valores mais altos de área dos dados observados *in situ*. Essas limitações podem ser em função de diversos fatores, como, por exemplo, da complexidade do formato do espelho d'água dos reservatórios, com descontinuidades e/ou braços estreitos, ou ainda da ocorrência de vegetação próxima à margem dos corpos hídricos, visto que os algoritmos de detecção empregados possuem eficiência reduzida em mapear água com vegetação.

Dentre todos os métodos testados na abordagem 1 com a utilização de imagens de radar, o algoritmo *SurfWater* apresentou os melhores resultados, seguido do método de limiar predefinido. Com a realização dos testes dos diversos cenários para os parâmetros de entrada do *SurfWater*, foi possível notar que os parâmetros apresentaram sensibilidade considerável, dada a diferença de resultado entre os cenários testados. A mesma sensibilidade não foi observada para os testes de composição de polarização, visto que não houve grande diferença nos resultados apresentados. Alterações nas rotinas do algoritmo *SurfWater* podem ser testadas a fim de aprimorar a detecção de água, tendo como finalidade a melhoria na detecção de água em ambientes complexos. Entretanto, a limitação dos tipos de produtos de satélite que podem ser executados no *SurfWater* torna o algoritmo inviável para aplicações de grande escala, como o monitoramento de reservatórios em toda a amplitude do estado de Pernambuco. Recomenda-se, para trabalhos futuros, a realização de testes de parâmetros do algoritmo *SurfWater* que não foram levados em conta no âmbito deste trabalho, podendo citar, como exemplo, o tamanho da janela de tempo considerado para a

geração da máscara final de água, a fim de melhorar as zonas de água de detectada.

Para a abordagem 2, com a utilização de imagens ópticas, de modo geral, os resultados da detecção de água não foram satisfatórios, dada a grande diferença entre os valores de área calculados das máscaras de água geradas pelo algoritmo *WaterDetect* e os valores obtidos do monitoramento *in situ*. Diversas dificuldades foram notadas com o uso de produtos ópticos provenientes do satélite Sentinel 2. A primeira dificuldade refere-se à limitação quanto à ocorrência de nuvens nas imagens, de modo que, mesmo com reservatórios localizados em áreas com cobertura de nuvem reduzida, como a região Sertão do estado de Pernambuco, diversos produtos obtidos dentro do período de análise foram descartados. Além disso, diversas máscaras de água geradas pelo *WaterDetect* foram inviabilizadas por apresentarem falhas na detecção dos *pixels* de água, o que pode ser uma limitação do algoritmo na classificação dos *pixels* em situações específicas de reflexo da luz solar emitida pelo corpo hídrico. Vale destacar que os resultados obtidos com o *WaterDetect* e com o MapBiomias são bastante similares, o que pode reforçar a hipótese da limitação do uso de imagens ópticas para o monitoramento de reservatórios na região. Desse modo, testes podem ser realizados na região semiárida utilizando imagens de radar a fim de verificar a acurácia na detecção de água superficial no bioma considerado e fazendo um comparativo com a detecção de água por imagens ópticas.

Foram notadas algumas limitações com o uso dos dados MapBiomias que podem inviabilizar a sua utilização como base de dados de referência. A primeira limitação refere-se à escala temporal do MapBiomias, visto que a base de dados não fornece valores de área para a escala diária, sendo possível obter apenas dados nas escalas mensal e anual. A segunda limitação é referente à composição dos corpos hídricos adotada pelo MapBiomias, de modo que, a depender do tamanho e da proximidade entre os reservatórios, a base de dados pode considerar que dois ou mais reservatórios constituem um único corpo hídrico, é o caso, por exemplo, dos reservatórios de Bitá e Utinga, analisados neste trabalho, em que o MapBiomias os consideram como um único corpo hídrico, não sendo possível a análise individual e restrita dos reservatórios. Para a terceira e última limitação observada, o MapBiomias apresentou um comportamento de subestimação dos valores mais inferiores de área de água, de modo que não refletiu adequadamente a tendência da série histórica. Entretanto, vale destacar que os resultados do *SurfWater* e do MapBiomias foram similares para o reservatório de Sicupema, considerando que apresentaram um comportamento significativo de superestimação dos valores de área quando comparados aos valores obtidos do monitoramento *in situ*, o que pode refletir erros de medição ou CAV desatualizada dos valores obtidos pelo ANA-SAR. Portanto, a recomendação é que os produtos MapBiomias sejam usados

apenas para confirmar ou reforçar hipótese de erros da base de dados usada como referência, como o caso apresentado neste trabalho.

Por fim, os resultados de correção de viés utilizando RNA, de modo geral, mostraram-se satisfatórios para os casos em que o tamanho da amostra de teste – isto é, a quantidade de dados de monitoramento *in situ* nas mesmas datas dos dados calculados dos algoritmos de detecção – foi suficiente para treinamento e construção do modelo MLP. Em situações como essas, o mesmo modelo obtido poderá ser aplicado a novos valores de área de água calculados, visto que conseguiu refletir com eficiência o comportamento da série histórica observada. Entretanto, considerando a complexidade de implementação da RNA e que a correção da série temporal calculada para as situações abordadas neste estudo depende somente da série temporal observada, recomenda-se testar o método de regressão linear a fim de verificar simplificação da metodologia para correção de viés.

## REFERÊNCIAS

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO. *Cadernos de Capacitação em Recursos Hídricos: Sistemas de informação na gestão de águas: conhecer para decidir*. Brasília, 2016. 122 p. Disponível em: <[https://biblioteca.ana.gov.br/sophia\\_web/Acervo/Detalhe/68931](https://biblioteca.ana.gov.br/sophia_web/Acervo/Detalhe/68931)>.

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO. *Plano Nacional de Segurança Hídrica*. Brasília, 2019. 112 p. Disponível em: <<https://arquivos.ana.gov.br/pnsh/pnsh.pdf>>.

AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO. *Atlas águas: segurança hídrica do abastecimento urbano*. Brasília, 2021. 332 p. Disponível em: <<https://atlas.ana.gov.br>>.

AICHOURI, I. *et al.* River flow model using Artificial Neural Networks. *Energy Procedia*, v. 74, p. 1007–1014, 2015.

ALSDORF, D. E.; RODRIGUEZ, E.; LETTENMAIER, D. P. Measuring surface water from space. *Reviews of Geophysics*, v. 45, n. 2, 2007.

BAI, Z. G. *et al.* Proxy global assessment of land degradation. *Soil Use and Management*, v. 24, n. 3, p. 223–234, 2008.

BOGARDI, J. J. *et al.* Water security for a planet under pressure: interconnected challenges of a changing world call for sustainable solutions. *Current Opinion in Environmental Sustainability*, v. 4, n. 1, p. 35–43, 2012.

BOLANOS, S. *et al.* Operational surface water detection and monitoring using Radarsat 2. *Remote Sensing*, v. 8, n. 4, 2016.

BREIMAN, L. Random Forests. *Machine Learning*, v. 45, p. 5–32, 2001.

BRISCO, B. *et al.* A semi-automated tool for surface water mapping with RADARSAT-1. *Canadian Journal of Remote Sensing*, v. 35, n. 4, p. 336–344, 2009.

CALIŃSKI, T.; HARABASZ, J. A dendrite method for cluster analysis. *Communications in Statistics*, v. 3, n. 1, p. 1–27, 1974.

CATRY, T. *et al.* Wetlands and malaria in the Amazon: Guidelines for the use of Synthetic Aperture Radar remote-sensing. *International Journal of Environmental Research and Public Health*, v. 15, n. 3, 2018.

CHAO, B. F.; WU, Y. H.; LI, Y. S. Impact of artificial reservoir water impoundment on global sea level. *Science*, v. 320, n. 5873, p. 212–214, 2008.

CHEN, Y.; MING, Z.; MENENTI, M. Change detection algorithm for multi-temporal remote sensing images based on adaptive parameter estimation. *IEEE Access*, v. 8, p. 106083–106096,

2020.

CHUNG, J. *et al.* Soil moisture content estimation based on Sentinel-1 SAR imagery using an Artificial Neural Network and hydrological components. *Remote Sensing*, v. 14, n. 3, 2022.

COLLISCHONN, B.; CLARKE, R. T. Estimativa e incerteza de curvas cota-volume por meio de sensoriamento remoto. *Revista Brasileira de Recursos Hídricos (RBRH)*, v. 21, n. 4, p. 719–727, 2016.

CONDE, F. C.; MUÑOZ, M. D. M. Flood monitoring based on the study of Sentinel-1 SAR images: The Ebro River case study. *Water*, v. 11, n. 12, 2019.

CONDEÇA, J.; NASCIMENTO, J.; BARREIRAS, N. Monitoring the storage volume of water reservoirs using Google Earth Engine. *Water Resources Research*, v. 58, n. 3, 2022.

COOLEY, S. W.; RYAN, J. C.; SMITH, L. C. Human alteration of global surface water storage variability. *Nature*, v. 591, 2021.

CORDEIRO, M. C.; MARTINEZ, J.-M.; PEÑA-LUQUE, S. Automatic water detection from multidimensional hierarchical clustering for Sentinel-2 images and a comparison with level 2A processors. *Remote Sensing of Environment*, v. 253, 2021.

DABBOOR, M.; BRISCO, B. Wetland monitoring and mapping using Synthetic Aperture Radar. In: GÖKÇE, D. (Ed.). *Wetlands Management*. Rijeka: IntechOpen, 2018. cap. 5. Disponível em: <<https://doi.org/10.5772/intechopen.80224>>.

DRUSCH, M. *et al.* Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, v. 120, p. 25–36, 2012.

DU, Y. *et al.* Water bodies' mapping from Sentinel-2 imagery with Modified Normalized Difference Water Index at 10-m spatial resolution produced by sharpening the SWIR band. *Remote Sensing*, v. 8, n. 4, 2016.

ESTADO DE PERNAMBUCO. *Plano Estadual de Mudanças Climáticas*. Recife, 2011. 94 p.

EUROPEAN SPACE AGENCY. *Sentinel-2 User Handbook*. Paris, 2015. 64 p. Disponível em: <[https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2\\_User\\_Handbook](https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook)>. Acesso em: 17 ago. 2023.

EUROPEAN SPACE AGENCY. *Sentinel-1B in-flight anomaly summary report*. Paris, 2022. Disponível em: <<https://sentinel.esa.int/documents/247904/4819394/Sentinel-1B+In-Flight+Anomaly+Summary+Report.pdf>>. Acesso em: 27 fev. 2024.

FACELI, K. *et al.* *Inteligência Artificial: Uma abordagem de aprendizado de máquina*. Rio de Janeiro: LTC, 2019. 387 p.

FALKENMARK, M. Adapting to climate change: towards societal water security in dry-climate

- countries. *International Journal of Water Resources Development*, v. 29, n. 2, p. 123–136, 2013.
- FEYISA, G. L. *et al.* Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment*, v. 140, p. 23–35, 2014. ISSN 0034-4257.
- FILIPPONI, F. Sentinel-1 grd preprocessing workflow. *Proceedings*, v. 18, n. 1, 2019.
- FILIPPUCCI, P. *et al.* Sentinel-2 high-resolution data for river discharge monitoring. *Remote Sensing of Environment*, v. 281, 2022.
- GEDNEY, N. *et al.* Detection of a direct carbon dioxide effect in continental river runoff records. *Nature*, v. 439, p. 835–838, 2006.
- GLEICK, P. H. Global freshwater resources: Soft-path solutions for the 21st century. *Science*, v. 302, n. 5650, p. 1524–1528, 2003.
- GREY, D.; SADOFF, C. W. Sink or Swim? Water security for growth and development. *Water Policy*, v. 9, n. 6, p. 545–571, 2007.
- HAGOLLE, O. *et al.* A multi-temporal method for cloud detection, applied to FORMOSAT-2, VEN $\mu$ S, LANDSAT and SENTINEL-2 images. *Remote Sensing of Environment*, v. 114, n. 8, p. 1747–1755, 2010.
- HAN, G. *et al.* Bias correction of sea surface temperature retrospective forecasts in the South China Sea. *Acta Oceanologica Sinica*, v. 41, n. 2, p. 41–50, 2022.
- HAN, L. *et al.* A Deep Learning method for bias correction of ECMWF 24–240 h forecasts. *Advances in Atmospheric Sciences*, v. 38, n. 9, p. 1444–1459, 2021.
- HARMEL, T.; CHAMI, M. Estimation of the sunglint radiance field from optical satellite imagery over open ocean: Multidirectional approach and polarization aspects. *Journal of Geophysical Research: Oceans*, v. 118, n. 1, p. 76–90, 2013.
- HE, S. *et al.* Multi-objective operation of cascade reservoirs based on short-term ensemble streamflow prediction. *Journal of Hydrology*, v. 610, 2022.
- HUANG, C. *et al.* Detecting, extracting, and monitoring surface water from space using optical sensors: A review. *Reviews of Geophysics*, v. 56, n. 2, p. 333–360, 2018.
- HUANG, W. *et al.* Automated extraction of surface water extent from Sentinel-1 data. *Remote Sensing*, v. 10, n. 5, 2018.
- IPCC. *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2013. 1535 p.

JABBARI, A.; BAE, D.-H. Application of artificial neural networks for accuracy enhancements of real-time flood forecasting in the imjin basin. *Water*, v. 10, n. 11, 2018.

KINGMA, D. P.; BA, J. *Adam: A Method for Stochastic Optimization*. 2017.

KITTLER, J.; ILLINGWORTH, J. Minimum error thresholding. *Pattern Recognition*, v. 19, n. 1, p. 41–47, 1986.

LARY, D. J. *et al.* Machine Learning and bias correction of MODIS Aerosol Optical Depth. *IEEE Geoscience and Remote Sensing Letters*, v. 6, n. 4, p. 694–698, 2009.

LE, X.-H. *et al.* Application of convolutional neural network for spatiotemporal bias correction of daily satellite-based precipitation. *Remote Sensing*, v. 12, n. 17, 2020.

LEEUWEN, B. van; TOBAK, Z.; KOVÁCS, F. Sentinel-1 and -2 based near real time inland excess water mapping for optimized water management. *Sustainability*, v. 12, n. 7, 2020.

LI, J. *et al.* Satellite detection of surface water extent: A review of methodology. *Water*, v. 14, n. 7, 2022.

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. 53–62, 2020.

LIAW, A.; WIENER, M. *et al.* Classification and regression by randomForest. *R news*, v. 2, n. 3, p. 18–22, 2002.

LICKLEY, M.; SOLOMON, S. Drivers, timing and some impacts of global aridity change. *Environmental Research Letters*, v. 13, n. 10, 2018.

LUO, C. *et al.* Characteristics of reservoirs to mitigate drought effects with a hedging rule triggered by drought limited water level. *Journal of Hydrology*, v. 617, 2023.

MANJUSREE, P. *et al.* Optimization of threshold ranges for rapid flood inundation mapping by evaluating backscatter profiles of high incidence angle SAR images. *International Journal of Disaster Risk Science*, v. 3, p. 113–122, 2012.

MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil—past, present, and future. *Theoretical and Applied Climatology*, v. 129, p. 1189–1200, 2017.

MARKERT, K. N. *et al.* On the merging of optical and SAR satellite imagery for surface water mapping applications. *Results in Physics*, v. 9, p. 275–277, 2018.

MARTINIS, S. *et al.* Towards a global seasonal and permanent reference water product from Sentinel-1/2 data for improved flood mapping. *Remote Sensing of Environment*, v. 278, 2022.

MARTINIS, S.; PLANK, S.; ČWIK, K. The use of Sentinel-1 time-series data to improve flood monitoring in arid areas. *Remote Sensing*, v. 10, n. 4, 2018.

- MARTINIS, S.; TWELE, A.; VOIGT, S. Towards operational near real-time flood detection using a split-based automatic thresholding procedure on high resolution TerraSAR-X data. *Natural Hazards and Earth System Sciences*, v. 9, n. 2, p. 303–314, 2009.
- MARTINS, V. S. *et al.* Remote sensing of large reservoir in the drought years: Implications on surface water change and turbidity variability of Sobradinho reservoir (Northeast Brazil). *Remote Sensing Applications: Society and Environment*, v. 13, p. 275–288, 2019.
- MCFEETERS, S. K. The use of the normalized difference water index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, v. 17, n. 7, p. 1425–1432, 1996.
- MOGHIM, S.; BRAS, R. L. Bias correction of climate modeled temperature and precipitation using artificial neural networks. *Journal of Hydrometeorology*, American Meteorological Society, v. 18, n. 7, p. 1867–1884, 2017.
- MORANDEIRA, N. S. *et al.* Mapping plant functional types in floodplain wetlands: An analysis of C-Band polarimetric SAR data from RADARSAT-2. *Remote Sensing*, v. 8, n. 3, 2016.
- MUELLER-WILM, U.; DEVIGNOT, O.; PESSIOT, L. *Sen2Cor configuration and user manual*. Telespazio VEGA Deutschland GmbH: Darmstadt, Germany, 2016. Disponível em: <<https://step.esa.int/thirdparties/sen2cor/2.11.0/docs/OMPC.TPZG.SUM.001%20-%20i1r0%20-%20Sen2Cor%202.11.00%20Configuration%20and%20User%20Manual.pdf>>. Acesso em: 11 set. 2023.
- NIELSEN, F. Hierarchical clustering. In: \_\_\_\_\_. *Introduction to HPC with MPI for Data Science*. Cham: Springer International Publishing, 2016. p. 195–211.
- NOBRE, A. *et al.* Height Above the Nearest Drainage – a hydrologically relevant new terrain model. *Journal of Hydrology*, v. 404, n. 1, p. 13–29, 2011.
- 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.
- PALOSCIA, S. *et al.* Soil moisture mapping using Sentinel-1 images: Algorithm and preliminary validation. *Remote Sensing of Environment*, v. 134, p. 234–248, 2013.
- PAN, B. *et al.* Improving precipitation estimation using Convolutional Neural Network. *Water Resources Research*, v. 55, n. 3, p. 2301–2321, 2019.
- PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.
- PEKEL, J.-F. *et al.* High-resolution mapping of global surface water and its long-term changes. *Nature*, v. 540, p. 418–422, 2016.
- PEÑA-LUQUE, S. *et al.* Sentinel-1&2 multitemporal water surface detection accuracies, evaluated at regional and reservoirs level. *Remote Sensing*, v. 13, n. 16, 2021.

PENG, T. *et al.* Streamflow forecasting using empirical Wavelet Transform and Artificial Neural Networks. *Water*, v. 9, n. 6, 2017.

PEREIRA, L. S.; CORDERY, I.; IACOVIDES, I. *Coping with water scarcity: Addressing the challenges*. Paris: Springer Science & Business Media, 2009. 385 p.

PERNAMBUCO. SECRETARIA DE INFRAESTRUTURA E RECURSOS HÍDRICOS. *Plano Estadual de Recursos Hídricos de Pernambuco - PERH/PE: Volume 4 – Diagnóstico Integrado*. Recife, 2022. 299 p. Disponível em: <<https://www.apac.pe.gov.br/planos>>.

PHAM-DUC, B.; PRIGENT, C.; AIRES, F. Surface water monitoring within Cambodia and the Vietnamese Mekong Delta over a year, with Sentinel-1 SAR observations. *Water*, v. 9, n. 6, 2017.

RÄTTICH, M.; MARTINIS, S.; WIELAND, M. Automatic flood duration estimation based on multi-sensor satellite data. *Remote Sensing*, v. 12, n. 4, 2020.

SAID, S.; KOTHYARI, U. C.; ARORA, M. K. ANN-based soil moisture retrieval over bare and vegetated areas using ERS-2 SAR data. *Journal of Hydrologic Engineering*, v. 13, n. 6, p. 461–475, 2008.

SANTORO, M.; WEGMÜLLER, U. Multi-temporal synthetic aperture radar metrics applied to map open water bodies. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, n. 8, p. 3225–3238, 2014.

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.

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.

SCOTT, C. A. *et al.* Water Security and Adaptive Management in the Arid Americas. *Annals of the Association of American Geographers*, v. 103, n. 2, p. 280–289, 2013.

SISTEMA DE ESTIMATIVAS DE EMISSÕES DE GASES DE EFEITO ESTUFA DO OBSERVATÓRIO DO CLIMA. *Projeto MapBiomias – Coleção 8 da Série Anual de Mapas de Uso e Cobertura da Terra do Brasil*. Brasília, 2022. Disponível em: <<https://brasil.mapbiomas.org/>>. Acesso em: 21 set. 2023.

SOUZA, C. M. *et al.* Reconstructing three decades of land use and land cover changes in Brazilian Biomes with Landsat archive and Earth Engine. *Remote Sensing*, v. 12, n. 17, 2020.

SOUZA, W. d. O. *et al.* Analysis of environmental and atmospheric influences in the use of SAR and optical imagery from Sentinel-1, Landsat-8, and Sentinel-2 in the operational monitoring of reservoir water level. *Remote Sensing*, v. 14, n. 9, 2022.

SRINIVASAN, V.; KONAR, M.; SIVAPALAN, M. A dynamic framework for water security.

*Water Security*, v. 1, p. 12–20, 2017.

TAFFARELLO, D. *et al.* Field investigations of the 2013–14 drought through quali-quantitative freshwater monitoring at the headwaters of the Cantareira System, Brazil. *Water International*, v. 41, n. 5, p. 776–800, 2016.

TAPIADOR, F. J. *et al.* Neural networks in satellite rainfall estimation. *Meteorological Applications*, v. 11, n. 1, p. 83–91, 2004.

TAYFUR, G. *et al.* Flood hydrograph prediction using Machine Learning methods. *Water*, v. 10, n. 8, 2018.

TIEN BUI, D. *et al.* New hybrids of ANFIS with several optimization algorithms for flood susceptibility modeling. *Water*, v. 10, n. 9, 2018.

TORRES, R. *et al.* GMES Sentinel-1 mission. *Remote Sensing of Environment*, v. 120, p. 9–24, 2012.

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, 2022.

TULBURE, M. G. *et al.* Surface water extent dynamics from three decades of seasonally continuous landsat time series at subcontinental scale in a semi-arid region. *Remote Sensing of Environment*, v. 178, p. 142–157, 2016.

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.

UN-Water. *Water Security & the Global Water Agenda – A UN-Water Analytical Brief*. United Nations University, 2013. 45 p. Disponível em: <<https://www.unwater.org/publications/water-security-and-global-water-agenda>>.

UNITED NATIONS. *Sustainable Development Goal 6 Synthesis Report 2018 on Water and Sanitation*. New York, 2018. 195 p.

VAN DER WALT, S. *et al.* Scikit-image: image processing in Python. *PeerJ*, v. 2, n. e453, 2014.

VANDERHOOF, M. K. *et al.* High-frequency time series comparison of Sentinel-1 and Sentinel-2 satellites for mapping open and vegetated water across the United States (2017–2021). *Remote Sensing of Environment*, v. 288, 2023.

VIEIRA, R. M. S. P. *et al.* Identifying areas susceptible to desertification in the Brazilian northeast. *Solid Earth*, v. 6, n. 1, p. 347–360, 2015.

WADA, Y. *et al.* Modeling global water use for the 21st century: the Water Futures and Solutions (WFaS) initiative and its approaches. *Geoscientific Model Development*, v. 9, p. 175–222, 2016.

WAGENER, T. *et al.* The future of hydrology: An evolving science for a changing world. *Water Resources Research*, v. 46, n. 5, 2010.

WANG, X. *et al.* A robust Multi-Band Water Index (MBWI) for automated extraction of surface water from Landsat 8 OLI imagery. *International Journal of Applied Earth Observation and Geoinformation*, v. 68, p. 73–91, 2018.

WHITE, L. *et al.* RADARSAT-2 beam mode selection for surface water and flooded vegetation mapping. *Canadian Journal of Remote Sensing*, v. 40, n. 2, p. 135–151, 2014.

WIELAND, M.; MARTINIS, S. A modular processing chain for automated flood monitoring from multi-spectral satellite data. *Remote Sensing*, v. 11, n. 19, 2019.

WIELAND, M.; MARTINIS, S. Large-scale surface water change observed by Sentinel-2 during the 2018 drought in Germany. *International Journal of Remote Sensing*, v. 41, n. 12, p. 4742–4756, 2020.

XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, v. 27, n. 14, p. 3025–3033, 2006.

YAMAZAKI, D. *et al.* MERIT Hydro: A high-resolution global hydrography map based on latest topography dataset. *Water Resources Research*, v. 55, n. 6, p. 5053–5073, 2019.

YANG, X. *et al.* Urban surface water body detection with suppressed built-up noise based on water indices from Sentinel-2 MSI imagery. *Remote Sensing of Environment*, v. 219, p. 259–270, 2018.

YANG, Z. *et al.* Multi-objective operation-decision-making-risk propagation analysis for cascade reservoirs affected by future streamflow process variations. *Journal of Hydrology*, v. 620, 2023.