

Extração de Corpo Hídrico Usando uma Cena Sentinel-1 e Redes Neurais Artificiais: Estudo de Caso – Barragem de Carpina-PE

Water Body Extraction Using a Sentinel-1 Scene and Artificial Neural Networks: Case Study – Carpina-PE Dam

Juarez Antônio da Silva Júnior¹ 

Ubiratan Joaquim da Silva Junior² 

Palavras-chave:

Aprendizagem Profunda
Sensoriamento Remoto
Radar de Abertura Sintética
Recursos Hídricos

Resumo

A água de superfície é o recurso e fator ambiental mais importante para manter a sobrevivência humana e a estabilidade dos ecossistemas, portanto, informações precisas e oportunas sobre águas superficiais são urgentemente necessárias. Neste estudo foi proposto uma abordagem de classificação de imagens por Redes Neurais Artificiais para o mapeamento da extensão da água de superfície da Barragem de Carpina-PE usando dados (SAR) do satélite Sentinel-1, bem como suas polarizações (VH e VV) e os índices polarimétricos de água gerados (SDWI e SWI). Todos os conjuntos de dados apresentaram limitações na detecção de pequenos corpos hídricos, como rios estreitos, e superestimação em áreas de pastagem, gerando erros de comissão variando de 16,5 % a 28,9% e erros de omissão variando entre 1,47% e 3,5%, com destaque para as polarizações VH e VV. A precisão geral da classificação variou de 96% a 98% e valores de R^2 chegaram próximo de 1, onde o melhor desempenho foi visto para o SDWI e o SWI. Os experimentos comparativos indicaram que, as polarizações unitárias de radar com índices polarimétricos de água, foram úteis para melhorar a precisão da extração de corpos hídricos em locais com muitas nuvens, sem variações significativas, além de fornecer informações detalhadas, com potencial de monitoramento contínuo.

Keywords

Deep Learning
Remote Sensing
Synthetic Aperture Radar
Water resources

Abstract

Surface water is the most important resource and environmental factor for maintaining human survival and ecosystem stability, therefore accurate and timely information on surface water is urgently needed. In this study, an image classification approach using Artificial Neural Networks was proposed for mapping the surface water extent of the Carpina-PE Dam using radar image from the Sentinel-1 satellite, as well as its polarizations (VH and VV) and the generated water indices (SDWI and SWI). All datasets presented limitations in detecting small water bodies, such as narrow rivers, and overestimation in pasture areas, generating commission errors ranging from 16.5% to 28.9% and omission errors ranging from 1.47% and 3.5%, with emphasis on VH and VV polarizations. The overall classification accuracy ranged from 96% to 98% and R^2 values reached close to 1, where the best performance was seen for SDWI and SWI. The comparative experiments indicated that unitary radar polarizations with water spectral indices were useful for improving the accuracy of extracting water bodies in places with clouds, without significant variations, in addition to providing detailed information, with potential for continuous monitoring.

¹ Universidade Federal de Pernambuco - UFPE, Recife, PE, Brasil. juarez.silvajunior@ufpe.br

² Universidade Federal de Pernambuco - UFPE, Recife, PE, Brasil. ubiratan.joaquim@ufpe.br

INTRODUÇÃO

Os corpos de água superficiais, como rios, lagos e reservatórios, desempenham papéis importantes no desenvolvimento socioeconômico e no equilíbrio dos ecossistemas, e fornecem recursos naturais insubstituíveis para a sobrevivência e o desenvolvimento humano. Sob a influência das alterações climáticas e das atividades humanas, a distribuição espacial e os componentes bioquímicos inerentes aos corpos de água superficiais estão a sofrer grandes mudanças. O monitoramento oportuno da dinâmica dos corpos de água superficiais é, portanto, de grande importância para estudos e atividades de planejamento relacionados à água, como gestão de recursos hídricos, prevenção de desastres hídricos e proteção dos ambientes aquáticos (Zhang *et al.* 2019; Guo *et al.* 2022).

Recentemente, os dados de sensoriamento remoto têm sido amplamente utilizados para o mapeamento da água. O Radar de Abertura Sintética (SAR), como um sensor ativo de micro-ondas, não é afetado pela cobertura de nuvens, então adquire imagens durante a noite, permite a obtenção de imagens em qualquer clima, e tem uma ampla gama de observações. Portanto, o mapeamento de corpos d'água com base em imagens SAR atraiu muitos estudiosos recentemente. Além disso, o uso do sensoriamento remoto de forma eficaz e de custo relativamente baixo para monitorar inundações e secas, pode dar uma grande contribuição para a tomada de decisões e ações de resgate (Bao *et al.*, 2021).

Os métodos atuais de extração de informações sobre água incluem os métodos de limite (Guo *et al.*, 2022), aprendizado de máquina (Rajendiran; Kumar, 2022) e aprendizado profundo (Li *et al.*, 2021), entre outros. O aprendizado profundo é um método popular no processamento de imagens que vem sendo muito usado nos últimos anos (Nasir *et al.*, 2023). As Redes Neurais Artificiais (RNAs) têm sido usadas na classificação de cenas (Tamiru; Dinka, 2021), e ainda são utilizados a segmentação semântica (Pinheiro, 2023) e a

detecção de objetos (Guo *et al.*, 2022). A vantagem das RNAs é capturar os recursos de imagens brutas por múltiplas redes neurais, o que pode evitar o processamento complexo de recursos. RNAs para segmentação semântica são capazes de realizar classificação de imagens em nível de pixel, o que é importante para extração de informações de imagens. Nas RNAs, as camadas artificiais rasas são capazes de capturar as informações de posição dos pixels e as camadas artificiais profundas são usadas para rotular os pixels. Dessa forma, As RNAs estão sendo gradualmente aplicadas para a extração de informações sobre água em imagens (Xie *et al.*, 2023).

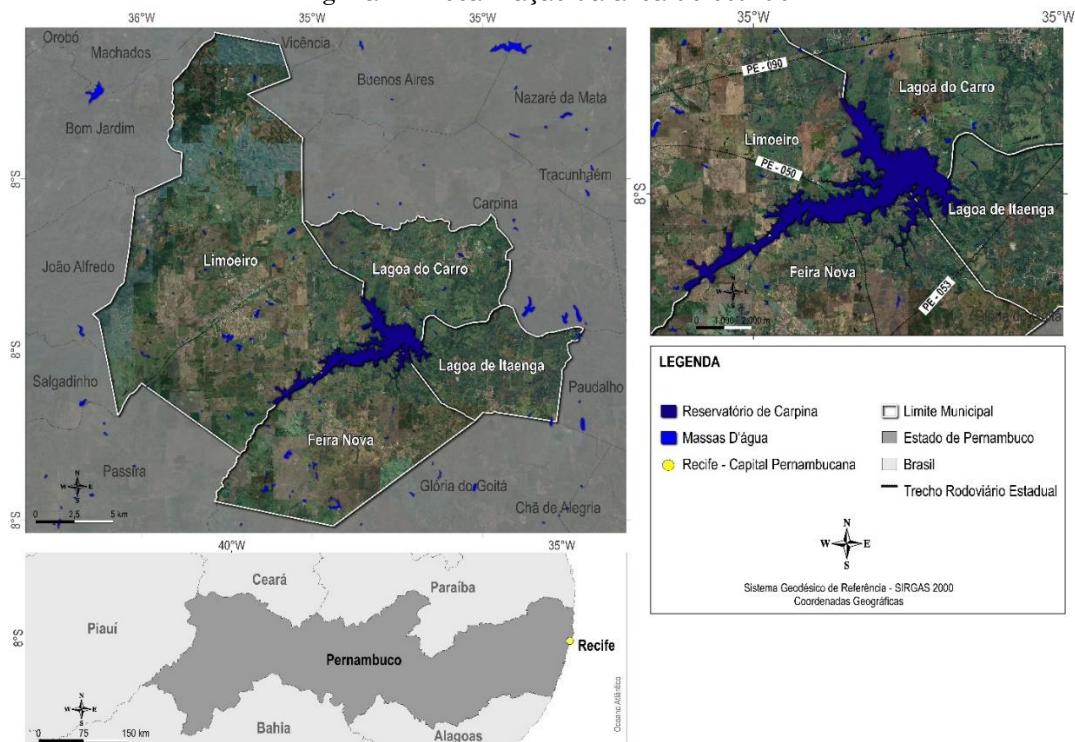
Os objetivos deste trabalho são, portanto, (1) realizar o treinamento de dados para a classificação de imagens pelo método de Redes Neurais Artificiais, baseado em número de épocas; (2) utilizar os métodos RNA para extrair espacialmente o corpo d'água da Barragem de Carpina; e finalmente, (3) avaliar quantitativamente a precisão desses algoritmos, utilizando três métricas de precisão e uma comparação visual.

MATERIAIS E MÉTODOS

Área de estudo

A barragem de Carpina tem as seguintes coordenadas centrais: 7°53'28"S 35°21'45"W. Localiza-se entre os municípios de Limoeiro, Lagoa do Carro, Lagoa de Itaenga e Feira Nova, e possui a capacidade de armazenamento de 270 milhões de metros cúbicos de água. Suas águas são usadas para o abastecimento público, a piscicultura e o controle de enchentes da Região Metropolitana de Recife (RMR), e tem como principal função o controle de cheias do Rio Capibaribe. Foi construída pelo extinto Departamento Nacional de Obras e Saneamento (DNOS) em 1978, em resposta à grande inundação da Região Metropolitana do Recife em 1975 (Lambert, 2021).

Figura 1 - Localização da área de estudo



Fonte: Os autores (2023).

A Barragem de Carpina é uma das maiores barragens de água do estado de Pernambuco e uma das mais importantes da bacia hidrográfica do Rio Capibaribe, e desempenha um importante papel na contenção de cheias do Rio Capibaribe, passando a ser utilizada também como fornecedora de água para consumo humano a partir do ano de 2002 (Costa Júnior, 2022).

Dados Sentinel-1 e pré-processamento

O Sentinel-1 é um programa de radar de abertura sintética, que tem uma constelação de dois satélites de órbita polar (Sentinel-1A e Sentinel-1B). Um conjunto de imagens do Sentinel-1A (faixa 69) foi usado neste estudo para a detecção da Barragem de Carpina. As imagens foram obtidas da Agência Espacial Européia (ESA), por meio do site do Copernicus (2023) referentes ao dia 20 de agosto de 2022. Os produtos S1A_IW_GRD Nível-1 utilizados, correspondem ao comprimento de onda de 5,6 cm nas polarizações VV e VH, operando na banda C (5,405 GHz). As imagens obtidas possuem uma largura de faixa de aproximadamente 250 km e resolução espacial de 10 m, onde cada pixel contém valores de intensidade de retroespalhamento de radar (Son et al. 2021).

O conjunto de ferramentas *Science Toolbox Exploitation Platform* (SNAP) desenvolvido pela

ESA foi utilizado para o pré-processamento de dados SAR, com o *Graph Processing Tools* (GPT) do *ESA's Toolbox* (S1TBX). Essas etapas incluem a calibração radiométrica, filtro speckle e correção de terreno. O objetivo da calibração SAR é fornecer imagens nas quais os valores dos pixels possam ser diretamente relacionados ao retroespalhamento do radar. Dessa forma, a calibração radiométrica converte os sinais brutos de pixels dos produtos S1A_IW_GRD na escala de número digital (ND), em intensidades de retroespalhamento sigma zero (σ^0). Devido à coerente interferência que se manifesta em imagens SAR, devido aos diversos espalhamentos elementares das ondas eletromagnéticas refletidas, ocorre um fenômeno perturbador conhecido como *speckle*. Esse fenômeno introduz ruído nas intensidades dos pixels da imagem, resultando em variações que exibem um padrão granular e comprometem a capacidade de interpretar a imagem de maneira adequada. Para reduzir o ruído *speckle*, foi utilizada a filtragem *speckle* com filtro de Lee, de tamanho de janela de 3x3 pixels. A minimização desse ruído é fundamental, para uma melhor extração de informações nesse tipo de imagem. Posteriormente, a Correção de Terreno *Range Doppler* foi aplicada para geocodificar as imagens, uma vez que a geometria da visão lateral do sistema SAR e a topografia da Terra causam várias distorções. Essa correção foi feita com o uso do modelo

terrestre *Shuttle Radar Topography Mission* (SRTM) (Filipponi, 2019).

Dual-Polarized Water Index (SDWI)

A seleção de um índice de água é de crucial importância para a extração de corpos hídricos por sensoriamento remoto. Neste trabalho, além das polarizações VV e VH, o corpo hídrico também foi extraído usando o índice Sentinel-1 Dual-Polarized Water Index (SDWI) (Nasir *et al.*, 2023). Dedicado às bandas duplamente polarizadas do Sentinel-1, esse índice pode efetivamente distinguir a diferença entre água e outros objetos em bandas de onda duplamente polarizadas e pode aprimorar as informações dos corpos d'água de superfície e eliminar perturbações de outros tipos de superfície, como vegetação e solo. O SDWI (Equação 1) é calculado como:

$$SDWI = \ln_{10} * VV * VH - 8 \quad (1)$$

Onde VV e VH denotam os valores de pixel da imagem mediana VV e imagem mediana VH, respectivamente.

SAR Water Index (SWI)

O SWI (SAR Water index) é um índice útil para delimitação de corpos hídricos e monitoramento de secas, obtido pelas polarizações VH e VV do Sentinel-1. O SWI foi construído com base na equação de regressão linear entre os dados Sentinel-1 e MNDWI (O Índice da Diferença Normalizada da Água Modificada) do Sentinel-2 (Tian *et al.*, 2012). Simultaneamente, o SWI tem uma característica semelhante ao MNDWI, com base na Equação 2:

$$SWI = 0.1747 \times VV + 0.0082 \times VH \times VV + 0.0023 \times VV^2 - 0.0015 \times VH^2 + 0.1904 \quad (2)$$

Treinamento e Classificação por Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são uma forma de inteligência artificial que simula algumas funções do cérebro humano para associar as classes de Água e não Água corretas aos pixels da imagem, nesse caso, as imagens VH, VV, SWI e SDWI. A classificação baseada em RNA usa abordagem não paramétrica e, portanto, é acessível a incorporação de dados suplementares no processo de classificação para melhorar a precisão. Uma RNA consiste em uma série de camadas, cada uma contendo um conjunto de unidades de processamento

chamadas neurônios. Todos os neurônios em uma determinada camada são ligados por conexões ponderadas a todos os neurônios nas camadas anteriores e subsequentes. Durante a fase de treinamento, a RNA aprende sobre as regularidades presentes nos dados de treinamento e então constrói regras que podem ser estendidas aos dados desconhecidos (Giles *et al.*, 2021).

O conjunto de dados de treinamento foi usado para atualizar os parâmetros da rede durante cada ciclo (doravante referido como uma época), onde as saídas da rede são comparadas com os dados de treinamento e a perda é calculada com base em suas diferenças. Os parâmetros de rede foram ajustados para minimizar a erro. O número de épocas refere-se ao número de vezes que todo o conjunto de dados de treinamento é passado para frente e para trás através da rede neural. Cada época consiste em uma passagem direta, onde os dados de entrada são processados pela rede para obter previsões de saída, seguido de uma passagem reversa, onde os parâmetros da rede (pesos e vieses) são ajustados com base nos erros calculados (Salah, 2017).

O conjunto de validação testa a rede no final de cada época e é usado para variar os hiperparâmetros associados ao treinamento, como a taxa de aprendizado, bem como determinar quando a rede concluiu o treinamento (Hasan *et al.*, 2019). O conjunto de dados de teste foi usado posteriormente para avaliar a precisão da rede totalmente treinada, de modo que aproximadamente 70% dos dados foram usados para treinamento e 30% para validação. A rede foi treinada em trinta épocas de todo o conjunto de dados.

Dados de referência e análise de acurácia

A análise de acurácia do corpo d'água foi considerada por meio de uma grade de pixels com um tamanho de célula de referência de 3m em comparação com os 10 m dos dados Sentinel-1, o que permitiu uma avaliação da densidade do corpo d'água baseado em avaliações de precisão tradicionalmente realizadas através de uma matriz de confusão.

Baseado nos elementos da matriz de confusão, foi possível gerar quatro coeficientes de avaliação de acurácia temática e descrever a adequação entre as classes geradas e os dados de referência, entre eles os Erros de Omissão (EO) e Comissão (EC) e o Coeficiente Kappa. O EO é a relação entre o pixel pertencente a categoria *i* no mapa de referência, mas que foi categorizada como *j* no mapa classificado, enquanto o Erro de Comissão é quando a referência indica que o pixel pertence a categoria de não pertinência *j*,

mas no mapa foi classificado como pertinência i , respectivamente. O coeficiente Kappa trata-se de um método estatístico para avaliar o nível de concordância entre dois conjuntos de dados. A formulação matemática de cada estimativa pode ser encontrada em Nasir *et al.* (2023).

O mapa de referência adotado neste estudo foi um recorte de abrangência integral do corpo hídrico da barragem através de uma imagem PlanetScope R/G/B/NIR, com resolução espacial de 3 m, do mesmo mês da imagem Sentinel-1 utilizada. Essa imagem foi obtida em Planet (2023).

Os procedimentos de validação, bem como o uso de dados PlanetScope, estão de acordo com o protocolo internacional de “Procedimentos e Técnicas de Validação de Dados Geoespaciais” propostos por Balakrishnan (2019), que descrevem o conjunto de regras e melhores práticas para confirmar a qualidade dos dados geoespaciais que levam em consideração o Controle de qualidade visual, o Nível de critérios de aceitação de dados, a Precisão de posição, a Inconsistência, a Precisão temática e a Verificação de atributos.

Figura 2- Fotografias do entorno do corpo hídrico.



Fonte: Os autores (2023).

Para a análise do espaço geográfico, a relação entre a imagem visual do pesquisador em campo (escala local) e a imagem vertical da área de estudo (escala de paisagem) permite muitas vezes que seja definida a chamada “verdade terrestre”, de forma a validar uma classificação de cenas obtidas por sensores orbitais. Para tanto, a aferição das coordenadas geográficas na imagem da paisagem é fundamental. No entanto, é comum nesses casos realizar-se uma sequência de registros de imagens, obtidas por instrumentos GPS (Henke-Oliveira, 2022).

Visando integrar os dados obtidos em diferentes escalas e auxiliar na perspectiva de reconhecimento de padrões de forma visual, para a seleção de amostras de treinamento, foi realizada uma pesquisa de campo na área de estudo, nos dias 22/03 e 23/03. A análise de campo baseou-se em inspeção da dinâmica paisagista local, com registro de fotografias e obtenção de coordenadas usando o aplicativo GPS Tools. Os pontos amostrais com a informação categórica foram inseridos no processo de treinamento e classificação. Devido

a impossibilidade de locomoção e a segurança, áreas remotas e internas do corpo hídrico não foram contempladas, por outro lado, os pontos coletados possibilitaram descrever os sistemas naturais no entorno do corpo hídrico.

Regressão Linear por proporção de grade 0,5 km x 0,5km

As proporções de feições de água classificadas por RNA (VH, VV, SDWI e SWI) foram definidas separadamente em células de uma grade de 0,5 km x 0,5 km, bem como o produto de validação, para a comparação por regressão linear simples. O Coeficiente de Determinação da Regressão Linear (R^2) e os termos de inclinação e interceptação da regressão resumem a precisão e a exatidão das proporções classificadas como Água e Não Água, respectivamente (Boschetti *et al.* 2019). Se os erros de 3 m de omissão e comissão se compensarem nas células da grade de 10 m, então o R^2 e o coeficiente de inclinação serão próximos da unidade e a interceptação será próxima de zero, indicando alta precisão e

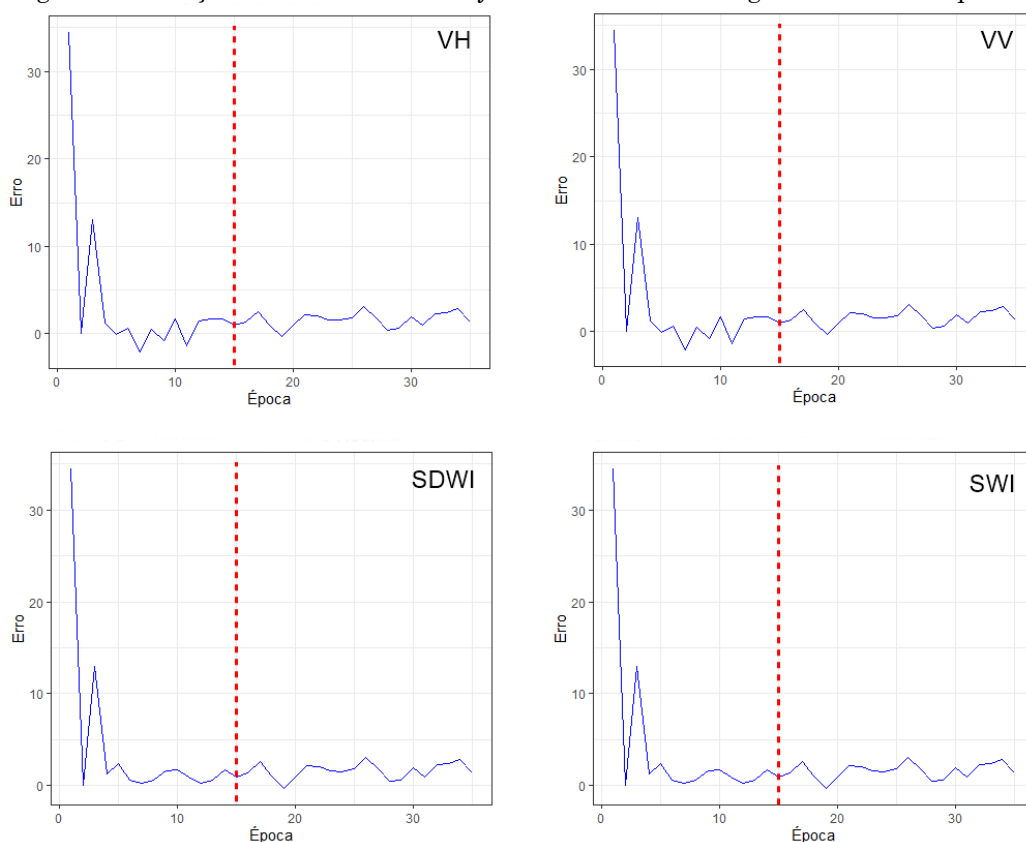
exatidão das feições de Água classificadas por proporções de área.

RESULTADOS

Análise de Treinamento RNA

A Figura 3 mostra a convergência do Erro em relação ao número de épocas para o conjunto de pixels amostrais VH, VV, SDWI e SWI. Como mostrado, os erros de treinamento são muito semelhantes entre si e convergiram para o valor mínimo e estável possível.

Figura 3 - Relação entre o Erro no conjunto de dados de imagens usando 30 épocas.



Fonte: Os autores (2023).

No geral, ajustar o número de épocas com base no desempenho da validação pode ajudar a evitar o *overfitting* e obter uma melhor generalização. Observa-se um comportamento semelhante no conjunto de dados, onde o maior erro é visto nas épocas iniciais do treinamento, com instabilidade nas 5^o e 10^o épocas do treinamento. Identificou-se também que o ponto em que a rede começa a se sobreajustar ou quando a precisão da validação se estabiliza, é quando o treinamento chega na 15^o época, com valores de erro abaixo de 5. Após a 15^o época houve uma estabilização sem variações significativas, portanto no processo de

classificação por RNA, uma quantidade de épocas igual a 15 foi utilizada nos quatro modelos de classificação.

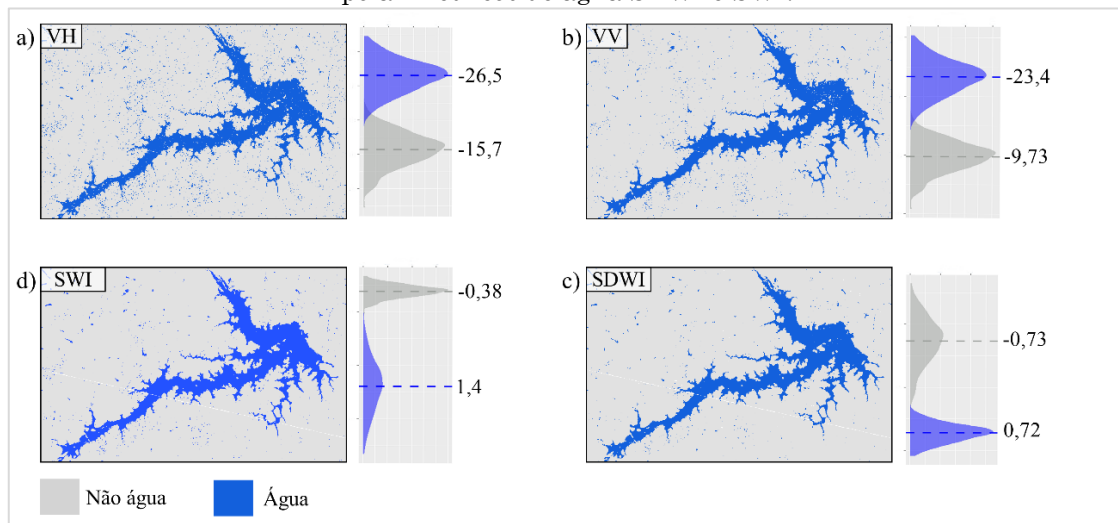
Desempenho de extração de corpo de água por fotointerpretação

O método de RNA pode determinar automaticamente o limiar de segmentação com base nos vetores de suporte e histograma da imagem, que é amplamente utilizado na extração de corpos d'água, em combinação de bandas unitárias SAR e índices de água (Guo *et al.* 2022). Nesta seção, foi comparado

visualmente o desempenho geral do método aplicado integralmente na área de estudo. Os

resultados da extração do corpo d'água usando o método de RNA são mostrados na Figura 4.

Figura 4 - Corpo hídricos obtido por RNA para as polarizações S1 VH, VV e os índices polarimétricos de água SDWI e SWI.



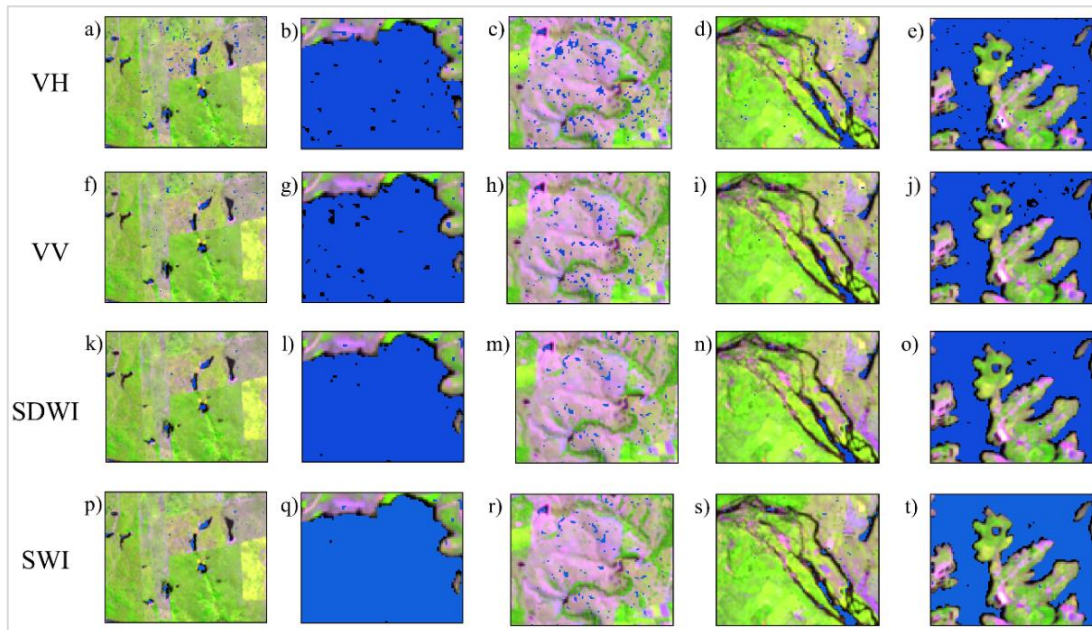
Fonte: Os autores (2023).

Percebe-se visualmente que a delimitações dos corpos hídricos não apresentaram variações significativas entre si, ou seja, todas mostraram integralmente a distribuição espacial do corpo hídrico da barragem. Apesar disso, os mapas apresentaram uma variação importante na detecção de pequenos lagos no entorno da barragem, com destaque para os mapas VH e VV, onde é visível a alta distribuição de pixels isolados de corpos hídricos em toda área de estudo. A vantagem do uso de índices espectrais SAR pode efetivamente resolver a deficiência de uma única imagem de polarização e distinguir as áreas aquáticas. Além disso, a detecção de recursos por meio do classificador RNA pode reduzir a interferência de dados inválidos

causada por ruídos, melhorando assim a eficiência da operação e a precisão da classificação.

O recurso de polarizações unitárias (VV e VH) não necessariamente melhora a precisão da classificação, porque alguns recursos podem ter correlação e redundância devido as características de dispersão semelhantes, acarretando numa alta distribuição de pixels isolados sem relação clara com corpos hídricos. A comparação visual da delimitação do espelho d'água da barragem por diferentes métodos na imagem SAR, seguiram com algumas peculiaridades mostradas na figura 5.

Figura 5 - Painéis de visualização local para os diferentes setores da Barragem de Carpina com base nos mapas de VH, VV, SDWI e SWI, por meio do apoio de uma cena Sentinel-2/ MSI de composição em falsa-cor R4G8B12.



Fonte: Os autores (2023).

O mapeamento de pequenos lagos no entorno da barragem, foi um limitador e fonte de erros na qualidade da detecção, como pode ser visto na figura 3, onde as polarizações VH e VV detectaram falsos positivos (ruídos) e alguns lagos não foram completamente detectados (Figura 3a, b, e e j). Já o SDWI e o SWI, apesar da menor presença de ruído, também não detectaram alguns corpos, além de apresentarem limitações na detecção nas bordas, deixando de classificar a maioria dos corpos hídricos (Figura 3k e p). Na massa d'água, localizada próximo a linha da barragem, o classificador mostrou uma peculiaridade na detecção. As polarizações VV e VH apresentaram alguns pixels sem presença de água nesse setor (Figura 3b e g), enquanto o SDWI trouxe uma distribuição menor dos pixels "Não água" dentro da massa d'água (Figura 3l). Comportamento semelhante ao SDWI também foi visto na composição SWI, por outro lado, a melhor detecção foi vista no SWI, mostrando um conjunto de pixels homogêneos e poucas falhas (Figura 3q).

Áreas de pastagens também foram alvos de pixels mal detectados nos quatro casos. As polarizações VV e VH foram as que mais detectaram erroneamente pixels de água em

feições de pastagens (Figura 3c e h). Já o SDWI e SWI mostraram um comportamento semelhante ao VV e VH, com algumas superestimações, enquanto com menor distribuição de pixels ruidosos nessas áreas (Figura m e r). Já nas figuras 3d, i, n e s é possível observar que nenhum dos conjuntos de dados foram capazes de detectar pixels de água em trechos estreitos e nas bordas do corpo hídrico, mostrando um recuo significativo, principalmente nas figuras 3e, j, o e t, provavelmente relacionado a pixels afetados por mistura espectral, com informações espectrais do solo e da água, onde não foram considerados pelo classificador como corpo d'água.

Análise por Erro de Comissão, Omissão e Coeficiente Kappa

Por meio do cálculo dos elementos da Matriz de Contingência binária gerado através das imagens classificadas por RNA e os dados *PlanetScope*, a Tabela 1 mostra os coeficientes de Erro de comissão e Omissão e o Kappa, na análise de acurácia da detecção dos corpos hídricos.

Tabela 1 - Erros de Omissão e Comissão, e Coeficiente Kappa para os diferentes conjuntos de dados S1.

	VH	VV	SDWI	SWI
EO (%)	3,5	2,9	2	1,47
EC (%)	28,9	20,3	16,5	19,3
Kappa	0,79	0,86	0,89	0,88

Fonte: Os autores (2023).

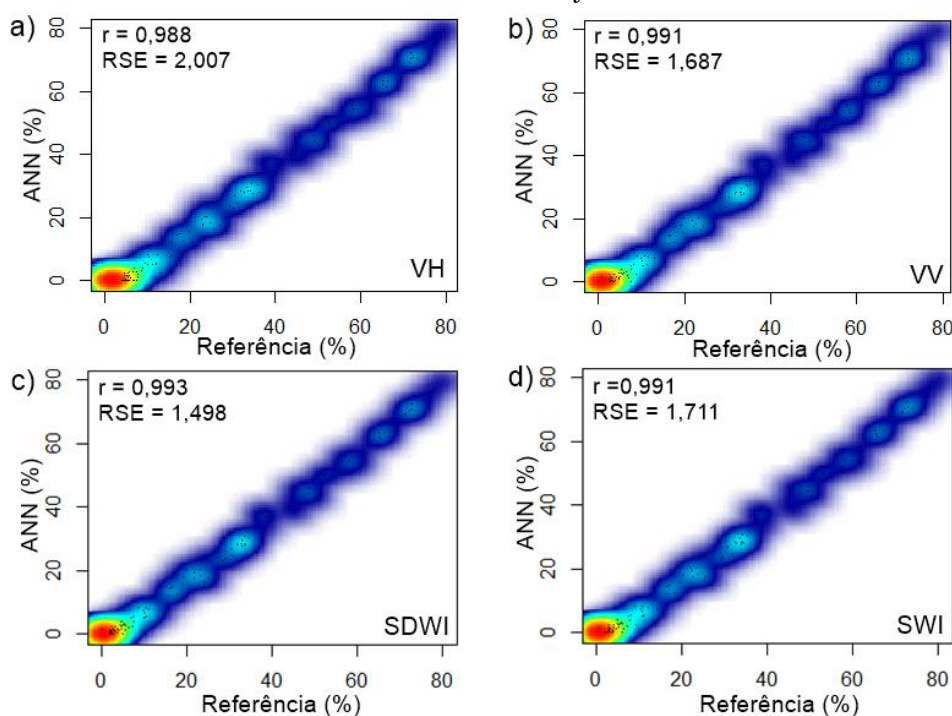
Todos os conjuntos de dados apresentaram baixo erro de omissão ($EO < 4$), onde o SWI apresentou melhor desempenho e as polarizações VH e VV tiveram as maiores estimativas de erro. O resultado obtido, mostrado pelo SWI, pode estar fortemente relacionado com a maior aderência espacial com o mapa de referência, chegando a 91%, enquanto o VH, VV e o SDWI foram de 81%, 84% e 89%, respectivamente. As polarizações VH e VV apresentaram as maiores estimativas de erro de comissão, ambas com superestimação de $0,28 \text{ km}^2$ e $0,23 \text{ km}^2$ enquanto o SDWI, que apresentou o menor erro de comissão, apresentou $0,16 \text{ km}^2$ de área sem a sua correta atribuição da classe “Não água”. O SWI apresentou uma moderada estimativa de EC, com valor próximo a polarização VV. Com base nos valores do coeficiente Kappa, o SDWI e o SWI mostraram melhor desempenho em relação as polarizações unitárias VH e VV, embora é importante observar que todos apresentaram altos valores de coeficiente Kappa

($Kp > 0,78$) e sem variações significativas ($0,79 \sim 0,89$).

Métricas de Regressão Linear em grade 0,5 km x 0,5 km

Para complementar as análises de comparação entre o produto RNA (VH, VV, SDWI e SWI) e o dado de referência *PlanetScope*, com base nas classes de “Água” e “Não Água”, a figura 6 mostra um gráfico de dispersão das proporções de células de grade pelo produto RNA contra as proporções de grade pelo produto de referência espacial. Células de grade com dimensões laterais de 0,5 km (500 m) foram consideradas, pois são maiores que a dimensão do pixel Sentinel-1 de 10 m, mas pequenas o suficiente para minimizar a ocorrência de células com proporções semelhantes a feições de Água em ambos os produtos.

Figura 6 - Gráficos de dispersão da proporção de área classificada como Água em células de uma grade de 0,5 x 0,5 km, conforme definido pela classificação RNA para cada conjunto de dados (y-eixo) e pelos dados de referência PlanetScope (eixo-x), compreendida integralmente na área de estudo. A escala de cores do arco-íris ilustra a frequência de células com os mesmos valores de proporção do eixo x e do eixo y.



Fonte: Os autores (2023).

Tanto os parâmetros de precisão quanto os índices SDWI e SWI, demonstraram um bom desempenho ao serem relacionados ao mapa de referência, exibindo uma relação linear significativa ($R^2 \sim 0,9$). As polarizações VH e VV também revelaram R^2 estimados elevados, com uma pequena discrepância entre si. Embora as polarizações VH e VV tenham apresentado um coeficiente angular ligeiramente maior, o SDWI revelou o menor coeficiente linear. O SWI, por sua vez, exibiu um coeficiente angular próximo a 1, sugerindo uma concordância mais expressiva com a imagem de referência. Enquanto VH e VV exibiram coeficientes lineares superiores a cerca de 0,014, o SWI também demonstrou essa estimativa similar. Em um contexto mais amplo, a análise de regressão revelou que todos os conjuntos de dados desempenharam um papel relevante na detecção de corpos hídricos. Isso se traduziu em um coeficiente de determinação (R^2) que ultrapassou 0,95, alcançado com um nível de confiança de 95%.

DISCUSSÃO

Em resumo, a arquitetura RNA provou ser um método poderoso e estável para a classificação binária da água, mas ainda existem alguns fatores que afetam sua precisão. Limitações na identificação de algumas classes como pastagens, podem ser uma deficiência na detecção, e a principal causadora de erros de comissão acima dos 10% para todos os conjuntos de dados, porém, um aumento do número de amostras e um novo ajuste de parâmetros RNA podem atenuar a distribuição de pixels ruidosos. As áreas de pastagem e corte raso possuem baixo retroespalhamento nos quatro tipos de polarizações existentes, bastante semelhante ao encontrado em corpos hídricos, uma vez que parte da energia do radar incidente é capaz de penetrar na superfície do solo, resultando em menor intensidade retroespalhada (Wang *et al.* 2013). Essa semelhança pode causar inconsistências na arquitetura RNA para separar essas áreas. A precisão da extração é em geral mais suscetível a ruídos com propriedades similares às da água, o que gera dificuldade em distingui-los nas imagens de polarização unitária SAR. Portanto, algumas das razões para um pequeno erro de comissão e omissão podem ser compreendidas.

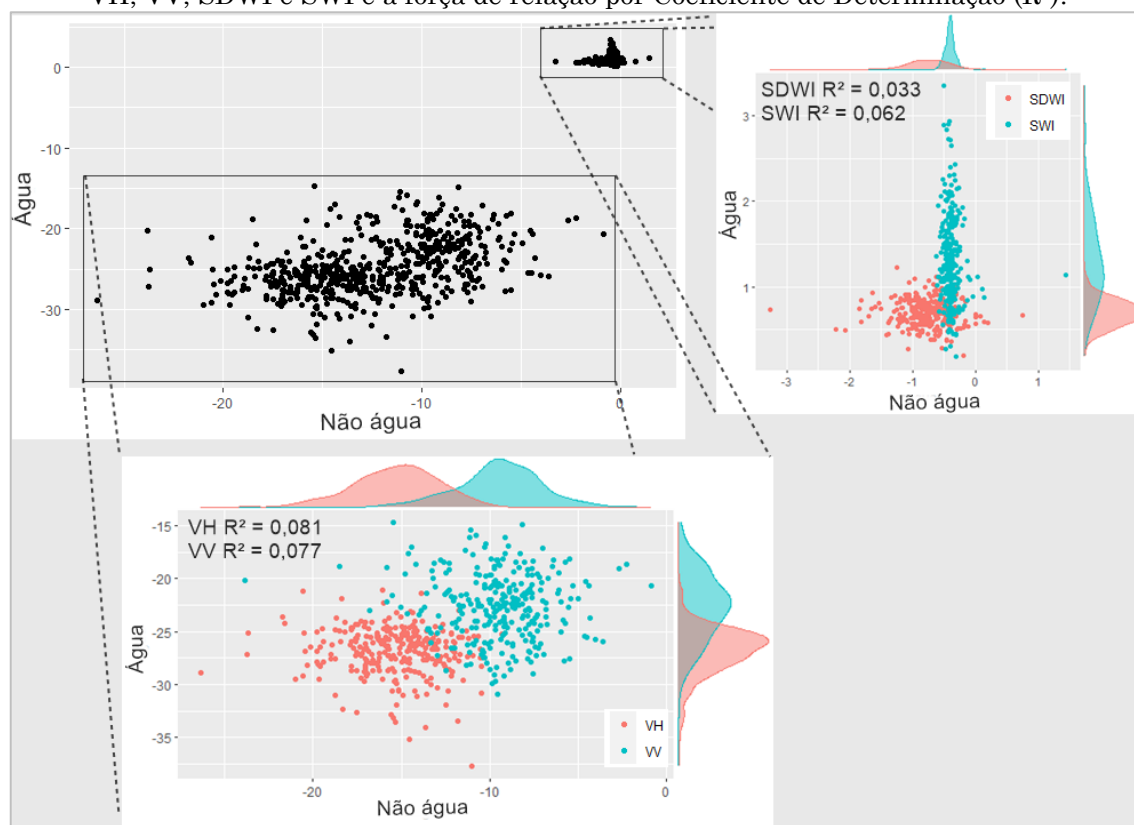
Apesar dos índices SDWI e SWI terem a capacidade de filtrar pixels superestimados, eles provocam alguns problemas. Depois que o índice

SDWI e SWI são empregados, apesar de ainda existirem falsas detecções, a extração de água é feita, porém inevitavelmente provoca a detecções perdidas, conforme mostrado nas Figuras 3 n e s. Os resultados mostraram que o conjunto de dados com base no SDWI e SWI tiveram a maior precisão e melhor resultado de extração de corpos d'água, quando comparado com as polarizações unitárias VH e VV. A principal razão é que os conjuntos SDWI e SWI para as classes de Água e Não Água possuem menor relação entre si, como pode ser visto nos menores valores de R^2 na figura 6. Diante disso, aumenta a capacidade de RNA de prever os elementos da água, bem diferente da classificação realizada por informações únicas das polarizações separadas.

No entanto, o método mostrou um resultado relativamente fragmentado na extração de pequenos corpos d'água, além da extração de rios estreitos que foi ruim, acarretando em erros de omissão importantes. De fato, para o monitoramento de grandes corpos d'água superficiais, pequenas lagoas, pequenos reservatórios e rios estreitos podem ser razoavelmente negligenciados devido à sua baixa importância, pois nos preocupamos principalmente com a análise de mudança das águas superficiais para a área de estudo como um todo. O fato dessas feições terem sido omitidas não é inesperado, uma vez que a classe de água, definida como um pixel com comportamento espectral misto de água e vegetação ou reflectância do solo, que por sua vez, não foi incluída pela classificação RNA. Pixels mal classificados também foram encontrados na massa d'água da barragem, principalmente nas polarizações VH e VV. A razão disso pode ter sido porque a superfície da água não é lisa e alguns pixels de retroespalhamento não apresentam as características do corpo d'água, causando confusões no classificador e afetando principalmente as polarizações originais. Nesse caso, nos índices SDWI e SWI, esses pixels de ruído no corpo d'água são atenuados. Apesar disso, o uso de imagens Sentinel-1, combinado com o RNA, mostrou ser importante para extração de corpos hídricos, com erros de omissão abaixo de 4%, e $R^2 > 0,9$, ou seja, grande parte dos espelhos d'água foram efetivamente detectados pelo conjunto de dados.

Por fim, os resultados da classificação para todos os métodos testados (Figura 2), sugerem que o método proposto pode capturar adequadamente a cobertura de água, observando que o efeito da extração de águas abertas e pequenas áreas de água pode ser um fator importante na qualidade da detecção.

Figura 7 - Ilustração Scatterplot de distribuição de pixels de “Água” e “Não água” para os conjuntos VH, VV, SDWI e SWI e a força de relação por Coeficiente de Determinação (R^2).



Fonte: Os autores (2023).

CONCLUSÕES

Em geral, podem ser mencionadas as seguintes conclusões:

(a) A classificação de corpos d'água usando imagens de polarização unitária S1 (VH e VH) pode causar superestimações, principalmente nos pixels de baixo retroespalhaento de alguns tipos de cobertura da terra, com erro de comissão variando entre 16 e 29%.

(b) O reconhecimento de corpos hídricos lineares e pequenos lagos ainda é um desafio, uma vez que as combinações de dados empregados neste estudo mostraram limitações na detecção dessas áreas, sendo capaz de gerar erros de omissão média de 2,5%.

(c) Os índices polarimétricos de água SDWI e SWI mostraram, no geral, o melhor desempenho na classificação, e menor correlação entre as classes “Água” e “Não Água”, proporcionando uma extração precisa, principalmente em locais de corpos hídricos e menor sensibilidade da mistura espectral encontrada na borda da barragem, mostrando um coeficiente Kappa entre 0,88 e 0,89.

(d) Os resultados obtidos a partir da exploração de dados Sentinel-1 indicam que a constelação Sentinel é uma ferramenta poderosa para mapear e monitorar grandes ecossistemas, complexos e sensíveis, como os reservatórios de água no Nordeste Brasileiro, permitindo uma frequência de revisitação muito alta. Apesar disso, o método não foi testado em locais de sombras, relevo acidentado, ruído speckle e diferentes ângulos de incidência, o que podem ser objetos de estudo para trabalhos futuros.

(e) O uso de Redes Neurais Artificiais (RNAs) para o treinamento e classificação, demonstrou eficiência na execução da tarefa de mapeamento de águas superficiais, minimizando o erro resultante do pré-processamento. Isso foi alcançado através da otimização do número de épocas empregado, evidenciando que o método não foi sensível à complexidade dos dados.

Por fim, o método aplicado neste estudo foi relativamente simples e pode atender aos requisitos de alta precisão, o que é de grande importância para a aplicação prática da gestão de recursos hídricos por meio de metodologias de processamento digital de imagens de radar.

REFERÊNCIAS

- BAO, L.; LV, X.; YAO, J. Water Extraction in SAR Images Using Features Analysis and Dual-Threshold Graph Cut Model. **Remote Sensing**, [S.l.], v. 13, n. 17, p. 3465, 2021. <http://dx.doi.org/10.3390/rs13173465>.
- BOSCHETTI, L.; ROY, D. P.; GIGLIO, L.; HUANG, H.; ZUBKOVA, M.; HUMBER, M. L. Global validation of the collection 6 MODIS burned area product. **Remote Sensing of Environment**, [S.l.], v. 235, p. 111490, 2019. <http://dx.doi.org/10.1016/j.rse.2019.111490>
- BALAKRISHNAN, M. **Geospatial Data Validation Procedure and Techniques**. **International Archive of Applied Sciences and Technology**, [S.l.], v. 10, n. 1, p. 148-153, 2019. https://soeagra.com/iaast/iast_march2019/25f.pdf
- COPERNICUS, **Data Space Ecosystem**. 2023. Disponível em: <https://dataspace.copernicus.eu/>. Acesso em: 10 nov. 2023.
- COSTA JÚNIOR, J. **Uso do modelo digital de elevação e do modelo digital de terreno para atualização dos dados de barragens e capacidade de armazenamento de reservatórios em Pernambuco**. 2022. Trabalho de Conclusão de Curso (Engenharia Civil) – Universidade Federal de Pernambuco, Caruaru, 2022.
- FILIPPONI, Federico. Sentinel-1 GRD Preprocessing Workflow. **3Rd International Electronic Conference On Remote Sensing**, [S.l.], p. 100-115, 2019. <http://dx.doi.org/10.3390/ecrs-3-06201>
- GILES, A. B.; DAVIES, J. E.; REN, K.; KELAHER, B. A deep learning algorithm to detect and classify sun glint from high-resolution aerial imagery over shallow marine environments. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 181, n. 7, p. 20–26, 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271621002367?via%3Dihub>. Acesso em: 10 de nov. de 2023.
- GUO, Z.; WU, L.; HUANG, Y.; GUO, Z.; ZHAO, J.; LI, N. Water-Body Segmentation for SAR Images: past, current, and future. **Remote Sensing**, [S.L.], v. 14, n. 7, p. 1752, 2022. <http://dx.doi.org/10.3390/rs14071752>
- HASAN, M.; ULLAH, S.; KHAN, M. J.; KHURSHID, K. Comparative analysis of SVM, ann and cnn for classifying vegetation species using hyperspectral thermal infrared data. The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**, v. XLII-2/W13, n. 1, p. 1861–1868, 2019. Disponível em: <https://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-2-W13/1861/2019/isprs-archives-XLII-2-W13-1861-2019.pdf>. Acesso em: 10 nov. 2023.
- HENKE-OLIVEIRA, C.; HIROO SAITO, C. A imagem da paisagem e a paisagem da imagem: o sistema de aquisição, processamento, hospedagem e integração de informações sobre recursos ambientais (SAPHIRA). **Revista Espaço e Geografia**, [S. l.], v. 15, n. 2, p. 385:405, 2022. Disponível em: <https://periodicos.unb.br/index.php/espacoegografia/article/view/39947>. Acesso em: 27 mar. 2023.
- LAMBERT, M. P. **Estudo dos indicadores de risco de inundação no município do Recife decorrente do rompimento hipotético da barragem de Carpina**. 2022. Trabalho de Conclusão de Curso (Engenharia Civil) - Universidade Federal de Pernambuco, Caruaru, 2021.
- LI, M.; HONG, L.; GUO, J.; ZHU, A. Automated Extraction of Lake Water Bodies in Complex Geographical Environments by Fusing Sentinel-1/2 Data. **Water**, [S.l.], v. 14, n. 1, p. 30, 2021. <http://dx.doi.org/10.3390/w14010030>
- MARTINEZ, J; LETOAN, T. Mapping of flood dynamics and spatial distribution of vegetation in the Amazon floodplain using multitemporal SAR data. **Remote Sensing of Environment**, [S.l.], v. 108, n. 3, p. 209-223, 2007. <http://dx.doi.org/10.1016/j.rse.2006.11.012>
- NASIR, N; KANSAL, A.; ALSHALTONE, O.; BARNEIH, F.; SHANABLEH, A.; AL-SHABI, M.; SHAMMAA, A. A. Deep learning detection of types of water-bodies using optical variables and ensembling. **Intelligent Systems with Applications**, [S.l.], v. 18, p. 200222, 2023. <http://dx.doi.org/10.1016/j.iswa.2023.200222>
- PLANET, Analytic Imagery and Archive. 2023. Disponível em: <https://www.planet.com/products/planet-imagery/>. Acesso em: 10 nov. 2023.
- PINHEIRO, M. M. F. **Aprendizagem profunda na segmentação semântica de rios em imagens de alta resolução espacial**. 2023. 102 f. Tese (Doutorado em Meio Ambiente e Desenvolvimento Regional) - Universidade do Oeste Paulista, Presidente Prudente, 2023.
- RAJENDIRAN, N.; KUMAR, L. S. Pixel Level Feature Extraction and Machine Learning Classification for Water Body Extraction. **Arabian Journal for Science and Engineering**, [S.l.], v. 48, n. 8, p. 9905-9928,

2022. <http://dx.doi.org/10.1007/s13369-022-07389-x>
- SALAH, M. A survey of modern classification techniques in remote sensing for improved image classification. **Journal of Geomatics**, v. 11, n. 1, 2017. Disponível em: <http://isgindia.org/wp-content/uploads/2017/04/016.pdf>. Acesso em: 27 mar. 2023.
- SON, N.-T.; CHEN, C.-F.; CHEN, C.-R.; TOSCANO, P.; CHENG, Y.-S.; GUO, H.-Y.; SYU, C.-H. A phenological object-based approach for rice crop classification using time-series Sentinel-1 Synthetic Aperture Radar (SAR) data in Taiwan. **International Journal of Remote Sensing**, [S.l.], v. 42, n. 7, p. 2722-2739, 2021. <http://dx.doi.org/10.1080/01431161.2020.1862440>
- TAMIRU, H.; DINKA, M. O. Application of ANN and HEC-RAS model for flood inundation mapping in lower Baro Akobo River Basin, Ethiopia. **Journal of Hydrology: Regional Studies**, [S.L.], v. 36, p. 100855, ago. 2021. <http://dx.doi.org/10.1016/j.ejrh.2021.100855>.
- TIAN, Y.; CHEN, X.; LUO, P.; XU, Y. Beijiang water body information extraction based on ENVISAT-ASAR. 2012 **Second International Workshop On Earth Observation and Remote Sensing Applications**, [S.l.], v. 5, n. 8, p. 100-115, jun. 2012. <http://dx.doi.org/10.1109/eorsa.2012.6261181>
- WANG, X.; GE, L.; LI, X. Pasture Monitoring Using SAR with COSMO-SkyMed, ENVISAT ASAR, and ALOS PALSAR in Otway, Australia. **Remote Sensing**, [S.l.], v. 5, n. 7, p. 3611-3636, 2013. <http://dx.doi.org/10.3390/rs5073611>.
- XIE, Y.; CHEN, R.; YU, M.; RUI, X.; DU, X. Improvement and application of UNet network for avoiding the effect of urban dense high-rise buildings and other feature shadows on water body extraction. **International Journal of Remote Sensing**, [S.l.], v. 44, n. 12, p. 3861-3891, 2023. <http://dx.doi.org/10.1080/01431161.2023.2229498>.
- ZHANG, Z.; ZHANG, X.; JIANG, X.; XIN, Q.; AO, Z.; ZUO, Q.; CHEN, L. Automated Surface Water Extraction Combining Sentinel-2 Imagery and OpenStreetMap Using Presence and Background Learning (PBL) Algorithm. **Ieee Journal of Selected Topics in Applied Earth Observations And Remote Sensing**, [S.l.], v. 12, n. 10, p. 3784-3798, 2019. <http://dx.doi.org/10.1109/jstars.2019.2936406>

CONTRIBUIÇÃO DOS AUTORES

Juarez Antônio da Silva Júnior conceituou o trabalho, realizou a metodologia, analisou o software, validou os dados, redigiu e preparou o rascunho original. Ubiratan Joaquim da Silva Junior realizou a análise formal, visualizou e realizou a curadoria de dados. Os dois autores investigaram, redigiram, revisaram e editaram o texto. Além disso, os autores supervisionaram e administraram o projeto. Todos os autores leram e concordaram com a versão publicada do manuscrito.



Este é um artigo de acesso aberto distribuído nos termos da Licença de Atribuição Creative Commons, que permite o uso irrestrito, distribuição e reprodução em qualquer meio, desde que o trabalho original seja devidamente citado.