



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIAS E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

JUAREZ ANTÔNIO DA SILVA JÚNIOR

**DETECÇÃO DE CORPOS HÍDRICOS UTILIZANDO IMAGENS SAR SENTINEL-1
COM ÍNDICE SEWI E TÉCNICAS DE CLASSIFICAÇÃO**

Recife - PE

2025

JUAREZ ANTÔNIO DA SILVA JÚNIOR

**DETECÇÃO DE CORPOS HÍDRICOS UTILIZANDO IMAGENS SAR SENTINEL-1
COM ÍNDICE SEWI E TÉCNICAS DE CLASSIFICAÇÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia Civil com ênfase em Recursos Hídricos.

Orientadora: Prof.^a Dr.^a Leijdane Maria Maciel de Oliveira

Recife

2025

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Silva Junior, Juarez Antonio da.

Detecção de corpos hídricos utilizando imagens SAR Sentinel-1 com índice SEWI e técnicas de classificação / Juarez Antonio da Silva Junior. - Recife, 2025.

87 f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Civil, 2025.

Orientação: Leidjane Maria Maciel de Oliveira.

Inclui referências.

1. Random Forest; 2. Sensoriamento remoto; 3. Água. I. Oliveira, Leidjane Maria Maciel de. II. Título.

UFPE-Biblioteca Central

AGRADECIMENTOS

Agradeço ao órgão Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo fomento da pesquisa e pelo apoio e orientação da Professora Leidjane Oliveira e minha família e amigos.

RESUMO

O monitoramento de corpos hídricos é fundamental para a gestão sustentável dos recursos naturais, especialmente frente às mudanças climáticas e pressões antrópicas. Essa pesquisa tem como objetivo avaliar a eficácia de classificadores supervisionados e não supervisionados na extração de corpos d'água, utilizando imagens do sensor Sentinel-1 e o índice espectral proposto SAR *Enhanced Water Index* (SEWI). A pesquisa está estruturada em dois artigos científicos. O primeiro artigo foca na aplicação do SEWI em conjunto com seis classificadores não supervisionados: CLARA, K-means, SOM, Autoencoder, HDBSCAN e Expectativa-Maximização. Os resultados demonstraram que os classificadores Autoencoder e CLARA alcançaram os melhores desempenhos, com coeficientes de Dice médios de 0,81 e altos valores de recall (0,90 e 0,89, respectivamente). De forma geral, todos os métodos obtiveram acurácia global superior a 95%, evidenciando a eficiência do índice SEWI aliado a métodos de classificação autônoma para detectar corpos d'água. O segundo artigo investiga o uso de classificadores supervisionados — Random Forest (RF), Redes Neurais Artificiais (ANN), também utilizando o índice SEWI como variável de entrada. Os experimentos mostraram que RF e ANN apresentaram os melhores desempenhos médios, com acurácia global acima de 97% e coeficientes de Dice superiores a 0,85 na maioria das regiões avaliadas. A ANN, embora eficaz, apresentou menor consistência em áreas com ruído ou baixa resolução espectral. A integração do SEWI com métodos supervisionados demonstrou maior robustez na definição de contornos e na redução de erros de omissão e comissão, superando os classificadores não supervisionados em cenários mais complexos. Os resultados desta pesquisa indicaram que o SEWI é um índice robusto para a detecção de corpos d'água em imagens SAR, e que tanto métodos supervisionados quanto não supervisionados podem ser eficazes, a depender do contexto geográfico e da necessidade operacional, sendo recomendados para aplicações de monitoramento de recursos hídricos em larga escala.

Palavras-chave: SAR; corpos d'água, aprendizado de máquina; classificação não supervisionada; classificação supervisionada.

ABSTRACT

Water monitoring is essential for the sustainable management of natural resources, especially in the face of climate change and anthropogenic pressures. This dissertation aims to evaluate the effectiveness of supervised and unsupervised classifiers in extracting water bodies, using images from the Sentinel-1 sensor and the proposed spectral index SAR Enhanced Water Index (SEWI). The research is structured in two scientific articles. The first article focuses on the application of SEWI in conjunction with six unsupervised classifiers: CLARA, K-means, SOM, Autoencoder, HDBSCAN and Expectation-Maximization. The results demonstrated that the Autoencoder and CLARA classifiers achieved the best performances, with average Dice coefficients of 0.81 and high recall values (0.90 and 0.89, respectively). In general, all methods achieved global accuracy above 95%, demonstrating the efficiency of the SEWI index combined with autonomous classification methods to detect water bodies. The second article investigates the use of supervised classifiers — Random Forest (RF) and Artificial Neural Networks (ANN), also using the SEWI index as an input variable. The experiments showed that RF and ANN presented the best average performances, with global accuracy above 97% and Dice coefficients above 0.85 in most of the regions evaluated. The ANN, although effective, showed lower consistency in areas with noise or low spectral resolution. The integration of SEWI with supervised methods demonstrated greater robustness in defining contours and reducing omission and commission errors, outperforming unsupervised classifiers in more complex scenarios. The results of this dissertation indicate that SEWI is a robust index for detecting water bodies in SAR images, and that both supervised and unsupervised methods can be effective, depending on the geographic context and the operational need being recommended for large-scale water resource monitoring applications.

Keywords: SAR; water bodies, machine learning; unsupervised classification; supervised classification.

LISTA DE FIGURAS

Figura 1 –	Fluxograma da metodologia	1
------------	---------------------------	---

ARTIGO 1 – AVALIAÇÃO DA PRECISÃO DE CLASSIFICADORES NÃO SUPERVISIONADOS PARA EXTRAÇÃO DE ÁGUA UTILIZANDO O ÍNDICE SAR ENHANCED WATER INDEX (SEWI)

Figura 1 –	Locais referentes aos corpos hídricos utilizados neste estudo.	21
Figura 2 –	Locais referentes aos corpos hídricos utilizados neste estudo.	21
Figura 3 –	Distribuição de densidade do comportamento dos valores de retroespalhamento da polarização VV, VH e os valores do índice SEWI.	24
Figura 4 –	Ilustração simples dos principais tipos de modelos de agrupamento.	25
Figura 5 –	Extração de água obtidos pelo SEWI categorizados pelos classificadores não supervisionados.	31
Figura 6 –	Área do espelho d'água detectados pelos classificadores sendo comparados com a área obtida pela referência (linha tracejada).	32
Figura 7 –	Estimativas de Erro de Omissão (EO) e Erro de Comissão (EC).	35
Figura 8 –	Gráficos scatterplot das proporções de células rotuladas como água pelos classificadores plotados em relação à proporção rotulada como água pelo conjunto de dados de referência.	39

ARTIGO 2 – ANÁLISE DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS SAR PARA EXTRAÇÃO DE ÁGUA EM DIFERENTES CORPOS HÍDRICOS DO BRASIL

Figura 1 –	Área de estudo	54
------------	----------------	----

Figura 2 –	Figura 2 – Distribuição espacial do índice SEWI, CPI e GLCM para cada área de estudo.	63
Figura 3 –	Estimativas de Separabilidade JM	65
Figura 4 –	Gráfico de desempenho do modelo ANN mostrando a tendência de precisão de aprendizagem para dois conjuntos de dados (treinamento e teste).	66
Figura 5 –	Análise de acurácia do treinamento ANN em relação ao número de épocas	67
Figura 6 –	Corpos hídricos detectados pela combinação de métodos para cada área de estudo.	68
Figura 7 –	Áreas em Km ² dos corpos hídricos detectados pelos produtos. A linha tracejada em preto é o a área obtida pela referência.	69
Figura 8 –	Gráfico de barras representando as estimativas de Erro de omissão e comissão para cada área de estudo em relação aos produtos.	72
Figura 9 –	Barplot circular para as estimativas de coeficiente Dice para cada produto.	74
Figura 10 –	Barplot circular para as estimativas as estimativas de Recall para cada produto.	76
Figura 11 -	Gráficos de dispersão das proporções de células rotuladas como “Água” pelos produtos classificados plotados em relação à proporção rotulada como “Água” pelo conjunto de dados de referência.	79

LISTA DE TABELAS

ARTIGO 1 – AVALIAÇÃO DA PRECISÃO DE CLASSIFICADORES NÃO SUPERVISIONADOS PARA EXTRAÇÃO DE ÁGUA UTILIZANDO O INDICE SAR ENHANCED WATER INDEX (SEWI)

Tabela 1 –	Tabela de Contingência	30
Tabela 2 –	Coefficiente Dice-Sørensen para os diferentes classificadores.	35
Tabela 3 –	Coefficiente Recall para os diferentes classificadores.	36
Tabela 4 –	Estimativas de Acurácia Global (%)	42

ARTIGO 2 – ANÁLISE DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS SAR PARA EXTRAÇÃO DE ÁGUA EM DIFERENTES CORPOS HÍDRICOS DO BRASIL

Tabela 1 –	Estimativas de Acurácia Global (%)	77
------------	------------------------------------	----

ABREVIATURAS

SAR	<i>Synthetic Aperture Radar</i>
S1	Sentinel-1
GRD	<i>Ground Range Detected</i>
DEMs	<i>Digital Elevation Models</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
MNDWI	<i>Modified Normalized Difference Water Index</i>
SDWI	<i>Sentinel-1 Dual-Polarization Water Index</i>
SEWI	<i>Sentinel-1 Enhanced Water Index</i>
VV	Vertical-Vertical
VH	Vertical-Horizontal
SOWI	<i>SAR Optimized Water Index</i>
ANN	<i>Artificial Neural Network</i>
SVM	<i>Support Vector Machine</i>
CNN	<i>Convolutional Neural Network</i>
MLP	<i>Multilayer Perceptron</i>
RF	<i>Random Forest</i>
EM	<i>Expectation-Maximization</i>
IoU	<i>Intersection over Union</i>
RMSE	<i>Root Mean Square Error</i>
JM	<i>Jeffries-Matusita Distance</i>

PC1	Primeira Componente Principal
GLCM	<i>Gray-Level Co-occurrence Matrix</i>
KM	<i>K-Means</i>
ISODATA	<i>Iterative Self-Organizing Data Analysis Technique</i>
HDBSCAN	<i>Hierarchical Density-Based Spatial Clustering</i>
PAM	<i>Partitioning Around Medoids</i>
ODS	Objetivos de Desenvolvimento Sustentável (ONU)
CSD	Coeficiente de Sørensen-Dice
EO	Erro de Omissão
EC	Erro de Comissão
AG	Acurácia Global
C	Covariância

SUMÁRIO

1	INTRODUÇÃO	14
2	ARTIGO 1 – AVALIAÇÃO DA PRECISÃO DE CLASSIFICADORES NÃO SUPERVISIONADOS PARA EXTRAÇÃO DE ÁGUA UTILIZANDO O INDICE SAR ENHANCED WATER INDEX (SEWI)	17
2.1	INTRODUÇÃO	17
2.2	METODOLOGIA	21
2.2.1	Área de estudo	21
2.2.2	Dados Sentinel-1	22
2.2.3	Índice de água SAR aprimorado - Enhanced SAR Water Index (SEWI)	22
2.2.4	Classificadores não supervisionados	25
2.2.4.1	CLARA	26
2.2.4.2	K-médias	26
2.2.4.3	Endecoder	27
2.2.4.4	Expectativa-Maximização (EM)	27
2.2.4.5	SOM	28
2.2.4.6	HDBSCAN	28
2.2.5	Avaliação da acurácia	29
2.2.6	Coeficientes de precisão	29
2.2.7	Grade de regressão	30
3	RESULTADOS E DISCUSSÃO	31
4	CONSIDERAÇÕES FINAIS	44
5	REFERÊNCIAS	45
1	ARTIGO 2 – ANÁLISE DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS SAR PARA EXTRAÇÃO DE ÁGUA EM DIFERENTES CORPOS HÍDRICOS DO BRASIL	50
2	RESUMO	50
3	INTRODUÇÃO	50
4	METODOLOGIA	53
4.1	ÁREA DE ESTUDO	54

4.2	Dados	54
4.3	Dados SAR do Sentinel-1	54
4.4	Índice de água SAR aprimorado - Enhanced SAR Water Index (SEWI)	55
4.5	Métodos e Classificadores Supervisionados	55
4.5.1	Características do GLCM	56
4.5.2	Análise de Componentes Principais	58
4.6	Análise de Separabilidade	60
4.7	Classificadores Supervisionados	60
4.7.1	Random Forest (RF)	60
4.7.2	Artificial Neural Net (ANN)	61
4.8	Avaliação da acurácia	62
4.9	Mapbiomas Beta	62
5	RESULTADOS E DISCUSSÃO	63
5.1	Análise de separabilidade	64
5.2	Análise de treinamento	65
6	Considerações Finais	65
7	Referências	87

1 INTRODUÇÃO

Os recursos hídricos são ativos inestimáveis em nosso planeta, pois desempenham um papel vital na facilitação do crescimento sustentável tanto para as sociedades humanas quanto para os ecossistemas. O monitoramento do ambiente hídrico é de suma importância para o gerenciamento eficaz dos recursos hídricos, prevenção de desastres naturais e manutenção do equilíbrio ecológico (Song, Wang e Qian, 2025). A tecnologia de radar de abertura sintética (SAR) oferece recursos de observação em todas as condições climáticas e durante todo o dia, amplamente aplicados no monitoramento de águas superficiais, extração de litoral e avaliação de desastres de inundação. A nova geração de satélites SAR pode adquirir imagens em multiângulo e multipolarização, o que enriquece muito o conteúdo de informações e aumenta as dimensões dos recursos em comparação com dados de polarização única. Portanto, espera-se que a utilização eficaz desses recursos melhore a eficácia da análise e das aplicações de dados (Song, Wang e Qian, 2025; Zhang et al. 2025).

Técnicas baseadas em álgebra matricial para a geração de índices espectrais voltadas para imagens de radar foram desenvolvidas para alavancar informações de polarização dupla, como por exemplo o Índice de Água SAR e Óptico (SOWI), *Radar Vegetation Index* (RVI) e o *Radar Forest Degradation Index* (RFDI). Nesse sentido, os índices espectrais combinados com classificadores de segmentação são simples de implementar e melhoram a robustez e o reconhecimento dos alvos terrestres para o mapeamento, maximizando a preservação das informações da imagem original e o aprimoramento de detalhes sutis (Guo et al. 2022; Zhang et al. 2025; Yuan et al. 2023; Wang et al. 2024).

Recentemente, o uso de aprendizado profundo em métodos de fusão em nível de pixel atraiu interesse crescente. Métodos de aprendizado profundo têm a capacidade de extrair automaticamente uma ampla gama de recursos e lidar efetivamente com relacionamentos não lineares complexos em comparação com métodos tradicionais. Um módulo de fusão de recursos de polarização dupla adaptável baseado na convolução (1×1) pode efetivamente aumentar a precisão de reconhecimento de alvos minúsculos (Shen et al. 2022; Zhang et al. 2025; Yuan et al. 2023). Ao integrar detalhes de contextos espaciais e espectrais e blocos de agregação de atenção conjunta, uma rede de fusão de ramificação dupla foi proposta para produzir detalhes mais finos em nível de pixel. Com o desenvolvimento da fusão de recursos de imagens SAR, os métodos de aprendizado profundo fornecem mais potenciais técnicos. Como diferentes modelos de polarização exibem características de espalhamento distintas, continua sendo um

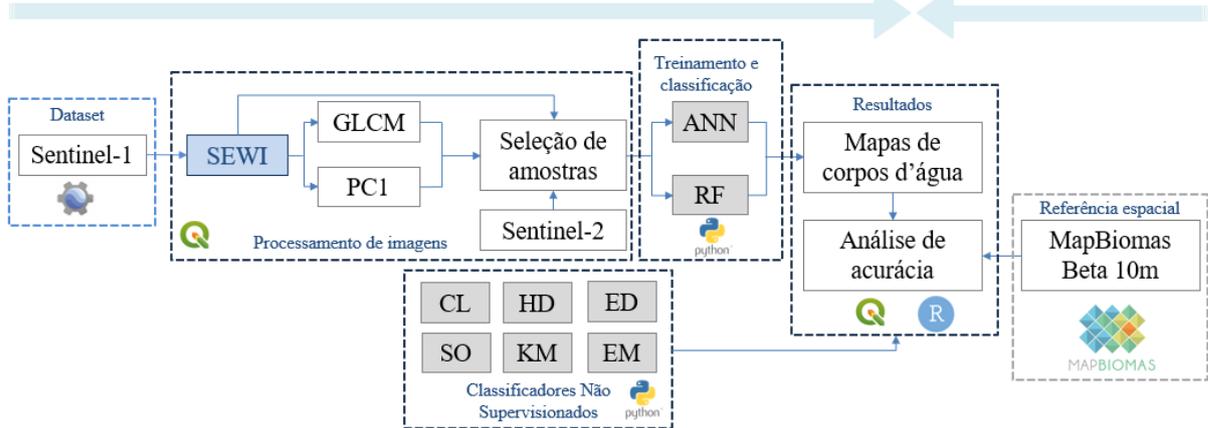
desafio desenvolver um método que possa aproveitar totalmente os recursos profundos de imagens SAR de multipolarização (Song, Wang e Qian, 2025).

Beneficiando-se das robustas capacidades de aprendizado, técnicas de aprendizado de máquina têm sido amplamente aplicadas à tarefa de extração de corpos d'água em imagens SAR. Entre essas técnicas, as Redes Neurais Artificiais (ANN) têm se destacado devido à sua capacidade de modelar relações não lineares complexas entre as características extraídas das imagens. As ANN's podem capturar padrões tanto simples quanto complexos, desde informações superficiais até relações mais abstratas, por meio de suas múltiplas camadas densamente conectadas (Song, Wang e Qian, 2025; Guo et al. 2022). Além disso, o algoritmo de Random Forest (RF) também tem sido amplamente utilizado nessa tarefa, graças à sua robustez, facilidade de interpretação e alta capacidade de generalização. O RF é eficiente na seleção de características relevantes e na mitigação de ruídos presentes nas imagens SAR, oferecendo bom desempenho na classificação de pixels em categorias como água e não-água, mesmo em cenários com fundos heterogêneos (Wang et al. 2024).

Apesar das ANN possuírem grande capacidade de modelagem, sua eficácia pode ser limitada quando se trata de capturar relações espaciais globais intrínsecas às imagens SAR, uma vez que não possuem mecanismos nativos para interpretar relações espaciais como fazem modelos baseados em convoluções ou atenção. Por outro lado, o Random Forest, ao operar com conjuntos de árvores de decisão, também enfrenta desafios em contextos que exigem uma modelagem mais profunda de dependências espaciais de longo alcance (Yuan et al. 2023; Wang et al. 2024). Para mitigar essas limitações, abordagens híbridas vêm sendo exploradas, combinando ANN com técnicas baseadas em extração de atributos manuais ou métodos estatísticos para enriquecer a representação dos dados. De forma semelhante, a integração de RF com técnicas de pré-processamento de atributos espaciais e texturais tem se mostrado eficaz, especialmente na melhoria da definição dos contornos de corpos d'água e na redução de erros em regiões com padrões espectrais semelhantes.

A Figura 1 mostra o fluxograma geral da pesquisa. O Sentinel-1 foi utilizado como fonte inicial de dados. Após a obtenção das imagens no Google Earth Engine, aplicou-se o índice SEWI, juntamente com a extração de características por meio da GLCM (Gray Level Co-occurrence Matrix) e do PC1 (Primeiro Componente Principal). Em seguida, realizou-se a seleção de amostras utilizando dados do Sentinel-2. Posteriormente, foi feita a classificação supervisionada com os algoritmos ANN (Rede Neural Artificial) e RF (Random Forest), além da aplicação de classificadores não supervisionados: CLARA (CL), HDBSCAN (HD), Encoder (ED), SOM (SO), K-médias (KM) e Expectation-Maximization (EM), todos executados em ambiente Python – Jupyter Notebook.

Figura 1 – Locais referentes aos corpos hídricos utilizados neste estudo.



Fonte: Autor (2025).

Por fim, foram produzidos os mapas de corpos d'água e realizada a análise de acurácia com o uso de ferramentas como QGIS e R, tendo como base de referência para validação os dados da plataforma MapBiomas Beta 10 m.

2 ARTIGO 1 – AVALIAÇÃO DA PRECISÃO DE CLASSIFICADORES NÃO SUPERVISIONADOS PARA EXTRAÇÃO DE ÁGUA UTILIZANDO O ÍNDICE SAR ENHANCED WATER INDEX (SEWI)

RESUMO

As técnicas de aprendizado de máquina e Sensoriamento Remoto têm avançado significativamente na detecção e monitoramento de superfícies aquáticas. Um dos principais marcos nesse progresso é a utilização do Radar de Abertura Sintética (SAR), cuja radiação retroespalhada e emitida tem a capacidade de penetrar na atmosfera em quaisquer condições climáticas, sendo, portanto, um elemento de particular relevância nesse contexto. Entre os métodos mais eficientes e precisos para a extração de corpos d'água, destacam-se os índices espectrais, que, ao serem combinados com classificadores não supervisionados, tornam-se ainda mais eficazes por meio da automação do processo. Com base na análise das características espectrais do satélite Sentinel-1, foi desenvolvido um novo índice denominado *SAR Enhanced Water Index* (SEWI). Esse índice foi aplicado em conjunto com cinco algoritmos de classificação não supervisionada — CLARA (*Clustering Large Applications*), K-means, SOM (*Self-Organizing Map*), Autoencoder, HDBSCAN (*Hierarchical Density-Based Spatial Clustering of Applications with Noise*) e Expectativa-Maximização (EM) — para detectar corpos d'água em nove áreas distintas do Brasil. A avaliação dos resultados foi realizada por meio de fotointerpretação, análise espacial e cálculo de métricas de acurácia temática, utilizando dados do MapBiomas como referência. Em geral, todos os algoritmos conseguiram segmentar consistentemente os pixels de água, com variações de área pouco expressivas na maioria dos corpos hídricos. Os algoritmos Autoencoder e CLARA obtiveram os maiores valores de Recall médio, com 0,90 e 0,89 respectivamente, e ambos alcançaram um coeficiente de Dice médio de 0,81. Em contrapartida, a Barragem de Tapacurá apresentou superestimativas relevantes em todos os métodos. Já os algoritmos HDBSCAN e SOM apresentaram as menores estimativas em todas as métricas, destacando-se pela acurácia global média de 96,59% e 95,51%, respectivamente, enquanto os demais algoritmos superaram os 97%. Apesar dessas variações pontuais, todos os algoritmos apresentaram acurácia global superior a 95%. A aplicação do índice SEWI em conjunto com classificadores não supervisionados mostrou-se eficaz e precisa na extração de corpos d'água, revelando elevado potencial para uso em sistemas automatizados voltados ao monitoramento espacial de águas superficiais em larga escala e de periodicidade semanal contribuindo para a gestão de recursos hídricos.

2 INTRODUÇÃO

Corpos de água superficiais, como lagos, rios, reservatórios e lagoas, são recursos finitos e vulneráveis, que desempenham um papel importante nas respostas climáticas, mantendo sistemas ecológicos e apoiando o desenvolvimento humano sustentável. Afetados pelas mudanças climáticas e pela atividade humana, a escassez e a poluição da água, a seca extrema e as inundações são mais frequentes em diferentes partes do mundo. Alcançar a gestão das águas superficiais e abordar a atual crise hídrica é o objetivo do Objetivo de Desenvolvimento Sustentável (ODS) 6 (gestão global sustentável dos recursos hídricos até 2030). A detecção precisa e rápida das águas superficiais, capturando a extensão e a dinâmica do corpo d'água, é a base para atingir os ODS (Du et al. 2023; Peixoto; Soares e Ribeiro, 2022).

Nesse contexto, o monitoramento da dinâmica do nível da água requer a compreensão dos processos hidrológicos e o gerenciamento dos recursos hídricos em que diferentes técnicas de detecção remota são usadas nessa abordagem. Muitas técnicas de detecção de águas superficiais foram desenvolvidas com base em imagens Radar de Abertura Sintética (SAR), separadas em duas categorias principais sendo o método de índice espectral e classificação de imagens. Com o avanço contínuo da tecnologia de satélites, dados em nuvem e equipamentos de radar relacionados, a obtenção de imagens SAR está se tornando cada vez mais rápida e conveniente (Guo et al. 2022; Nicollier, Kiperstok e Bernardes, 2023).

Os dados de radar de abertura sintética (SAR) são obtidos por sensores ativos que operam em comprimentos de onda maiores, capazes de penetrar nuvens e, em diferentes graus, a vegetação, independentemente das condições climáticas. Dessa forma, é possível obter informações sobre alvos terrestres ao longo de todo o dia. Corpos d'água apresentam constante dielétrica elevada e superfície geralmente lisa; assim, como a retroespalhamento ocorre predominantemente de forma especular, o coeficiente de retrodispersão desses corpos em imagens SAR tende a ser baixo (Chen e Zhao, 2022). A refletividade da superfície registrada pelo radar, conhecida como coeficiente de retrodispersão (σ^0), depende tanto dos parâmetros do sistema de radar (frequência, polarização, ângulo de incidência) quanto das características da superfície (topografia, rugosidade, propriedades dielétricas, teor de umidade, entre outros). Entretanto, como as imagens SAR são adquiridas em visão lateral, áreas com grande variação de relevo podem gerar sombras de radar, reduzindo a precisão na detecção de corpos d'água (Kseňak et al., 2022; Lyu et al., 2023). Além disso, em condições de vento, a formação de ondas na superfície aquática aumenta o coeficiente de retrodispersão, o que pode levar à omissão de áreas de água durante a extração. Outro fator relevante é a presença de florações de

algas: esses organismos liberam biossurfactantes que diminuem a retrodispersão das ondas de radar. Como essa resposta é semelhante à da própria água, não interfere no processo de extração (Shen et al., 2022).

Ainda outra relevância, a rugosidade da superfície da vegetação emergente é relativamente grande; portanto, pode produzir uma alta dispersão de volume, resultando na perda da extração de água sob essa vegetação. Resumidamente, o desempenho da detecção de corpos d'água em imagens SAR é facilmente afetado por regiões terrestres complexas, devido ao compartilhamento de características de diferentes continuidades e baixa intensidade de espalhamento com áreas aquáticas (Che, Li e Liu, 2025). Devido a essa interferência complexa, a detecção robusta e automática de corpos d'água em imagens SAR ainda requer mais estudos e testes.

Por meio de imagem SAR, vários métodos para extração de corpos d'água foram desenvolvidos, incluindo a divisão de bandas de densidade, classificação supervisionada e não supervisionada, cálculo de índices espectrais de água e outros métodos de extração. Com base nos estudos de Tian et al. (2022) e Han, Jia e Sun (2022) é possível constatar que o método de extração baseado no cálculo do índice espectral de água é uma ferramenta confiável, eficaz e ótima para mapear corpos d'água e suas mudanças, embora desafiador, devido ao número de polarizações disponibilizadas e a alta frequência de ruído. A transformação do índice de água através de operações algébricas nas imagens de polarizações, realça as diferenças espectrais entre as feições terrestres e água, em que normalmente os pixels de água, apresenta pixels com valores mais elevados e conseqüentemente mais claros em relação as feições terrestres.

Tian et al. (2022) utilizaram imagens Sentinel-1 e Sentinel-2 para detectar conteúdo de água em lagos da china através da implementação do Índice de Água por Imagem Óptica e SAR (SOWI). Basicamente, o SOWI utiliza os princípios do índice de água de imagem óptica e do método de limiarização de imagem SAR para extrair a distribuição de corpo d'água; fundindo NDWI, MNDWI e outros índices de corpo d'água com bandas de polarização de imagem SAR para realizar cálculos (Chen e Zhao, 2022). Os Autores encontraram uma precisão média do produtor dos resultados de extração de água nas cinco áreas foi de 89%, a precisão média do usuário foi de 98%, a precisão média geral foi de 97% e o coeficiente Kappa médio foi de 91%, todos os quais foram melhores do que os métodos de extração baseados em imagem SAR ou imagem óptica.

Inspirado no índice de vegetação de diferença normalizada (NDVI) e NDWI e de acordo com as características do corpo d'água da imagem de micro-ondas, Han, Jia e Sun (2022) propuseram um método de índice para extração de informações do corpo d'água com base nos

dados polarizados duplos do Sentinel-1 e no Sentinel-1 dual-polarized water index (SDWI). O índice expandi a diferença entre corpos d'água e outras características da superfície (fundo) amplificando 10 vezes o produto das imagens polarizadas VV e VH e, em seguida, usando o logaritmo natural como fórmula funcional. Du et al. (2023) revelaram que o índice de água duplamente polarizado (SDWI) do Sentinel-1, calculado pela combinação de dados polarizados vertical-vertical (VV) e vertical-horizontal (VH), é um índice útil para extração de água e o resultado é melhor do que cada uma das imagens polarizadas VV ou VH. No geral, a informação de contorno da água é a característica mais intuitiva e importante, sendo também uma característica essencial da imagem para pesquisas iniciais na tarefa de extrair água de imagens SAR. A detecção da área do corpo hídrico envolve encontrar um conjunto de pixels cujos valores mudam bruscamente na imagem, que geralmente é o contorno da água (Yilmaz et al. 2023).

A combinação entre índices espectrais e técnicas de classificação supervisionadas ou não supervisionada permitem derivar a extensão do corpo hídrico de forma automática. Entre elas, o aprendizado de máquina e o aprendizado profundo são técnicas de classificação de imagens baseadas em métodos de classificação supervisionados para extração de águas superficiais que alcançam maior precisão do que a classificação baseada em pixels (Che, Li e Liu, 2025). Normalmente, por ser baseado por amostras definidas pelos usuários, os algoritmos supervisionados fornecem melhores resultados, porém requerem a operacionalidade e compreensão prévia do usuário e tempo de processamento. Enquanto os classificadores não supervisionados, consegue extrair o polígono de corpos hídricos de forma autônoma e menor tempo processamento. No entanto, a literatura demonstra que técnicas não supervisionadas podem fornecer excelentes resultados se aplicadas adequadamente, ou seja, no mapa resultante da aplicação de índices espectrais de água, sendo, quanto maior a capacidade do índice em caracterizar os pixels de água, o classificador não supervisionado pode obter resultados significativos. Esses métodos geralmente são sensíveis ao ruído de manchas em imagens SAR e portanto, os classificadores não supervisionados são métodos válidos e eficientes nesta abordagem.

Nesse sentido, o princípio dos algoritmos de agrupamento automático é classificar os pixels na imagem em diferentes classes, ou grupos, de acordo com padrões específicos (como algumas regras de distância), de modo que a similaridade dos pixels no mesmo grupo seja a mais forte possível, e a diferença de pixels que não estão no mesmo grupo seja a maior possível. Ou seja, após o agrupamento, os pixels da mesma classe devem ser agrupados o máximo possível, e pixels diferentes devem ser separados o máximo possível (Du et al. 2023). No campo

da segmentação de corpos d'água SAR, K-means e o ISODATA são dois métodos principais de agrupamento. O uso de classificadores não supervisionados baseados em aprendizado profundo (deep learning) podem efetivamente extrair características de imagens de radar, alcançando resultados de classificação de alta precisão, no entanto, a pesquisas atuais sobre o uso de redes semânticas para a viabilidade classificação da água como por exemplo o HDBSCAN e o Autoencoder ainda não são vastas e precisam ser exploradas.

Nesse sentido Yadav et al. (2024) propuseram um novo modelo não supervisionado para detectar a extensão de corpos hídricos usando dados de séries temporais de Radar de Abertura Sintética (SAR). O modelo proposto é baseado em um autocodificador variacional (variational autoencoder) espaço-temporal, treinado com técnicas de reconstrução e aprendizado contrastivo. Os autores revelaram que o modelo atingiu uma média de 70% de pontuação de Intersecção sobre União (IoU), que é pelo menos 7% melhor do que a IoU dos modelos não supervisionados existentes. Jiang e Zeng (2024) utilizaram o algoritmo de agrupamento K-Means nas imagens polarimétricas duplas (VV e VH) do satélite Sentinel-1 utilizando recursos de textura GLCM para classificar corpos hídricos e alcançaram uma precisão entre 92% e 99%. Já Peña et al. (2024) implementaram o algoritmo DeepAqua que é baseado em segmentação semântica não supervisionadas de superfícies de águas úmidas com imagens SAR usando redes neurais profundas, resultados experimentais mostram que o DeepAqua supera outros métodos não supervisionados, melhorando a precisão em 3%, a Intersecção sobre União em 11% e a pontuação F1 em 6%. Todas essas abordagens utilizaram modelos modernos não supervisionados e as polarizações únicas das imagens SAR, nenhuma delas utilizaram índices espectrais SAR como dados de entrada (Rajeswari; Rathika, 2024).

Considerando o conceito de integrar índice espectral e classificadores não supervisionados, este estudo propõe a análise uma estrutura automatizada de detecção de água superficial usando imagens SAR Sentinel-1 e um novo índice espectral SEWI – SAR Enhanced Water Index diferentes corpos hídricos de regiões diferentes e complexas do Brasil sendo elas Cachoeira Dourada, Minas Gerais; Barragem de Tapacurá, Pernambuco; Barragem Arroio Duro, Rio Grande do Sul; Rio Mututi, Pará; Barragem Pedra do Cavalo, Bahia; Saco da Gorda, Mato Grosso; Açude Poço da Cruz, Pernambuco combinado com seis classificadores não supervisionados sendo eles CLARA (Clustering Large Applications) e o K-means; métodos baseados em deep learning, como o SOM (Self-Organizing Map) e o Autoencoder; métodos hierárquicos, como o HDBSCAN (Hierarchical Density-Based Spatial Clustering of Applications with Noise); e métodos probabilísticos, como o Expectativa-Maximização (EM);

com base na comparação quantitativa, especial e temática com os dados de referência do Mapbiomas Beta.

3 METODOLOGIA

3.1 Área de estudo

Os experimentos foram conduzidos em dezesseis áreas representativas de diferentes corpos hídricos do Brasil em relação a análise realizada como mostrado na Figura 1, para a análise supervisionada incluiu a Cachoeira Dourada em Minas Gerais, Barragem de Tapacurá, e Açude Poço da Cruz em Pernambuco; Barragem Arroio Duro no Rio Grande do Sul; Rio Mututi na Floresta Amazônica; Barragem Pedra do Cavalo na Bahia; e Saco da Gorda no bioma Pantanal. A seleção desses corpos hídricos considerou sua morfologia, distribuição espacial homogênea, relevância para os sistemas de recursos hídricos, biodiversidade e abastecimento regional, além da influência de fatores como sazonalidade, pressões antrópicas e mudanças climáticas, que causam variações contínuas em seus espelhos d'água.



Fonte: Autor (2025).

3.2 Dados Sentinel-1

Para extrair dados dos diferentes corpos hídricos, foram utilizadas um mosaico de cenas do sensor SAR Sentinel-1, disponibilizadas na plataforma em nuvem Google Earth Engine (GEE), referentes ao mês de outubro de 2023. A missão Sentinel-1 fornece dados de radar de abertura sintética (SAR) de banda C, com polarização dupla a 5,405 GHz. Essa coleção inclui cenas S1 calibradas e ortocorrigidas no modo *Ground Range Detected* (GRD), com polarizações VH e VV e resolução espacial de 10 metros. As imagens passaram por um processamento que incluiu remoção de ruído térmico, calibração radiométrica e correção de terreno utilizando diferentes modelos digitais de elevação (MDTs). Os valores finais corrigidos do terreno foram convertidos para decibéis por meio da escala logarítmica ($10 \cdot \log_{10}(VV \text{ ou } VH)$) (Filipponi, 2019).

3.1.1 Índice de água SAR aprimorado - Enhanced SAR Water Index (SEWI)

A intensidade da retrodispersão em imagens SAR está diretamente relacionada à rugosidade da superfície dos objetos terrestres. Superfícies lisas, como corpos d'água, são dominadas pela dispersão especular, refletindo o sinal do radar para longe do sensor e resultando em uma resposta mais fraca. Em contraste, superfícies terrestres, que apresentam maior rugosidade, exibem dispersão volumétrica, retornando um sinal mais intenso ao sensor (Tian et al. 2022; Du et al. 2023).

Nas imagens do Sentinel-1 SAR, essa diferença se traduz em valores de pixel baixos para corpos d'água, que aparecem como regiões escuras, enquanto áreas terrestres apresentam um retorno mais forte, sendo visualizadas com tons mais brilhantes (Tian et al., 2017). Partindo dessa premissa fundamental sobre o comportamento dos corpos hídricos em imagens SAR, o *SAR Enhanced Water Index* (SEWI), mostrado na equação 1, é definido como uma função $f(x_1, x_2)$, onde x_1 e x_2 representam, respectivamente, as polarizações VV e VH.

$$SEWI = \frac{1}{\left(\frac{1}{VH} + \frac{1}{VV}\right)^2} \quad (1)$$

O objetivo do SEWI é ampliar a separação entre corpos d'água e outras superfícies, explorando a característica de que os valores de pixels de água são extremamente baixos.

Matematicamente, isso ocorre porque, na formulação do índice, o denominador da função racional polinomial se aproxima de zero, resultando em um aumento expressivo do valor final de $f(x_1, x_2)$. Esse efeito é particularmente perceptível quando x_1 e x_2 assumem valores negativos e elevados em magnitude, evidenciando a alta resposta do índice para a detecção de corpos d'água. Tomando como base pixels de água das polarizações VV e VH que são valores negativos muito baixos, uma vez que a função dada pela equação 2.

$$f(x_1, x_2) = \frac{1}{\left(\frac{1}{x_1} + \frac{1}{x_2}\right)^2} \quad (2)$$

Que pode ser reescrita como na forma da equação 3.

$$f(x_1, x_2) = \left(\frac{x_1 x_2}{x_1 + x_2}\right)^2 \quad (3)$$

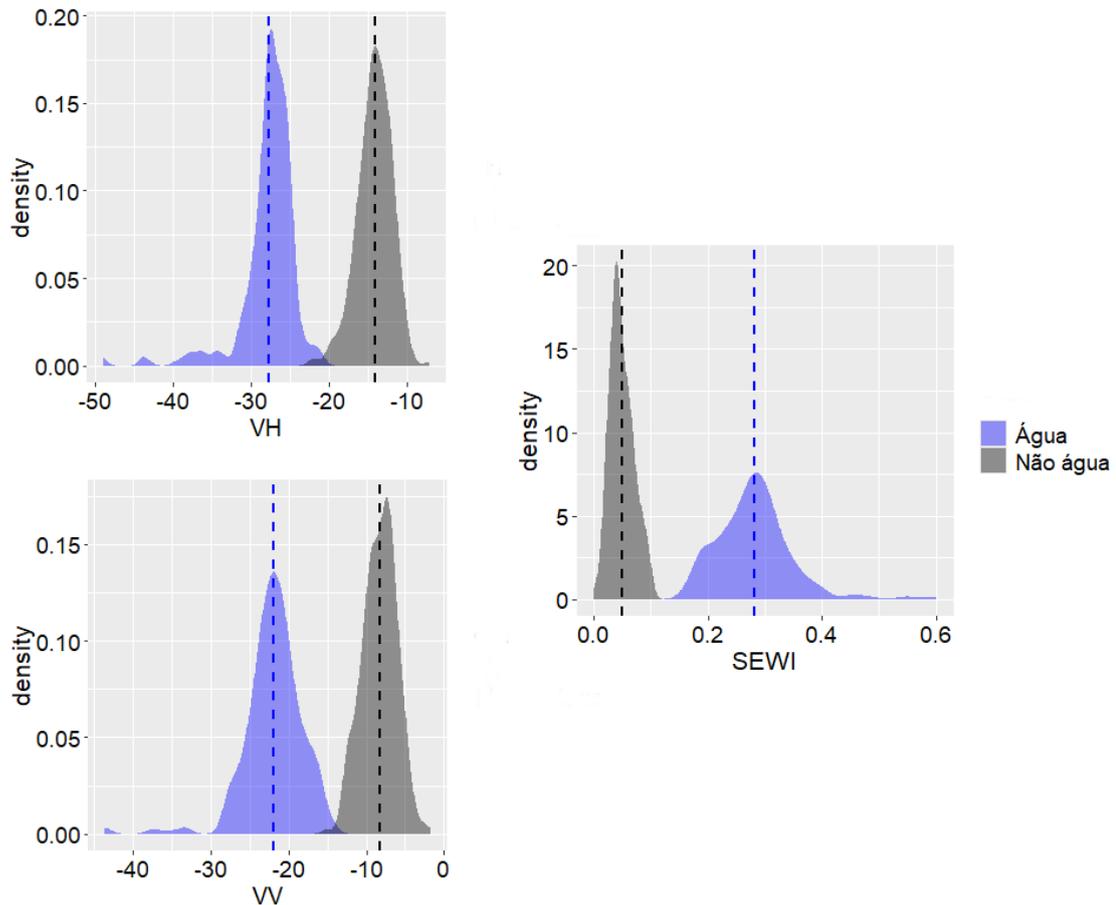
Se $x_1, x_2 < 0$, e, então a soma $x_1 + x_2$ será negativa, enquanto o produto $x_1 x_2$ será positivo, pois resulta da multiplicação de dois números negativos. Consequentemente, a fração $\left(\frac{x_1 x_2}{x_1 + x_2}\right)$ também será negativa, mas ao ser elevada ao quadrado, torna-se positiva. Quando x_1 e x_2 são valores negativos próximos em módulo, mas com grandes magnitudes, como ocorre com os pixels de água nas polarizações VV e VH, a função $f(x_1, x_2)$ cresce significativamente à medida que o denominador $x_1 + x_2$ se aproxima de zero. Isso acontece porque, quando x_1 e x_2 são grandes e negativos, a função atinge valores elevados, ou seja, a função é significativamente maximizada, resultando em pixels ligeiramente esbranquiçados nas imagens. Substituindo $x_1 = x_2 = -a$ a equação 3 pode ser reescrita como na equação 4.

$$f(-a, -a) = \frac{(-a \cdot -a)^2}{(-a - a)^2} = \frac{a^4}{4a^2} = \frac{a^2}{4} \quad (4)$$

Se a é muito pequeno (próximo de zero), $f(-a, -a)$ será muito pequeno (próximo de zero). No entanto, se x_1 e x_2 são próximos, mas não iguais, o denominador $(x_1 + x_2)^2$ pode ser muito menor que o numerador, levando a valores grandes de $f(x_1, x_2)$.

Baseado na obtenção do índice SEWI através de um conjunto amostral demonstrativo, a Figura 2 revela a distribuição de amostras de pixels de Água (em azul) e Não água (em cinza) em um espaço de histogramas de densidade para as polarizações VV e VH e o índice SEWI.

Figura 2 – Distribuição de densidade do comportamento dos valores de retroespalhamento da polarização VV, VH e os valores do índice SEWI.



Fonte: Autor (2025).

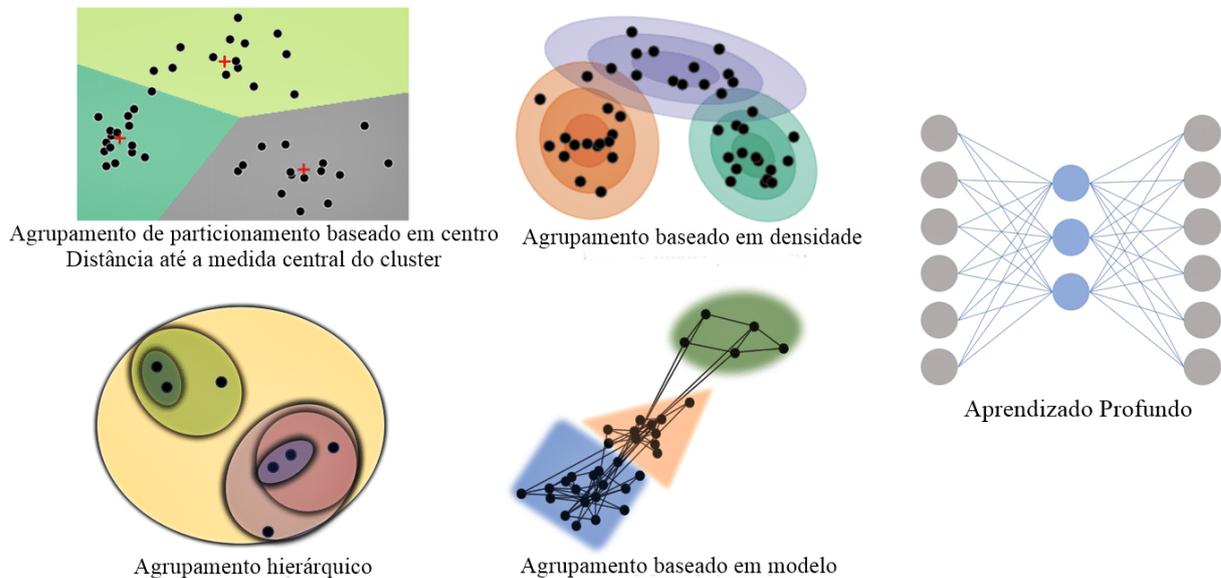
Observa-se uma clara separação entre os dois grupos, especialmente nos canais VH e VV, onde a água apresenta valores mais negativos. No índice SEWI, os valores para água tendem a ser maiores que os de não água. As linhas tracejadas representam os valores médios de cada classe, destacando o contraste entre os grupos. A figura 3 indica que as três variáveis, com destaque para o índice SEWI são eficazes para diferenciar corpos d'água de outras coberturas superficiais.

3.1.1 Classificadores não supervisionados

Vários de algoritmos de agrupamento foram publicados com variações em seu design fundamental, suposições, estruturas de dados alvo, parâmetros de interesse e processos computacionais/de otimização. A taxonomia dos algoritmos de agrupamento pode ser mapeada de diferentes maneiras (Figura 3), por exemplo, particional vs hierárquico, ou suave vs rígido. Considerando os problemas comuns encontrados na pesquisa em sensoriamento remoto,

resumimos amplamente os algoritmos comuns em cinco principais grupos, a saber, agrupamento de particionamento baseado em centro, agrupamento hierárquico, agrupamento baseado em densidade, agrupamento baseado em modelo e aprendizado profundo (Gao et al. 2023).

Figura 3 – Ilustração simples dos principais tipos de modelos de agrupamento.



Fonte: Adaptado Khosla et al. (2019).

Esta seção descreve os classificadores não supervisionados utilizados neste estudo para a identificação das classes Água e Não Água, utilizando o índice SEWI como única variável de entrada. Foram empregados algoritmos baseados em diferentes abordagens, incluindo métodos de partição, como o CLARA e o K-means; métodos baseados em deep learning, como o SOM e o Autoencoder; métodos hierárquicos, como o HDBSCAN ; e métodos probabilísticos, como o Expectativa-Maximização (EM). Todos os algoritmos foram configurados para identificar dois clusters (Água e Não Água) e implementados em ambiente Python na plataforma Jupyter Notebook.

3.1.1.1 CLARA

CLARA (*Clustering Large Applications*) é um algoritmo de agrupamento desenvolvido para lidar com grandes volumes de dados, sendo especialmente útil na análise de imagens de sensoriamento remoto de forma mais eficiente do que métodos tradicionais como o k-means. Baseia-se no algoritmo PAM (*Partitioning Around Medoids*), mas utiliza técnicas de amostragem para melhorar o desempenho computacional. Diferentemente do k-means, o PAM

— frequentemente confundido com o próprio k-means — trabalha com medoides, que são pontos reais do conjunto de dados e representam melhor os agrupamentos ao minimizar a soma das distâncias absolutas entre os dados e seus respectivos medoides (Devi e Kavida, 2020).

O funcionamento do CLARA envolve a seleção de múltiplas amostras aleatórias do conjunto de dados, aplicando o PAM a cada uma delas. Em seguida, avalia-se a qualidade do agrupamento considerando a média das dissimilaridades entre todos os dados do conjunto original, e não apenas os das amostras. O melhor resultado é aquele que apresenta a menor dissimilaridade média, sendo então selecionado como o agrupamento final. O desempenho do CLARA depende fortemente do tamanho das amostras escolhidas (Li et al. 2025). Uma de suas principais vantagens em relação a outros métodos baseados em medoides é sua robustez a outliers e sua escalabilidade para grandes conjuntos de dados (Gharahbagh et al. 2025). Assim, o CLARA apresenta uma excelente relação entre eficiência computacional e capacidade de lidar com big data, destacando-se como uma abordagem viável em cenários com grandes volumes de informação.

3.1.1.2 K-médias

K-means é um algoritmo de agrupamento baseado em partição que visa minimizar a soma dos quadrados das distâncias entre os pontos de dados e seus centróides de agrupamento correspondentes. Ele começa inicializando os centróides aleatoriamente, seguido por um processo iterativo de atribuição de pontos ao centróide mais próximo e atualizando os centróides com base na média dos pontos atribuídos. O agrupamento k-means é um método pelo qual pixels são atribuídos a classes espectrais por partições baseadas em máquina sem conhecimento prévio dessas classes. É uma maneira direta de classificação de imagens automática e sem amostragem externa. O algoritmo executa um particionamento de pixels que infere os rótulos das classes desejadas analisando a similaridade intraclasse e, vice-versa, o contraste entre as classes (Lemenkova; Debeir, 2022).

3.1.1.3 Encoder

Nesta pesquisa, propomos impulsionar o ED usando recursos artesanais. Em nosso modelo, uma etapa de pré-processamento foi realizada para criar representações mais robustas por meio de nosso ED proposto. Nesta fase, dois recursos artesanais práticos (ou seja, modelo de superfície digital normalizado (DSM) e índices de vegetação, como NDVI para classificação

de cena urbana, foram usados. Também usamos a fração mínima de ruído (MNF) como outro recurso de reforço. Este fluxo de trabalho atualizou nossos recursos profundos após o aprendizado não supervisionado pelo CAE (Wang et al. 2024)

ED é um método de aprendizagem de características não supervisionado que recentemente atraiu a atenção científica. ED é um modelo de extração de características multinível que visa descobrir as informações internas das imagens. Comparado com AE denso convencional, ED utiliza a localidade espacial das imagens originais, o que é crítico para o agrupamento de imagens e diminui a possibilidade de overfitting causado pela redundância de parâmetros (Ansith e Bini, 2022).

3.1.1.4 Expectativa-Maximização (EM)

A classificação Expectativa-Maximização (EM) é uma técnica estatística baseada em modelos de mistura, amplamente utilizada em Sensoriamento Remoto para classificação não supervisionada de imagens, como aquelas obtidas por satélites. O método busca identificar e separar padrões distintos em grandes conjuntos de dados espectrais, mesmo quando a informação de classe não está previamente disponível. O algoritmo EM é uma extensão dos métodos de clustering, como o k-means, mas é mais flexível e robusto, pois assume que os dados são gerados por uma combinação de várias distribuições estatísticas (geralmente Gaussianas), permitindo modelar melhor a variabilidade espectral das diferentes classes nas imagens (Xie, Wu, Qiang, 2023). De forma iterativa EM funciona com duas etapas principais, sendo a Etapa E (Expectativa) que calcula a probabilidade de cada ponto de dado pertencer a cada classe (ou componente da mistura), com base nos parâmetros atuais do modelo e Etapa M (Maximização) que atualiza os parâmetros do modelo (como média e variância de cada componente) para maximizar a verossimilhança dos dados os pesos calculados na etapa anterior.

3.1.1.5 SOM

Os Mapas Auto-Organizáveis (Self-Organizing Maps – SOMs) são redes neurais artificiais não supervisionadas amplamente utilizadas na análise de dados de sensoriamento remoto, especialmente quando se lida com conjuntos de dados de alta dimensão. Um SOM é composto por uma arquitetura de rede com duas camadas, uma de entrada e outra de mapa

competitivo. O aprendizado ocorre de forma não supervisionada, baseado na competição entre neurônios, o que resulta na formação de um mapa topológico que preserva as relações de similaridade entre os dados de entrada (Mokarram e Pham, 2025)

A principal função do SOM é reduzir a dimensionalidade dos dados, mapeando padrões de alta dimensão para uma grade de menor dimensão, normalmente bidimensional. Essa grade, composta por neurônios organizados espacialmente (geralmente em formato retangular), constitui o chamado espaço de saída, enquanto o conjunto original de dados pertence ao espaço de entrada. Durante o processo de treinamento, o SOM busca preservar as relações topológicas entre os dados: ou seja, padrões semelhantes no espaço de entrada são mapeados para neurônios vizinhos no espaço de saída. Essa característica torna os SOMs eficazes para a visualização, agrupamento e interpretação de dados complexos, como os provenientes de sensores remotos (Doan et al. 2021).

De forma geral, o SOM permite representar informações espectrais complexas de forma compacta, auxiliando na classificação temática, detecção de padrões e redução de ruído em imagens de satélite e outros produtos de sensoriamento remoto.

3.1.1.1 HDBSCAN

O HDBSCAN é uma extensão do algoritmo DBSCAN que melhora a detecção de clusters com densidades variadas, sendo especialmente útil em aplicações de sensoriamento remoto, onde os dados costumam ser complexos, ruidosos e heterogêneos. Diferente de algoritmos tradicionais como k-means, que assumem que todos os clusters têm forma esférica e densidade semelhante, o HDBSCAN não exige que o número de clusters seja pré-definido e pode identificar estruturas com diferentes densidades, além de detectar ruídos ou outliers automaticamente. Isso o torna ideal para análise de imagens multiespectrais, hiperespectrais e outros tipos de dados geoespaciais. O algoritmo calcula a densidade local ao redor de cada ponto e, a partir dessas estimativas, constrói uma hierarquia de agrupamentos, resultando em um dendrograma, onde os clusters são organizados de forma hierárquica. Em seguida, os clusters mais estáveis são extraídos com base em medidas de persistência, ou seja, na consistência com que aparecem ao longo da hierarquia. Por fim, os pontos que não pertencem a nenhum agrupamento consistente são identificados como outliers e rotulados como ruído (Zheng, Wen e Sarem, 2024).

3.1.1 Avaliação da acurácia

Os corpos hídricos detectados pelo produto Mapbiomas Beta 2023 foi utilizado como produto de referência na distribuição de pixels de Água e Não água nas oitos regiões em estudo. O MapBiomas Beta consiste no mapeamento oficial de classes de uso e cobertura do solo georreferenciado, elaborado com base em mosaicos de imagens dos satélites Sentinel-2, com resolução espacial de 10 metros. O período de mapeamento abrange de 2016 a 2023 cobrindo todo o território brasileiro. Esse processo foi realizado de forma colaborativa entre as instituições do MapBiomas, utilizando e algoritmos de aprendizado profundo (deep learning) na plataforma Google Earth Engine e Google Cloud Platforms (Mapbiomas, 2023).

3.1.1.1 Coeficientes de precisão

A qualidade de um mapa temático derivado do sensoriamento remoto é geralmente avaliada por meio de uma comparação sistemática com mapas produzidos por órgãos oficiais. Neste estudo, a precisão da escala local foi analisada por meio da tabela de contingência, uma tabela NxN que resume as previsões corretas e incorretas de um modelo de classificação (Tabela 1) (Libonati et al. 2015; Brereton, 2021). No caso deste estudo, a classificação binária “Água” e “Não Água” foi utilizada para medir a concordância e discordância entre a classificação e os dados de referência.

Tabela 1 – Tabela de Contingência

Classificado	Referência		
	Água Não Água	Água VP = Verdadeiro Positivo FN = Falso Negativo	Não água FP = Falso Positivo VN = Verdadeiro Negativo

Fonte: Autor (2025).

Foram calculadas as métricas Coeficiente Sorensen-Dice (eq. 7), Erro de Omissão (Eq 8), Erro de Comissão (Eq 9), Acurácia Global (Eq. 9) e Recall (Eq. 10). Esses indicadores resultaram da comparação categórica entre as seis imagens classificadas pelos métodos não supervisionados com os dados de referência (MapBiomas beta).

$$DC = \frac{2VP}{2VP + FP + FN} \quad (7)$$

$$EO = \frac{FN}{FN+VP} \quad (8)$$

$$EC = \frac{FP}{VP+FP} \quad (9)$$

$$AG = \frac{VP + VN}{VP + FP + FN + VN} \quad (10)$$

$$\text{Recall} = \frac{VP}{VP + FN} \quad (11)$$

O coeficiente de Dice (DC), que varia de 0 a 1, mede a similaridade entre o classificador e o mapa de referência com base no número de pixels de água em comum. Valores próximos a 1 indicam melhor concordância, enquanto valores próximos a 0 indicam pior desempenho. O erro de omissão (EO) representa a fração de pixels de água no mapa de referência que não foram classificados como tal no produto classificado. Já o erro de comissão (EC) corresponde à fração de pixels classificados como água no produto classificado, mas que na verdade são “não água” no mapa de referência. Ambos variam de 0 a 1, sendo que valores próximos a 1 indicam maior erro e valores próximos a 0 indicam melhor precisão (Brereton, 2021). O Recall, ou Taxa de Verdadeiros Positivos, indica a proporção de positivos reais corretamente classificados. Quanto maior o Recall (máximo = 1), melhor a detecção de pixels de água no produto classificado. A Acurácia Global (AG) reflete o grau de concordância entre o produto classificado e o mapa de referência para os pixels de “Água” e “Não Água”, representando a precisão geral da classificação. A AG varia de 0 a 100%, sendo que valores próximos a 100% indicam maior precisão do produto classificado (Libonati et al. 2015; Chughtai; Abbasi e Karas, 2021).

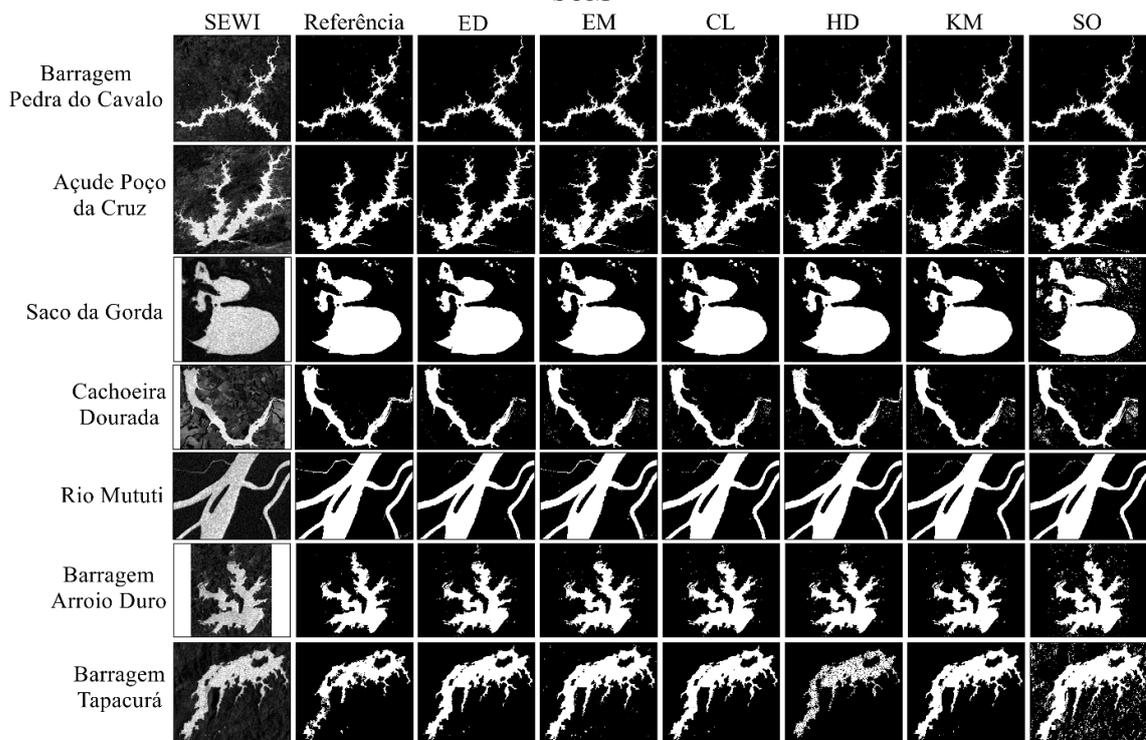
Grade de Regressão

Um certo grau de erro de omissão e comissão é devido unicamente à presença de pixels mistos, e a matriz de erro não distingue entre esses erros inevitáveis e erros devido à classificação incorreta. Por esse motivo, a matriz de erro e as métricas de precisão derivadas foram complementadas por uma avaliação de precisão de escala regional com base em métricas de regressão. A proporção de 1000 células de grade detectadas como “Água” pelos produtos classificados é comparada à proporção de área detectada pelos dados de referência. Dessa forma, calculados o RMSE e a Correlação (r) sendo está uma indicação da precisão (Giglio et al. 2018).

4 RESULTADOS

A Figura 4 mostra a distribuição de pixels do índice SEWI, a extração de água de referência, e as imagens SEWI submetidas à extração de água pelos diferentes classificadores para as áreas de estudo em análise.

Figura 4. Extração de água obtidos pelo índice SEWI categorizados pelos classificadores não supervisionados. ED = Encoder; EM = Expectation–Maximization; CL = CLARA; HD=HDBSCAN; KM = K-means e SO = SOM



Fonte: Autor (2025).

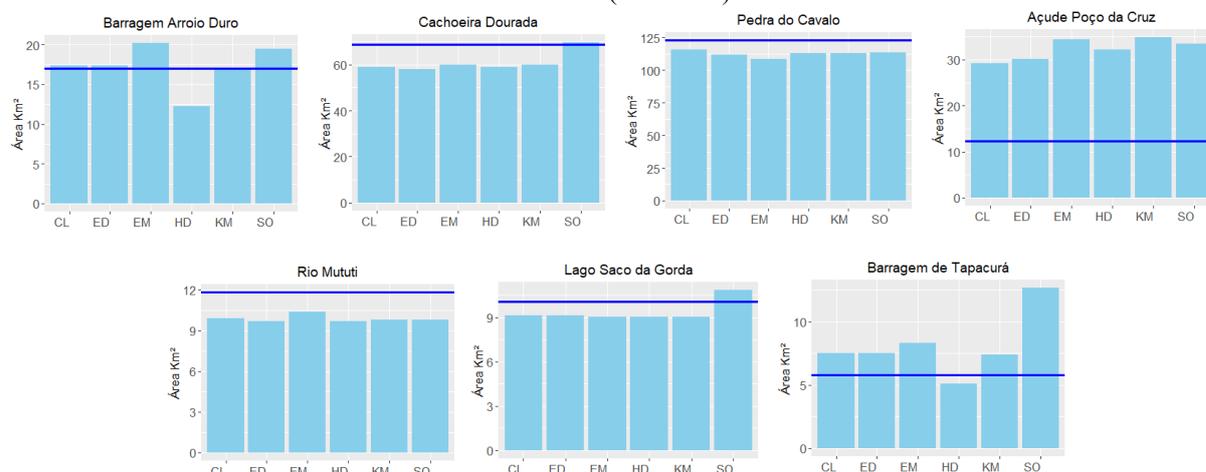
A maioria dos classificadores apresentou desempenho visual satisfatório na delimitação dos corpos d'água, especialmente em áreas com margens bem definidas, como Saco da Gorda, Rio Mututi e Barragem Arroio Duro. Nesses casos, os contornos gerados foram consistentes e próximos ao mapa de referência. Por outro lado, em regiões de paisagem complexas ou com ruído de fundo acentuado, como Barragem Pedra do Cavalo e Barragem Tapacurá, houve falhas de detecção ou excesso de segmentação — sobretudo por parte do SOM, que gerou mapas mais ruidosos e áreas indevidamente classificadas como água, evidentes, por exemplo, na dispersão de pixels brancos fora das áreas de interesse na última linha da imagem.

Como mostrado na figura 4, dentre os classificadores, os métodos ED, EM e KM foram os que mais consistentemente se aproximaram do mapa de referência, com boa definição dos contornos e poucos erros de inclusão ou exclusão. O CL também apresentou desempenho

estável, embora com leve imprecisão na definição das margens em alguns casos, como em Cachoeira Dourada. Já o HD mostrou bons resultados em áreas homogêneas, mas desempenho mais instável em regiões complexas, com falhas de continuidade nas massas d'água, especialmente em Tapacurá e Cachoeira Dourada.

A Figura 5 mostra a comparação entre as áreas delimitadas por diferentes classificadores (CL, ED, EM, HD, KM, SOM) e as áreas de referência (linha azul) para espelhos d'água de diversos corpos hídricos do Brasil. No geral, na maioria dos corpos hídricos analisados, os classificadores produziram áreas próximas à referência, com destaque para Saco da Gorda, Rio Mututi, e Barragem Arroio Duro.

Figura 5 – Área do espelho d'água detectados pelos classificadores sendo comparados com a área obtida pela referência (linha azul).



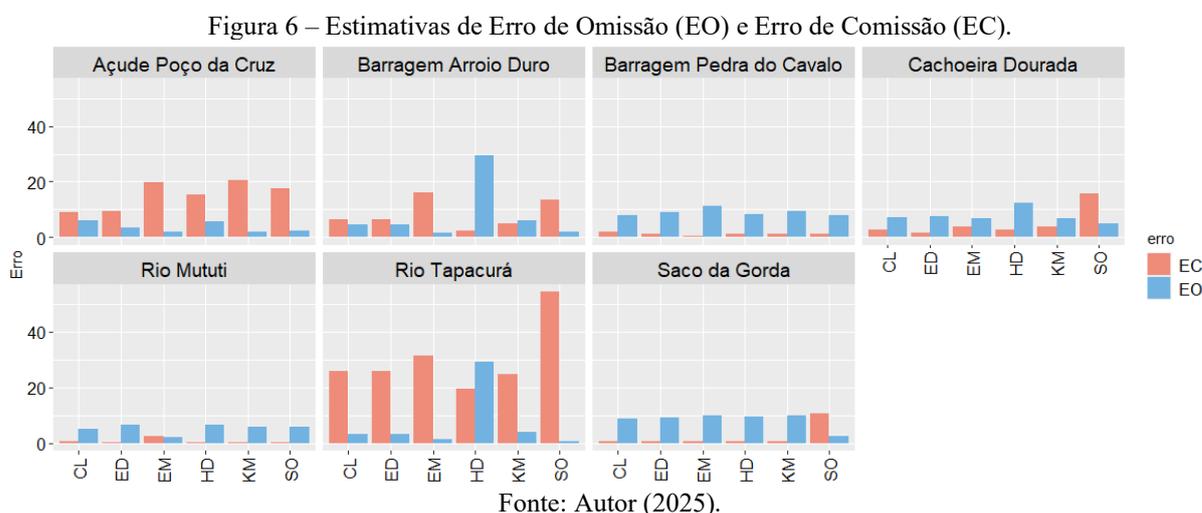
Fonte: Autor (2025).

A análise dos dados revela que os classificadores não supervisionados apresentam variações significativas em relação às áreas de referência, com desempenhos distintos para cada corpo hídrico. No geral, CLARA (CL) e Endecoder (ED) demonstram maior proximidade com os valores de referência, especialmente em corpos hídricos como Barragem Pedra do Cavalo (CL: 115,67 km² vs. referência: 122,871 km²) e Rio Mututi (ED: 9,71 km² vs. referência: 11,82 km²). O HDBSCAN (HD) também se destaca em alguns casos, como em Cachoeira Dourada (HD: 58,92 km² vs. referência: 68,75 km²), mas subestima consistentemente áreas como Barragem Arroio Duro (HD: 12,28 km² vs. referência: 17,02 km²) (Figura 6). Por outro lado, Expectation-Maximization (EM) e K-médias (KM) tendem a superestimar áreas como Açude Poço da Cruz (EM: 34,46 km²; KM: 34,84 km² vs. referência: 12,35 km²), indicando possível sensibilidade a ruídos ou variações no índice SEWI. Já a Self Organizing Map (SO) apresenta

o pior desempenho em Saco da Gorda (SO: 10,85 km² vs. referência: 10,08 km²) e Barragem de Tacacurá (SO: 12,68 km² vs. referência: 5,79 km²).

O classificador SOM apresenta maior variação em diversos corpos d'água, frequentemente superestimando a área em comparação com a referência — especialmente evidente em Cachoeira Dourada e Barragem Pedra do Cavalo. Isso corrobora a observação anterior de que o SOM tende à superestimação, nesse sentido, a Barragem Pedra do Cavalo, Cachoeira Dourada, e Tapacurá apresentam maior dispersão nos resultados entre os classificadores.

A Figura 6 apresenta uma comparação das taxas de erro de comissão (EC) em vermelho e erro de omissão (EO) em azul para diferentes classificadores (CL, ED, EM, HD, KM, SOM), aplicados à delimitação de corpos hídricos em várias regiões do Brasil. No geral, ED, EM e KM continuam se destacando como os classificadores mais equilibrados enquanto o SO, por outro lado, demonstra ser o menos confiável, com altos índices de erro, especialmente em áreas mais complexas.



O SOM destaca-se com o pior desempenho em Saco da Gorda (EO=2,52%, EC=10,48%) e Barragem de Tapacurá (EC=54,38%), indicando alta confusão na distinção de classes nesses locais e o HDBSCAN (HD) apresenta EC extremamente alto em Rio Mututi (29,59%) e Barragem Arroio Duro (29,22%), sugerindo tendência a falsos positivos (Figura 7). Já seu EO elevado nesses mesmos locais (6,66% e 29,59%) aponta dificuldade em identificar classes reais. O Expectation-Maximization (EM) tem desempenho equilibrado em Açude Poço da Cruz (EC=19,72%), mas falha em Barragem Arroio Duro (EC=31,24%), mostrando sensibilidade ao contexto geográfico. O CLARA (CL) mantém EC baixo em Rio Mututi

(0,46%), mas EO moderado (4,95%), enquanto ED reduz ainda mais o EC (0,22%) com EO maior (6,45%). Isso indica um trade-off clássico: menor inclusão de falsos positivos (EC) pode aumentar falsos negativos (EO). O Encoder (ED) é o mais estável em EO (valores entre 3,34% e 9,07%), exceto em Rio Mututi (6,45%). SO em Cachoeira Dourada tem EC=15,75% e EO=5,12%, mostrando tendência oposta (prioriza reduzir falsos negativos, aceitando mais falsos positivos).

Em regiões como Saco da Gorda, Rio Mututi, e Barragem Pedra do Cavalo, os erros (tanto EC quanto EO) foram geralmente baixos para todos os classificadores, por outro lado, no geral, nenhum classificador domina todos os cenários. HD e SO são os menos consistentes, enquanto ED e CL oferecem equilíbrio relativo. Dessa forma, o classificador SOM apresentou os maiores erros de comissão e omissão em várias regiões, como Rio Tapacurá, Cachoeira Dourada e Barragem Arroio Duro, por outro lado na Barragem de Tapacurá por exemplo, o SOM ultrapassa 50% em EC, sugerindo que grande parte das áreas classificadas como água na verdade não corresponde a corpos hídricos confirmando a tendência à superestimação e baixa precisão observada em análises anteriores.

A Tabela 2 mostra os valores de coeficiente dice. De modo geral, é possível observar que a performance dos algoritmos é relativamente consistente nos corpos hídricos "Barragem Pedra do Cavalo", "Rio Mututi" e "Cachoeira Dourada", com valores elevados (acima de 0,80 para todos os métodos, com pequenas variações). Entre os métodos, o Encoder (ED) e o CLARA (CL) se destacam pela consistência em valores elevados em praticamente todos os locais, inclusive em regiões mais desafiadoras como a "Barragem de Tapacurá", onde ambos obtêm 0,72 — valor relativamente alto considerando a queda de desempenho dos outros métodos nesse local.

Tabela 2 – Coeficiente Dice-Sørensen para os diferentes classificadores.

Classificador	Pedra do Cavalo	Poço da Cruz	Saco da Gorda	Cachoeira Dourada	Rio Mututi	Barragem Arroio Duro	Barragem de Tapacurá
CL	0,84	0,81	0,81	0,84	0,85	0,82	0,72
ED	0,84	0,82	0,81	0,84	0,85	0,79	0,72
EM	0,83	0,76	0,80	0,83	0,86	0,73	0,69
HD	0,84	0,78	0,81	0,81	0,85	0,71	0,61
KM	0,84	0,75	0,80	0,83	0,85	0,80	0,72
SO	0,85	0,77	0,78	0,76	0,84	0,79	0,50

Fonte: Autor (2025).

O (SO), apesar de ter o melhor valor na "Barragem Pedra do Cavalo" (0,85), mostra o pior desempenho na "Barragem de Tapacurá" (0,50). O Expectation-Maximization (EM) também apresenta flutuações maiores nos resultados, oscilando entre 0,69 e 0,86. Ainda que atinja o maior valor individual em "Rio Mututi" (0,86), sua performance inconsistente sugere que depende fortemente das condições específicas de cada local. O (HD) demonstra valores bons em geral, com destaque para a "Rio Mututi" (0,85), mas sofre quedas notáveis em "Barragem Arroio Duro" (0,71) e, principalmente, em "Barragem de Tapacurá" (0,61) (Figura 6).

Por fim, o (KM) mantém valores estáveis e elevados, sendo um dos mais equilibrados junto com o CLARA e o Endecoder, exceto por uma leve queda em "Açude Poço da Cruz" (0,75). A "Barragem de Tapacurá" se destaca negativamente como o corpo hídrico mais desafiador para todos os algoritmos, provavelmente devido a fatores como ruído nos dados, baixa qualidade das imagens, ou complexidade nas feições de interesse. Nenhum dos métodos atinge 0,75 nesse local, e o Self Organizing Map tem uma queda drástica para 0,50. Em suma, os algoritmos CLARA, Endecoder e K-médias apresentam melhor desempenho médio e maior robustez frente à variação de dados, sendo mais indicados para cenários com diferentes características. Já algoritmos como SO e EM, apesar de pontualmente eficazes, foram menos consistentes.

A Tabela 3 apresenta os valores de recall obtidos pelos diferentes classificadores (CL, ED, EM, HD, KM, SOM) na segmentação de espelhos d'água em diversos corpos hídricos brasileiros. De forma geral, observa-se que os classificadores ED, CL e KM apresentam os resultados mais consistentes, com valores elevados de recall (acima de 0,90) na maioria das regiões.

Tabela 3 – Coeficiente de Recall para os diferentes classificadores.

Classificador	Pedra do Cavalo	Poço da Cruz	Saco da Gorda	Cachoeira Dourada	Rio Mututi	Barragem Arroio Duro	Barragem de Tapacurá
CL	0,91	0,87	0,94	0,91	0,96	0,92	0,74
ED	0,91	0,89	0,94	0,92	0,95	0,94	0,74
EM	0,89	0,81	0,94	0,91	0,97	0,90	0,71
HD	0,91	0,80	0,94	0,86	0,95	0,70	0,54
KM	0,90	0,80	0,94	0,91	0,95	0,93	0,74
SO	0,91	0,82	0,92	0,82	0,97	0,88	0,51

Fonte: Autor (2025).

O classificador ED se destaca por alcançar os maiores valores em diversas áreas, como em Cachoeira Dourada (0,92), Rio Mututi (0,95) e Barragem Arroio Duro (0,94), mantendo

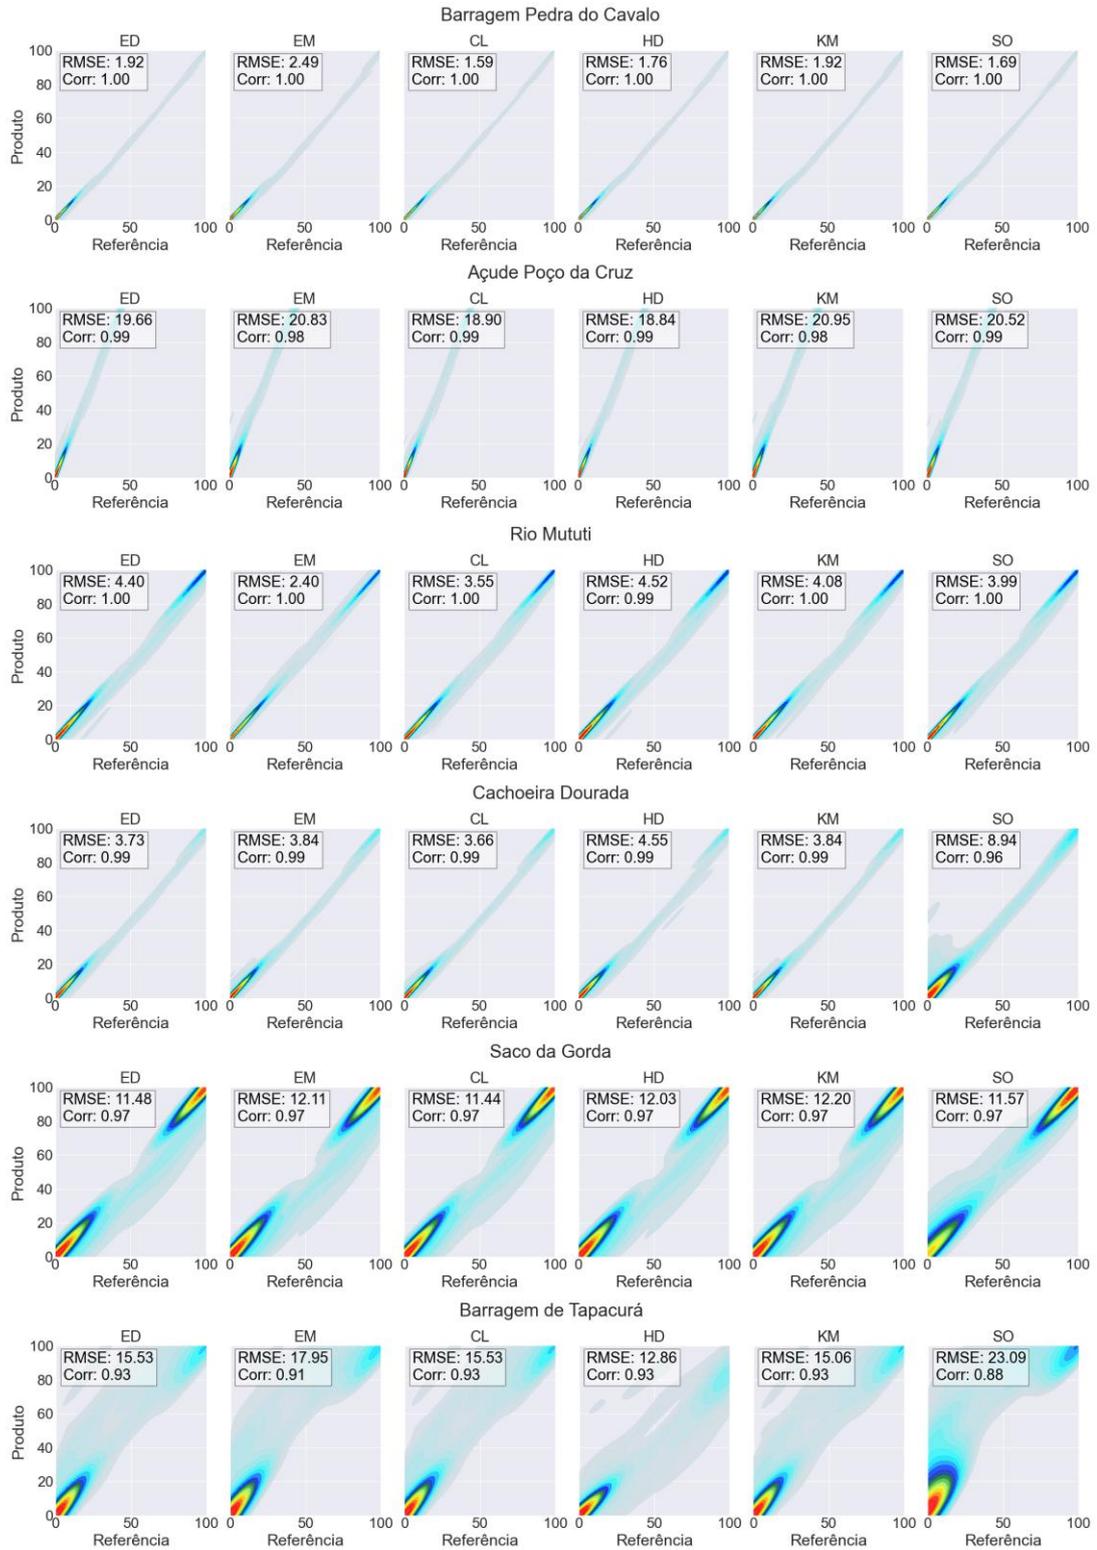
desempenho estável. Da mesma forma, CL e KM também obtêm resultados muito próximos, com valores altos em locais como Saco da Gorda (0,94) e Rio Mututi (0,96 e 0,95, respectivamente). Por outro lado, o classificador SOM mostra maior instabilidade, com valores significativamente mais baixos em regiões como Cachoeira Dourada (0,82) e, especialmente, Barragem de Tapacurá (0,51), o que reforça seu fraco desempenho já apontado em análises anteriores. A performance de HD também é irregular: embora apresente bons valores em alguns locais, como Barragem Pedra do Cavalo (0,91), apresenta quedas acentuadas em outros, como Barragem Arroio Duro (0,70) e Barragem de Tapacurá (0,54). A região de Barragem de Tapacurá é, de forma geral, a que apresenta os menores valores de recall entre todos os classificadores. Em síntese, os classificadores ED, CL e KM demonstram maior robustez e precisão na identificação de corpos hídricos, enquanto SOM e HD apresentam maior variabilidade e menor confiabilidade (Tabela 3).

A Figura 10 apresenta gráficos de dispersão entre os valores de área de referência e os valores estimados (produto) pelos diferentes classificadores para diversos corpos hídricos, acompanhados das métricas RMSE (Root Mean Square Error) e correlação de Pearson (Corr.). De maneira geral, os resultados apontam um alto grau de correlação (acima de 0,97 na maioria dos casos) entre os dados de referência e os valores estimados, dessa forma, a análise reforça que os classificadores ED, EM, CL e KM são mais confiáveis e precisos na estimativa da área de corpos hídricos, enquanto o SOM apresenta desempenho mais instável.

Observando os valores de RMSE, que indicam a magnitude dos erros entre as estimativas e os dados reais, o classificador CL obteve o menor erro na maioria das localidades, destacando-se na Barragem Pedra do Cavalo (1,59), Açude de Poço da Cruz (18,9), Rio Mututi (3,55) e Saco Gorda (11,44). O Autoencoder (ED) também apresentou desempenho competitivo, com o menor RMSE em Saco Gorda (11,48) e valores próximos aos de CL em outras barragens. Por outro lado, o método Self-Organizing Maps (SO) teve o pior desempenho em várias localidades, especialmente na Cachoeira Dourada (8,94) e na Barragem de Tapacurá (23,09), indicando maior inconsistência nas estimativas (Figura 7).

Quanto à correlação, que mede a relação linear entre as previsões e os dados reais, todos os classificadores apresentaram valores altos (acima de 0,93) na maioria dos locais, exceto na Barragem de Tapacurá, onde SO obteve a menor correlação (0,88). Os métodos ED, CL e KM mantiveram correlações consistentemente altas (0,99 ou 1) na maioria dos casos, reforçando sua confiabilidade. O HDBSCAN (HD) também apresentou bons resultados, mas com um desempenho ligeiramente inferior ao CL e ED em algumas localidades.

Figura 7 – Gráficos scatterplot das proporções de células rotuladas como água pelos classificadores plotados em relação à proporção rotulada como água pelo conjunto de dados de referência.



Fonte: Autor (2025).

Em síntese, o CLARA (CL) se destacou como o classificador mais preciso e consistente, combinando baixos valores de RMSE com altas correlações. O Autoencoder (ED) e o K-means

(KM) também foram robustos, enquanto o Self-Organizing Maps (SO) apresentou maior variabilidade e erros mais elevados. Portanto, para aplicações que demandam alta precisão na detecção de corpos hídricos, os classificadores CL, ED e KM são os mais recomendados com base nos resultados obtidos.

A análise dos valores de Acurácia Global (%) mostradas na Tabela 2, indica uma performance geralmente elevada para todos os classificadores, com destaque para ED, CL e HD. De forma geral, os classificadores ED, CL, KM e HD mantêm uma acurácia superior a 95% em todos os corpos hídricos, com variações discretas entre eles. Os classificadores CL e ED se destacam levemente por apresentarem resultados consistentemente altos e equilibrados, alcançando, por exemplo, 99,23% na Barragem Pedra do Cavalo, e 98,71% em Cachoeira Dourada.

Tabela 2 – Estimativas de Acurácia Global (%)

Classificador	Barragem Pedra do Cavalo	Açude Poço da Cruz	Saco da Gorda	Cachoeira Dourada	Rio Mututi	Barragem Arroio Duro	Barragem de Tapacurá
ED	99,1	98,17	95,92	98,71	98,11	97,07	96,28
EM	98,95	96,65	95,64	98,5	98,75	94,45	95,32
CL	99,23	98,06	95,94	98,59	98,47	97,07	96,28
HD	99,17	98,11	95,68	98,24	98,06	91,56	95,31
KM	99,16	96,51	95,61	98,5	98,25	97,03	96,36
SO	99,18	97,02	94,07	96,74	98,29	95,33	87,97

Fonte: Autor (2025).

O classificador EM, embora ainda bastante eficiente, apresentou valores ligeiramente mais baixos em algumas áreas específicas, como no Açude Poço da Cruz (96,65%) e na Barragem de Tapacurá (95,32%) (Tabela 2). Já o HD (HDBSCAN) apresenta boa acurácia na maior parte dos locais, mas sofre um forte decréscimo em Arroio Duro (91,56%), o que está de acordo com as análises anteriores de instabilidade do método em áreas com espectro mais confuso ou transições suaves entre as classes. O classificador SOM, apesar de alcançar valores elevados em algumas regiões (como 99,18% em Pedra do Cavalo), tem queda acentuada em locais como a Barragem de Tapacurá (87,97%) e Saco da Gorda (94,07%). Os classificadores apresentaram altos valores médios de acurácia global, mas com pequenas variações entre si, variando entre 95~98%, sendo as melhores estimativas foram vistas para o ED (97,62%), CL (97,66%) e KM (97,35) enquanto o SOM apresentou uma média um pouco menor, porém a mais baixa de todos, chegando a (95,51%).

O classificador ED apresentou segmentações bem definidas e se destacou como um algoritmo eficiente na detecção de corpos hídricos em imagens SAR. Neste estudo, seu

desempenho foi consistente, corroborando os achados de Zhang et al. (2024), que utilizaram o mesmo modelo para extrair corpos d'água na bacia do rio Weihe, na China, entre 2013 e 2021. Os resultados demonstraram que o ED é altamente eficaz mesmo em cenários complexos e possui grande potencial para análise em séries temporais longas e em larga escala. Adicionalmente, Yuan et al. (2023) reportaram uma acurácia global de 95,21% e um recall de 0,91 ao aplicar o ED para extração de fluxos de água na China usando dados híbridos do Sentinel-1. Os autores também revelaram que o método implementado utilizou o classificador de codificação ED, reduz significativamente a carga de trabalho da rotulagem manual e melhora a eficiência da geração de rótulos. Por outro lado, este método também melhora a precisão e a consistência da geração de rótulos, uma vez que algoritmos de aprendizado de máquina são capazes de manter dados consistentes melhor do que humanos. Portanto, este avanço tem implicações de longo alcance para projetos de detecção de corpos d'água em larga escala ou em tempo real, especialmente quando grandes quantidades de dados de imagens SAR precisam ser processadas (Xie et al. 2023).

Já Sun et al. (2024) obtiveram acurácia de 95,58% e recall de 0,95 em imagens de alta resolução. Tais evidências reforçam que o ED, por ser um modelo supervisionado baseado em aprendizado profundo, é capaz de aprender representações espaciais complexas e generalizar bem para diferentes tipos de imagem, em especial as de alta textura como as SAR. Seu desempenho estável neste estudo, com coeficientes de Dice-Sørensen entre 97%~99% e recall entre 0,74–0,95, indica sua robustez e capacidade de reconhecer padrões específicos da classe “água”, mesmo em ambientes heterogêneos.

O algoritmo EM, por sua vez, demonstrou bom desempenho ao lidar com incertezas e ajustar iterativamente os agrupamentos, sendo mais preciso em regiões com limites difusos. Nesta pesquisa, apresentou erros médios de omissão e comissão de aproximadamente 5% e 10%, respectivamente, com acurácia global variando entre 94% e 99%. Seu comportamento foi estável em regiões como Saco da Gorda e Barragem Pedra do Cavalo, mas apresentou superestimções notáveis em Cachoeira Dourada, Barragem Arroio Duro e Açude Poço da Cruz. Esses desvios podem estar relacionados a variações topográficas e superfícies lisas (como pastagens e solos expostos) que confundem o modelo ao redor dos corpos hídricos.

Os classificadores CLARA e K-means, ambos métodos clássicos baseados em distância, demonstraram desempenho eficiente principalmente em ambientes com bom contraste espectral entre água e outras classes. O K-means mostrou-se particularmente consistente em regiões homogêneas, sendo favorecido por corpos d'água bem delimitados. No geral, ambos apresentaram coeficientes de Dice entre 0,72–0,85 e acurácias entre 96–98%. Nas análises

quantitativas, o RMSE médio foi de 9,11 para o CLARA e 9,67 para o K-means, com coeficiente de correlação variando de 0,97 a 1, o que demonstra uma correspondência forte com os dados de referência. Estudos prévios reforçam esses resultados: Marzi e Gamba (2021) obtiveram acurácias superiores a 94% com o K-means em imagens Sentinel-1 na Lombardia (Itália), e Xie et al. (2023) relataram precisão e recall de 97,22% e 0,97, respectivamente, no Lago Dongting (China). Rani et al. (2024) também confirmaram a eficiência do método com acurácias entre 92% e 99% em diversos corpos d'água na Índia. Por outro lado, esses autores revelaram que apesar dos altos valores de precisão, os métodos de classificação foram testados principalmente em cenários simples e pode exigir validação adicional em cenários mais complexos. Outro ponto em que esses autores ressaltam é que o conjunto de dados é relativamente pequeno, o que pode afetar a capacidade de generalização do modelo. Além disso, embora o método neste artigo reduza a carga de trabalho de rotulagem manual, ele ainda requer certos recursos computacionais para executar o K-means e o treinamento de modelos de aprendizado profundo.

O classificador SOM, apesar de apresentar acurácia global média em torno de 95%, ficou aquém dos demais métodos. Embora tenha demonstrado baixo erro de omissão (cerca de 3%), apresentou alto erro de comissão (próximo a 17%), o que indica superestimação significativa da classe “água” nos arredores dos corpos hídricos. Como uma rede neural não supervisionada que projeta dados em grades bidimensionais, o SOM é sensível à complexidade espectral e variações de fundo, o que explica sua instabilidade visual e os altos valores de RMSE, especialmente em regiões como a Barragem de Tapacurá e Arroio Duro, onde há presença de solo exposto e superfícies lisas com comportamento espectral semelhante à água. No entanto, obteve desempenho mais satisfatório em áreas com menor variabilidade local e boa separabilidade espectral, como em Saco da Gorda e no Rio Mututi.

Por fim, o classificador HD (HDBSCAN) apresentou o comportamento mais instável entre os avaliados, sendo sensível à complexidade espacial. Registrou a maior taxa de erro de omissão médio (cerca de 14%) e o menor recall médio (0,82), em comparação com os demais que se mantiveram acima de 0,84. Embora tenha mostrado bom desempenho em áreas homogêneas como o Rio Mututi e Saco da Gorda, teve dificuldades em regiões mais complexas como Tapacurá e Cachoeira Dourada. Isso pode ser atribuído à forma como o HD define densidades locais: em áreas com transições suaves entre água e não-água, ele pode fragmentar ou eliminar partes válidas por considerar baixa densidade. Em ambientes com ruído espectral sutil, os clusters gerados tendem a ser imprecisos, resultando em perda de continuidade dos corpos hídricos. Assim, apesar de seu potencial, o HD requer ajustes finos em seus parâmetros

e tende a ser menos robusto que métodos mais simples e determinísticos como o K-means, ou que supervisionados como o ED.

5 CONCLUSÕES

Este estudo propõe um novo índice espectral para detecção de corpos d'água utilizando dados SAR do Sentinel-1, denominado SEWI (SAR-based Enhanced Water Index). O índice combina informações das polarizações VV e VH com o objetivo de classificar de forma eficaz áreas de corpo d'água e não corpo d'água, explorando as diferentes características de retroespalhamento de cada polarização. Essa abordagem permite realçar melhor as informações hídricas nas imagens, possibilitando uma delimitação mais rápida e precisa da distribuição dos corpos d'água, sem a interferência de nuvens — um problema comum em sensores ópticos passivos. Os resultados demonstram que o SEWI possui um bom desempenho na identificação de pixels de água: nas imagens processadas, os corpos hídricos aparecem com tons claros (altos valores de pixel), enquanto áreas terrestres são representadas por pixels escuros (baixos valores). O índice aproveita a alta discrepância no sinal de retroespalhamento entre a água e as superfícies terrestres para extrair corpos d'água com alta precisão em diversos contextos hidrológicos no Brasil, especialmente quando combinado com algoritmos de classificação supervisionada.

Quando utilizado como base para os algoritmos de detecção de mudanças, o SEWI foi eficaz na extração automática e precisa da amplitude da água. Isso indica que o índice pode ser empregado como uma ferramenta confiável no monitoramento de águas superficiais, fornecendo dados relevantes para estudos espaciais relacionados à variação da superfície hídrica. Além disso, ele permite mapear com precisão a distribuição regional dos corpos d'água e elaborar planos de gestão de recursos hídricos de longo prazo. Sua aplicação também contribui para estatísticas ambientais e para a compreensão da resposta dos corpos hídricos às mudanças climáticas, viabilizando monitoramentos semanais — uma melhoria significativa frente ao atual monitoramento anual conduzido por instituições públicas — e aumentando a precisão espacial quando associado a técnicas de aprendizado profundo, com altos índices de desempenho estatístico.

No estudo, algoritmos automatizados foram aplicados para classificar pixels de água e não água em diferentes corpos hídricos brasileiros, utilizando os dados SAR do Sentinel-1 e o índice SEWI. Os mapas resultantes seguiram padrões coerentes, com erros de omissão inferiores a 20%, exceto nos casos do algoritmo HDBSCAN na Barragem Arroio Duro e no

Rio Tapacurá. Nos demais corpos d'água, os mapas mostraram alta correspondência com os dados de referência, apresentando erros de comissão abaixo de 23%, com exceção do Rio Tapacurá, onde todos os algoritmos apresentaram maiores taxas de erro. A Barragem Pedra do Cavalo e o Rio Mututi alcançaram acurácia global superior a 98% em todos os algoritmos, o que pode estar relacionado à baixa heterogeneidade de cobertura terrestre no entorno (vegetação de baixo porte e floresta amazônica densa, respectivamente) e à pouca interferência de elementos subaquáticos como vegetação ou areia. Em contraste, o Rio Tapacurá apresentou os piores desempenhos nas métricas avaliadas, devido à sua topografia irregular e ao uso do solo diversificado, composto por fragmentos de floresta e culturas de superfície lisa, o que dificultou a correta classificação pelos algoritmos e levou a superestimações, apesar dos baixos índices de omissão.

De maneira geral, todos os algoritmos apresentaram alta acurácia global, acima de 90%, exceto o SOM no Rio Tapacurá, que obteve 87,97%. Os melhores desempenhos foram registrados pelos algoritmos CLARA, Auto-Encoder e K-médias. O algoritmo EM apresentou resultados intermediários, enquanto HDBSCAN e SOM tiveram os menores desempenhos. Apesar do bom rendimento do CLARA e Auto-Encoder, ambos exigem conhecimento prévio em programação, o que pode limitar seu uso por operadores sem familiaridade com técnicas computacionais. O K-médias, por outro lado, é amplamente utilizado na literatura e está disponível em grande parte dos softwares de geoprocessamento. Já o HDBSCAN, embora eficaz, requer elevado consumo de memória e processamento, o que representa uma limitação, especialmente em classificações multiclasse. O SOM, apesar de também depender de programação, apresenta rápida execução e não demanda recursos computacionais adicionais.

REFERÊNCIAS

ANSITH, S.; BINI, A. A. Land use classification of high resolution remote sensing images using an encoder based modified GAN architecture. **Displays**, p. 102229, 2022.

BRERETON, R. G. Contingency tables, confusion matrices, classifiers and quality of prediction. **Journal of Chemometrics**, v. 35, n. 11, 2021.

CHE, L.; LI, S.; LIU, X. Improved surface water mapping using satellite remote sensing imagery based on optimization of the Otsu threshold and effective selection of remote-sensing water index. **Journal of Hydrology**, p. 132771, 2025. Elsevier. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S002216942500109X>>.

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

DEVI, N. B.; KAVIDA, A. C. Pre-processing on remotely sensed data with unsupervised classification analysis. **Journal of Ambient Intelligence and Humanized Computing**. 2020.

DOAN, Q.-V.; KUSAKA, H.; SATO, T.; CHEN, F. S-SOM v1.0: a structural self-organizing map algorithm for weather typing. **Geoscientific Model Development**, v. 14, n. 4, p. 2097–2111, 2021. Copernicus Publications.

DU, Q.; LI, G.; CHEN, D.; et al. Extracting water body data based on SDWI and threshold segmentation: A case study in permafrost area surrounding Salt Lake in Hoh Xil, Qinghai-Tibet Plateau, China. **Research in Cold and Arid Regions**, v. 15, n. 4, p. 202–209, 2023. Elsevier. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2097158323000460?via%3Dihub>>.

FILIPPONI, F. Sentinel-1 GRD Preprocessing Workflow. **Proceedings**, v. 18, n. 1, p. 11, 2019.

GAO, C. X.; DOMINIC, D.; YE, Z.; CATHERINE L., S. An overview of clustering methods with guidelines for application in mental health research. **Psychiatry Research**, v. 327, p. 115265, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0165178123002159?ref=pdf_download&fr=RR-2&rr=80c4792e0cc313df>.

GHARAHBAGH, A. A.; HAJIHASHEMI, V.; MACHADO, J. J. M.; TAVARES, J. M. R. S. Land Cover Classification Model Using Multispectral Satellite Images Based on a Deep Learning Synergistic Semantic Segmentation Network. **Sensors**, v. 25, n. 7, p. 1988, 2025. MDPI AG. Disponível em: <<https://www.mdpi.com/1424-8220/25/7/1988>>. Acesso em: 3/5/2025.

GIGLIO, L.; BOSCHETTI, L.; ROY, D. P.; HUMBER, M. L.; JUSTICE, C. O. The Collection 6 MODIS burned area mapping algorithm and product. **Remote Sensing of Environment**, v. 217, p. 72–85, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0034425718303705>>.

GUO, Z.; WU, L.; HUANG, Y.; et al. Water-Body Segmentation for SAR Images: Past, Current, and Future. **Remote Sensing**, v. 14, n. 7, p. 1752, 2022. HAN, C.; JIA, C.; SUN, Y. Remote Sensing Monitoring and Disaster Assessment of Flood Based on Sentinel-1B Sar Data. **IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium**, 2022.

JIANG, X.; ZENG, Z. Empowering multi-source SAR flood mapping with unsupervised learning. **Environmental Research Letters**, 2024. IOP Publishing.

KHOSLA, M.; JAMISON, K.; NGO, G. H.; KUCEYESKI, A.; SABUNCU, M. R. Machine learning in resting-state fMRI analysis. **Magnetic Resonance Imaging**, v. 64, p. 101–121, 2019.

KSEŇAK, Ľ.; PUKANSKÁ, K.; BARTOŠ, K.; BLIŠŤAN, P. Assessment of the Usability of SAR and Optical Satellite Data for Monitoring Spatio-Temporal Changes in Surface Water: Bodrog River Case Study. **Water**, v. 14, n. 3, p. 299, 2022.

LI, Xiyao; LI, Jiayi; JIANG, Jie; PAN, Xiaofeng; HUANG, Xin. Spatio-temporal-text fusion for hierarchical multi-label crop classification based on time-series remote sensing imagery. *International Journal Of Applied Earth Observation And Geoinformation*, [S.L.], v. 139, p. 104471, maio 2025. Elsevier BV. <http://dx.doi.org/10.1016/j.jag.2025.104471>.

LIBONATI, R.; DACAMARA, C.; SETZER, A.; MORELLI, F.; MELCHIORI, A. An Algorithm for Burned Area Detection in the Brazilian Cerrado Using 4 μ m MODIS Imagery. **Remote Sensing**, v. 7, n. 11, p. 15782–15803, 2015.

LYU, X.; JIANG, W.; LI, X.; et al. MSAFNet: Multiscale Successive Attention Fusion Network for Water Body Extraction of Remote Sensing Images. **Remote Sensing**, v. 15, n. 12, p. 3121–3121, 2023. Multidisciplinary Digital Publishing Institute.

MARZI, D.; GAMBA, P. Inland Water Body Mapping Using Multitemporal Sentinel-1 SAR Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 14, p. 11789–11799, 2021.

MOKARRAM, M.; PHAM, T. M. Environmental Monitoring of Oil Pollution in the Marine Waters using Machine Learning and Remote Sensing. **Advances in Space Research**, 2025. Elsevier BV.

NICOLLIER, V.; KIPERSTOK, A.; BERNARDES, M. E. C. A governança das águas no Brasil: qual o papel dos municípios? **Estudos Avançados**, v. 37, p. 279–302, 2023. Disponível em: <<https://www.scielo.br/j/ea/a/SVDPHh74bVQJRpf86M4mfYp/>>.

OS. YILMAZ; FATİH GÜLGEN; FÜSUN BALIK ŞANLI; ATEŞ, A. The Performance Analysis of Different Water Indices and Algorithms Using Sentinel-2 and Landsat-8 Images in Determining Water Surface: Demirkopru Dam Case Study. **Arabian Journal for Science and Engineering**, v. 48, n. 6, p. 7883–7903, 2023. Springer Science+Business Media.

PEIXOTO, F. DA S.; SOARES, J. A.; RIBEIRO, V. S. Conflitos pela água no Brasil. **Sociedade & Natureza**, v. 34, n. 1, 2021. Disponível em: <<https://seer.ufu.br/index.php/sociedadnatureza/article/download/59410/32985/277538>>.

PEÑA, F. J.; HÜBINGER, C.; PAYBERAH, A. H.; JARAMILLO, F. DeepAqua: Semantic segmentation of wetland water surfaces with SAR imagery using deep neural networks without manually annotated data. **International Journal of Applied Earth Observation and Geoinformation**, v. 126, p. 103624, 2024. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S156984322300448X>>. Acesso em: 29/2/2024.

POLINA LEMENKOVA; OLIVIER DEBEIR. R Libraries for Remote Sensing Data Classification by K-Means Clustering and NDVI Computation in Congo River Basin, DRC. **Applied sciences**, v. 12, n. 24, p. 12554–12554, 2022. Multidisciplinary Digital Publishing Institute. Acesso em: 4/1/2024.

RAJESWARI, S.; RATHIKA, P. Emerging methodologies in waterbody delineation: an In-depth review. **International Journal of Remote Sensing**, v. 45, n. 17, p. 5789–5819, 2024. Acesso em: 6/2/2025.

RANI, R.; GUPTA, C.; PATRA, T. K.; SINGH, R. Water and Land Surface Detection from Sentinel C band Dual Polarimetric SAR Satellite Imagery. **IEEE International Conference On Interdisciplinary Approaches In Technology And Management For Social Innovation (Iatmsi)**, p. 1–6, 2024. Acesso em: 3/5/2025.

SHEN, G.; FU, W.; GUO, H.; LIAO, J. Water Body Mapping Using Long Time Series Sentinel-1 SAR Data in Poyang Lake. **Water (Switzerland)**, v. 14, n. 12, p. undefined–undefined, 2022. Disponível em: <<https://www.mendeley.com/catalogue/1f006e08-fa62-388c-bf46-6a454811e0b1>>.

SUN, D.; GAO, G.; HUANG, L.; LIU, Y.; LIU, D. Extraction of water bodies from high-resolution remote sensing imagery based on a deep semantic segmentation network. **Scientific Reports**, v. 14, n. 1, 2024. Nature Portfolio.

TIAN, B.; ZHANG, F.; LANG, F.; et al. A Novel Water Index Fusing SAR and Optical Imagery (SOWI). **Remote Sensing**, v. 14, n. 21, p. 5316, 2022. MDPI AG. Disponível em: <<https://www.mdpi.com/2072-4292/14/21/5316>>. Acesso em: 3/4/2025.

TIAN, H.; LI, W.; WU, M.; et al. Dynamic Monitoring of the Largest Freshwater Lake in China Using a New Water Index Derived from High Spatiotemporal Resolution Sentinel-1A Data. **Remote Sensing**, v. 9, n. 6, p. 521, 2017.

WANG, Y.; HERNÁNDEZ, H. H.; ALBRECHT, C. M.; ZHU, X. X. Feature Guided Masked Autoencoder for Self-supervised Learning in Remote Sensing. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, p. 1–17, 2024. Institute of Electrical and Electronics Engineers. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/10766851>>. Acesso em: 5/5/2025. XIE, Y.;

WU, D.; QIANG, Z. An Improved Mixture Model of Gaussian Processes and Its Classification Expectation–Maximization Algorithm. **Mathematics**, v. 11, n. 10, p. 2251–2251, 2023. Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/2227-7390/11/10/2251>>.

XIE, Y.; ZENG, H.; YANG, K.; YUAN, Q.; YANG, C. Water-Body Detection in Sentinel-1 SAR Images with DK-CO Network. **Electronics**, v. 12, n. 14, p. 3163–3163, 2023. Multidisciplinary Digital Publishing Institute.

YADAV, R.; NASCETTI, A.; AZIZPOUR, H.; BAN, Y. Unsupervised flood detection on SAR time series using variational autoencoder. **International Journal of Applied Earth Observation and Geoinformation**, v. 126, p. 103635, 2024. Disponível em: <<https://arxiv.org/pdf/2212.03675.pdf>>.

YUAN, Q.; WU, L.; HUANG, Y.; GUO, Z.; LI, N. Water-Body Detection From Spaceborne SAR Images With DBO-CNN. **IEEE Geoscience and Remote Sensing Letters**, v. 20, p. 1–5, 2023. Institute of Electrical and Electronics Engineers (IEEE). Acesso em: 3/5/2025.

ZHANG, T.; JI, W.; LI, W.; et al. EDWNet: A Novel Encoder–Decoder Architecture Network for Water Body Extraction from Optical Images. **Remote Sensing**, v. 16, n. 22, p. 4275–4275, 2024. Multidisciplinary Digital Publishing Institute.

ZHENG, Y.; WEN, D.; SAREM, M. A novel NAM-based image segmentation using hierarchical density-based spatial clustering. **IET Image Processing**, v. 18, n. 5, p. 1245–1257, 2024. Institution of Engineering and Technology. Acesso em: 3/5/2025.

4 ARTIGO 2 – ANÁLISE DE TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS SAR PARA EXTRAÇÃO DE ÁGUA EM DIFERENTES CORPOS HÍDRICOS DO BRASIL

RESUMO

Este artigo avalia a precisão de classificadores supervisionados, Random Forest (RF) e Redes Neurais Artificiais (ANN), na extração de corpos hídricos utilizando o índice SAR Enhanced Water Index (SEWI), combinado com técnicas de textura (GLCM) e redução de dimensionalidade (PCA). O estudo abrange dezesseis áreas representativas no Brasil, analisando imagens SAR do Sentinel-1. Os resultados demonstram que o SEWI é eficaz na distinção entre água e não água, com alta separabilidade estatística (valores JM próximos de 2). A primeira componente principal (PC1) e a textura GLCM também apresentaram desempenho satisfatório, embora o GLCM tenha mostrado limitações em regiões com ruído ou texturas complexas. Os classificadores RF e ANN alcançaram acurácias globais superiores a 90%, com desempenhos similares, indicando que a escolha entre eles pode ser baseada em critérios secundários, como eficiência computacional. A morfologia dos corpos hídricos e o entorno influenciaram nos resultados: áreas homogêneas, como as lagoas do Pantanal, tiveram melhor detecção, enquanto regiões urbanizadas ou com corpos menores apresentaram desafios, como superestimação ou omissão de pixels. A metodologia destaca-se pela adaptabilidade a diferentes contextos ambientais e pela eficiência na integração de dados de sensoriamento remoto. O método mostrou-se robusto para mapeamento em larga escala, com potencial para monitoramento contínuo de recursos hídricos. Conclui-se que a combinação de SEWI, SEWI+GLCM e SEWI+PCA com classificadores de aprendizado de máquina é uma abordagem promissora para a extração precisa de águas superficiais, contribuindo para a gestão sustentável dos recursos hídricos no Brasil.

Palavras-chave: SEWI, GLCM, PCA, Random Forest, Redes Neurais Artificiais, sensoriamento remoto.

1 INTRODUÇÃO

O Brasil abriga cerca de 12% da água doce superficial do planeta e aproximadamente 70%. No entanto, essa abundância hídrica não é sinônimo de distribuição equilibrada. A extensão territorial e a diversidade climática resultam em uma oferta desigual, agravada pela concentração populacional em determinadas regiões, o que pode gerar escassez tanto em quantidade quanto em qualidade (Qin et al. 2024). Nesse cenário, o monitoramento eficaz dos corpos hídricos torna-se essencial, e o Sensoriamento Remoto por radar desponta como uma ferramenta estratégica. Essa tecnologia permite o acompanhamento contínuo e preciso de rios,

reservatórios e áreas alagadas, independentemente das condições climáticas ou de iluminação, o que é crucial em um país de dimensões continentais e forte sazonalidade como o Brasil. Além disso, a água é recurso vital para atividades-chave da economia brasileira, como a irrigação (69% do uso), a geração de energia hidrelétrica (quase 80% da matriz elétrica), e a aquicultura, favorecida pelos 8.500 km de costa e vastas áreas alagadas (Alonso-Sarria; Valdivieso-Ros e Molina-Pérez, 2025). A gestão descentralizada e participativa dos recursos hídricos, centrada nas bacias hidrográficas, é reforçada por dados confiáveis obtidos por satélites, que auxiliam na tomada de decisões sustentáveis, na prevenção de conflitos e na proteção desse bem público essencial. O Sensoriamento Remoto, portanto, é aliado indispensável à governança hídrica no Brasil (Jin et al. 2021; Qin et al. 2025).

A utilização de imagens de radar de abertura sintética (SAR), caracterizadas por suas capacidades de penetração em nuvens e em todas as condições climáticas, possui valor de aplicação significativo para a detecção de águas superficiais. Aproveitando os resultados de detecção de água obtidos, é possível obter insights oportunos sobre mudanças nas condições de inundação, ambientes aquáticos, linhas costeiras e proteção ambiental (Kubendiran e Ramaiah, 2024). Conseqüentemente, isso fornece informações e orientações vitais para a prevenção, mitigação e resgate de desastres nacionais, bem como para o planejamento abrangente do desenvolvimento (Gao et al. 2025).

Técnicas de sensoriamento remoto baseadas em imagens para extração de corpos d'água pode ser amplamente categorizadas em dois grupos principais: baseadas em índices espectrais e baseadas em classificação de imagens. O método baseado em somente índices espectrais depende das características únicas de refletância espectral de corpos d'água no momento do imageamento. O método de limiarização em índices espectrais é amplamente utilizado, método que consiste no valor de limiar único (Schlaffer et al. 2022). No entanto, os resultados podem ser menos eficazes quando ocorrem perturbações nas imagens relacionadas a diferentes dados de sensores e da complexidade das características da superfície, sua precisão e capacidade de retenção de detalhes podem ser desafiadas e normalmente causam superestimções. Outra desvantagem é que uma distribuição bimodal característica não é mostrada se a água ocupa uma pequena fração da imagem (Pech-May et al. 2023; Qin et al. 2024).

Métodos baseados em aprendizado de máquinas demonstraram poderosas capacidades automáticas de aprendizado e reconhecimento de características. Eles não precisam predefinir regras complexas de classificação, mas podem descobrir autonomamente as características de nível profundo de corpos d'água a partir de dados massivos e otimizar continuamente a representação dessas características por meio do treinamento de modelos, demonstrando assim

vantagens significativas na precisão da extração e generalização. O aprendizado profundo utiliza redes neurais para aprender informações de alta dimensão e multiescala, como cor, textura, tamanho e posição de objetos-alvo, formando modelos de extração para diferentes objetos (Song et al. 2025).

Li et al. (2021) propuseram um método de extração de corpos d'água de lagos pela fusão de dados Sentinel-1/2 na China, utilizando algoritmo SVM. Os autores obtiveram uma precisão geral da extração de água lacustre foi aprimorada em 3% e o erro de comissão e omissão foi controlado em até 6%. Bhadra et al. (2020) propuseram a detecção de corpos hídricos em tempo real utilizando imagens multiespectrais, SAR e técnica de aprendizado profundo Rede Neural Convolutacional (CNN). A CNN obteve um bom desempenho com precisão de 80% na detecção de corpos d'água. Li et al. (2023) utilizaram os algoritmos de árvore de decisão, floresta aleatória e U-Net aprimorado para extração de corpos d'água do Lago Poyang, China como estudo de caso e imagens SAR Sentinel-1 e atingiram precisão geral de 98,71% e um coeficiente Kappa de 0,97. Gao et al. (2025) indicaram que o uso de classificadores baseado em redes neurais artificiais pode extrair bordas de água mais integrais e características mais detalhadas, aprimorando a precisão e a generalização da extração de corpos d'água usando imagens SAR, em que obtiveram valores de Acurácia do Produtor (PA) e Intersecção sobre União (IoU) para extração de água são 95,24% e 91,63%, respectivamente.

Esses estudos mostram que as ferramentas de classificação superam os métodos de limiarização de banda única e multibanda para extração de água. Com base nessas descobertas, alguns pesquisadores combinaram dados de Sensoriamento Remoto SAR, usando classificadores para extração de água. Comparado aos métodos de índice espectral, o aprendizado de máquina alcança melhores resultados de extração de corpos d'água e a combinação desses métodos pode gerar ainda melhores resultados. No entanto, a literatura também destaca questões como dependência da amostra, suscetibilidade a sombras de montanhas e baixa transferibilidade. Em conclusão, os métodos baseados em pixels ainda enfrentam desafios para abordar o problema de similaridade espectral (Engram et al. 2024; Pech-May et al. 2023).

Com a finalidade de reduzir esses problemas, principalmente evidenciadas nas imagens SAR que possuem ruído e características espectrais limitadas em alguns aspectos, técnicas de textura e dimensionamento com a Análise de Componentes Principais (PCA) podem ser aplicadas. Como as imagens Sentinel-1 têm a maior resolução espacial e as características texturais mais ricas, os métodos de extração de água superficial com base em informações de textura têm sido extensivamente investigados quando comparados aos algoritmos tradicionais

de segmentação de limiar. Entre eles, a matriz de co-ocorrência de níveis de cinza (GLCM) é o método mais amplamente utilizado para descrever características texturais. Yu et al. (2022) combinaram o coeficiente de retrodispersão das imagens Sentinel-1 e cinco características GLCM para extrair informações de água superficial, o que demonstrou o alto potencial das imagens SAR Sentinel-1 em aplicações de extração de água de longo prazo. Kajári et al. (2024) incorporaram o parâmetro de textura da GLCM-média e o classificador XGBoost para extrair água superficial. A abordagem permitiu distinguir água superficial com maior precisão e auxiliou na detecção de água altamente dinâmica em comparação com métodos de limiar tradicionais. Eles também demonstraram que o efeito do ruído speckle em imagens SAR pode ser suprimido e os resultados da classificação foram aprimorados pela combinação de características texturais GLCM.

Nesse mesmo contexto, Tavus et al. (2022) utilizaram informações texturais obtidas do GLCM e as bandas de análise de componentes principais (PCA) foram empregadas no método RF para extrair corpos d'água após o rompimento da barragem de Sardoba, os autores mostraram que a fusão de dados S1 e S2 exibe precisão de classificação muito alta para as áreas inundadas e pode separar também a vegetação inundada. Apesar do bom desempenho dos produtos híbridos GLCM e PCA para detecção e corpos hídricos, alguns autores relatam que a combinação dos métodos pode realçar esse ruído em águas com matérias orgânica e em suspensão e em regiões texturalmente não uniformes, portanto, estudos e investigações nestas abordagens são válidos para compreender e mitigar problemas.

Assim, esta pesquisa tem como objetivo a implementação de um método para extração de águas superficiais através do cálculo de características baseadas na implementação do índice espectral de água SAR, combinado com métodos SEWI+GLCM e SEW+PCA com modelos de classificação Random Forest e Artificial Neural Net em diferentes regiões do Brasil.

2 METODOLOGIA

2.1 Área de estudo

Estudo foram selecionados diferentes corpos hídricos do Brasil. A seleção desses corpos hídricos considerou sua morfologia, distribuição espacial homogênea, relevância para os sistemas de recursos hídricos, biodiversidade e abastecimento regional, além da influência de fatores como sazonalidade, pressões antrópicas e mudanças climáticas, que causam variações contínuas em seus espelhos d'água.



Fonte: Autor (2025).

As análises foram realizadas em dezesseis áreas representativas de diferentes corpos hídricos do Brasil em relação a análise realizada como mostrado na figura 1, para análise não supervisionada, foram o Rio Içá, o Lago do Salsa e o Rio Preto da Eva, situados no estado do Amazonas; o Rio Içu, no Rio Grande do Norte; o Açude Serrinha II, em Pernambuco; o Açude Eng. Ávidos, na Paraíba; Açude Mendubim, no Rio Grande do Norte; o Lago Paranoá, em Brasília; e um conjunto de pequenas lagoas do Bioma Pantanal, localizado no estado do Mato Grosso (Figura 1).

2.2 Dados

2.2.1. Dados SAR do Sentinel-1

A missão Sentinel-1 fornece dados de radar de abertura sintética (SAR) em banda C, com dupla polarização (VV e VH) operando a 5,405 GHz. A coleção utilizada é composta por cenas no modo Ground Range Detected (GRD), já calibradas e ortoretificadas, com resolução espacial de 10 metros (Filipponi, 2019). Para a extração de dados dos diferentes corpos hídricos, foi utilizado um mosaico de imagens do sensor SAR Sentinel-1, disponibilizado na plataforma em nuvem Google Earth Engine, correspondente ao mês de outubro de 2023. As imagens foram submetidas a um fluxo de pré-processamento que incluiu remoção de ruído térmico, calibração radiométrica e correção topográfica com o uso de diferentes modelos digitais de elevação (DEMs). Por fim, os valores corrigidos foram convertidos para decibéis (dB) por meio da escala logarítmica (Yang et al. 2025).

2.2.2. Índice de água SAR aprimorado - Enhanced SAR Water Index (SEWI)

A intensidade da retrodispersão em imagens SAR está diretamente relacionada à rugosidade da superfície dos objetos terrestres. Superfícies lisas, como corpos d'água, são dominadas pela dispersão especular, refletindo o sinal do radar para longe do sensor e resultando em uma resposta mais fraca. Em contraste, superfícies terrestres, que apresentam maior rugosidade, exibem dispersão volumétrica, retornando um sinal mais intenso ao sensor (Tian et al. 2022; Du et al. 2023; Zhai et al. 2025).

O SAR Enhanced Water Index (SEWI) é o novo método usado especificamente para extração de corpos d'água em imagens de radar. Este método foi inspirado partindo dessa premissa fundamental sobre o comportamento dos corpos hídricos em imagens SAR. Nas imagens SAR, essa diferença se traduz em valores de pixel baixos para corpos d'água, que aparecem como regiões escuras, enquanto áreas terrestres apresentam um retorno mais forte, sendo visualizadas com tons mais brilhantes ou seja, o cerne deste método reside na utilização abrangente das características de espalhamento de dados de radar de polarização dupla para aumentar a separabilidade entre um corpo d'água e outros tipos de cobertura de solo; assim, essa abordagem permite a extração eficaz do corpo d'água. O modelo do SEWI é o seguinte:

$$SEWI = \frac{1}{\left(\frac{1}{VH} + \frac{1}{VV}\right)^2} \quad (1)$$

O objetivo do SEWI é ampliar a separação entre corpos d'água e outras superfícies, explorando a característica de que os valores de pixels de água são extremamente baixos.

2.3 MÉTODOS E CLASSIFICADORES SUPERVISIONADOS

Neste estudo, foram utilizados métodos de extração de atributos baseados em textura e redução de dimensionalidade, sendo eles o GLCM (Matriz de Coocorrência de Níveis de Cinza) e a PC1 (primeira componente principal), extraídos a partir dos dados originais do Sentinel-1, compostos pelos canais VV, VH e pelo índice SEWI. Os dados processados foram classificados por algoritmos supervisionados de aprendizado de máquina, incluindo o Random Forest (RF) e o Artificial Neural Network (ANN), com o objetivo de avaliar a acurácia temática e o potencial de detecção de corpos d'água em diferentes áreas de estudo.

Foram aplicados os classificadores RF e ANN em três produtos raster — SEWI, GLCM e PC1 — gerando, assim, seis combinações distintas de entrada para os modelos. O conjunto de amostras utilizado foi empregado tanto no treinamento quanto na classificação de pixels das classes “Água” e “Não Água”, com a implementação realizada em Python, utilizando a biblioteca scikit-learn. Para o modelo ANN, foi utilizada a ferramenta MLPClassifier, enquanto para o Random Forest foi empregado o RandomForestClassifier, conforme metodologia descrita por Noi & Kappas (2017) e Melion & Legesse (2024).

A seleção das amostras foi conduzida de forma aleatória e estratificada, com base em fotointerpretação de imagens Sentinel-2 em datas próximas das imagens Sentinel-1. Ao todo, foram coletadas 1000 amostras, sendo 500 referentes à classe “Água” e 500 à classe “Não Água”. Para o treinamento dos algoritmos de classificação, 70% das amostras foram destinadas ao treinamento e 30% à validação.

2.3.1 Características do GLCM

As imagens podem ser interpretadas como uma grade de valores de cinza, onde pixels vizinhos podem formar clusters locais com intensidades semelhantes ou contrastantes. Esses clusters podem ser analisados por meio de atributos extraídos da Matriz de Coocorrência de Nível de Cinza (GLCM), que descreve a distribuição estatística da coocorrência dos valores de intensidade dos pixels em uma determinada vizinhança (Tavus, Kocaman e Gokceoglu, 2022). O cálculo dos atributos da GLCM começa com a construção de uma matriz baseada na relação espacial entre os valores dos pixels adjacentes, considerando um deslocamento específico

(distância e ângulo). Para isso, utiliza-se uma janela móvel (kernel) centrada em cada pixel da imagem, dentro da qual são analisadas as interações entre os pixels vizinhos. À medida que a janela percorre toda a imagem, diferentes matrizes de coocorrência são geradas, permitindo a extração de atributos que caracterizam a textura da imagem, como contraste, correlação, energia e homogeneidade. Esse processo é amplamente utilizado em análise de textura para segmentação de imagens, reconhecimento de padrões e aplicações em áreas como visão computacional e processamento de imagens de sensoriamento remoto (Balling, Herold e Reiche, 2022).

Diversos atributos da matriz de co-ocorrência de nível de cinza (GLCM) foram desenvolvidos para identificar e descrever padrões específicos em imagens, como a detecção de bordas e a homogeneidade dos valores de cinza. Entre eles, um dos mais utilizados é a GLCM Mean (média da GLCM), que é uma medida estatística que representa o valor médio das relações de intensidade entre pares de pixels em uma imagem, calculada a partir da matriz de co-ocorrência. Essa matriz descreve a frequência com que diferentes combinações de níveis de cinza aparecem em uma imagem, considerando uma determinada distância e direção entre os pixels (Tavus e Kocaman, 2024; Kupidura, 2019).

Para calcular a média da GLCM, é necessário considerar tanto a média das linhas (μ_i), que representa a intensidade média do pixel de referência (i), quanto a média das colunas (μ_j), que corresponde à intensidade média do pixel vizinho (j). Ambas são obtidas multiplicando cada valor da matriz normalizada de co-ocorrência ($P(i, j)$) pelo respectivo nível de cinza (i ou j) e somando todos os resultados (Tavus, Kocaman e Gokceoglu, 2022). A fórmula para a média das linhas (μ_i) é dada por:

$$\mu_i = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} i \cdot P(i, j) \quad (2)$$

Onde N é o número de níveis de cinza na imagem, e $P(i, j)$ é o valor normalizado da GLCM na posição (i, j) . De forma análoga, a média das colunas (μ_j) é calculada como:

$$\mu_j = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} j \cdot P(i, j) \quad (3)$$

Esses valores fornecem informações sobre a distribuição média das intensidades na textura da imagem. Se a média for alta, significa que há uma predominância de tons mais claros

nas relações entre pixels, enquanto uma média baixa indica tons mais escuros. Uma GLCM Mean mais alta indica uma predominância de pares de pixels com intensidades elevadas, sugerindo a presença de regiões mais brilhantes na imagem. Por outro lado, uma GLCM Mean mais baixa reflete uma maior presença de pares de pixels com intensidades reduzidas, o que pode estar associado a áreas mais homogêneas e escuras (Kupidura, 2019). Neste estudo, a GLCM Mean foi calculada em quatro direções (0°, 45°, 90° e 135°) sobre o índice SEWI, gerando um raster com os valores médios da textura GLCM. Essa medida é útil em aplicações como análise de texturas, classificação de imagens e reconhecimento de padrões, onde características estatísticas da distribuição de intensidades são importantes para diferenciar corpos hídricos.

2.3.2 Análise de Componentes Principais

Em Sensoriamento Remoto, a aplicação da Análise de Componentes Principais (PC1) baseia-se no fato de que as bandas de imagens multiespectrais e hiperespectrais costumam ser altamente correlacionadas, frequentemente contendo informações redundantes sobre os alvos de superfície. A ACP reduz essa redundância ao transformar as bandas correlacionadas em novas combinações lineares que melhor representam a variação dos valores de pixel na imagem. Ao aplicar a ACP, as bandas espectrais das imagens originais podem ser convertidas em um conjunto menor de Componentes Principais (PCs) não correlacionadas, sendo que a primeira componente principal (ACP) geralmente concentra mais de 95% da informação presente nas bandas originais (Jing, Shaohai e Xiaole, 2021). A Primeira Componente Principal (PC1) é a que retém a maior parte da variância dos dados originais, representando as características mais dominantes da imagem. No contexto de SAR, a PC1 pode enfatizar alvos principais da cena, como áreas de forte espalhamento de radar como a água aprimorando análises de complexidade computacional e melhoramento a interpretação visual de feições hídricas nas imagens (Quan et al. 2024).

A obtenção da Primeira Componente Principal (PC1) inicia-se com a organização dos dados, onde uma imagem SAR com n pixels em bandas pode ser representada por uma matriz X de dimensão $n \times m$, na qual cada linha corresponde a um pixel e cada coluna representa uma banda da imagem (Parente, Alcaras e Figliomeni, 2024).

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (4)$$

Para evitar que diferenças de escala entre as bandas influenciem o resultado, os dados são normalizados. Isso é feito subtraindo a média de cada banda da matriz original, gerando a matriz centralizada X' , dada por:

$$X' = X - \mu \quad (5)$$

onde μ representa a média de cada coluna (banda). A partir da matriz centralizada, calcula-se a matriz de covariância C , que descreve a relação estatística entre as bandas da imagem. A matriz de covariância é obtida pela equação X e tem dimensão $n \times m$, onde cada elemento indica a covariância entre duas bandas da imagem.

$$C = \frac{1}{n-1} (X')^T X' \quad (6)$$

Em seguida, realiza-se a decomposição espectral da matriz de covariância, obtendo-se seus autovalores (λ) e autovetores (v), resolvendo-se a equação característica $Cv = \lambda v$. Os autovalores representam a variância explicada por cada componente principal, enquanto os autovetores definem as direções principais dos dados. A PC1 é definida pelo autovetor correspondente ao maior autovalor, ou seja, se os autovalores forem ordenados em ordem decrescente (Jing, Shaohai e Xiaole, 2021; Quan et al. 2024).

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m, \quad (7)$$

o autovetor v_1 associado ao maior autovalor λ_1 define a primeira componente principal. Assim, a PC1 é calculada como

$$PC1 = X' v_1. \quad (8)$$

Por fim, para projetar os dados na direção da PC1 e obter uma nova imagem transformada, realiza-se a multiplicação da matriz de dados centralizados pelo autovetor principal, gerando:

$$Y_1 = X'v_1. \quad (9)$$

A matriz Y_1 contém os valores da imagem na nova base, e a primeira coluna corresponde à PC1 (Parente, Alcaras e Figliomeni, 2024). Essa componente captura a maior variabilidade presente nos dados originais, enfatizando padrões dominantes na cena SAR, como diferenças de espalhamento eletromagnético entre diferentes tipos de terreno, presença de corpos d'água.

Neste estudo, baseado nos atributos espectrais das polarizações VV e VH e o índice SEWI, a PC1 foi empregada com o objetivo de realçar os pixels correspondentes a corpos hídricos, gerando um raster da primeira componente principal (PC1). Nessa imagem, os pixels de água aparecem mais claros, enquanto os pixels de áreas não aquáticas se apresentam em tons de cinza mais escuros.

2.3.3 Análise de Separabilidade

Após a obtenção de todos os produtos raster de corpos hídricos, foi realizado um teste de separabilidade com base no conjunto de amostras, visando identificar o recurso espectral com maior capacidade de diferenciar pixels de água e não água. Para esse propósito, foi utilizada a métrica de distância de Jeffries-Matusita (JM) (equações 3 e 4).

$$J = 2(1 - e^{-B}) \quad (10)$$

$$B = \frac{1}{8} \{(m_1 - m_2)^2 \frac{2}{\sigma_1^2 + \sigma_2^2} + \frac{1}{2} \ln \left[\frac{\sigma_1^2 + \sigma_2^2}{2\sigma_1\sigma_2} \right]\} \quad (11)$$

Onde B é a distância Bhattacharya; m_i e σ_1 e σ_2 ($i = 1$ e 2 ,) representa a média e variância das classes $C1$ e $C2$, respectivamente. Essa métrica avalia o grau de separação entre duas distribuições probabilísticas, considerando suas médias e matrizes de covariância (Zhang et al., 2023). Os valores de JM variam de 0 a 2, onde valores próximos de 0 indicam baixa separabilidade, enquanto valores próximos de 2 representam alta separabilidade. Assim, o produto que apresentar o maior valor de JM será aquele com maior capacidade de detecção de água.

2.3.4 CLASSIFICADORES SUPERVISIONADOS

2.3.4.1 Random Forest (RF)

O Random Forest (RF) é um classificador de conjunto composto por múltiplas árvores de decisão geradas a partir de subconjuntos aleatórios dos dados de treinamento. A decisão final de classificação ou previsão é determinada com base na votação da maioria entre as árvores. As árvores são construídas substituindo subconjuntos das amostras de treinamento, onde cada árvore de decisão é criada de forma independente (Adugna; Xu; Fan, 2022). Em cada nó, a divisão ocorre com base em variáveis selecionadas aleatoriamente a partir do número total de preditores, conforme definido pelo parâmetro m_{try} , escolhido pelo usuário. Essa abordagem resulta na criação de árvores com alta variância e baixo viés, formando uma floresta composta por diversas árvores (n_{tree}), ou estimadores, conforme especificado. O modelo utiliza a votação majoritária das árvores para classificar novos pixels na imagem (Zhao et al., 2023; Kadam et al., 2025). Com base na definição de m_{try} como \sqrt{n} , onde n representa o número de preditores, neste estudo adotou-se ($m_{try} = 1$). Dessa forma, esse valor foi mantido constante durante as classificações. O ajuste do modelo de Random Forest (RF) foi realizado exclusivamente por meio do hiperparâmetro N_{tree} , visando identificar o modelo ideal para a classificação. Para isso, testou-se uma variedade de valores, avaliando de 1 a 50 árvores com um incremento de 10, com base nas estimativas de precisão.

2.3.4.2 Artificial Neural Net (ANN)

A classificação por Redes Neurais Artificiais (ANN) é composta por neurônios artificiais organizados em camadas interconectadas. Esses neurônios atuam como processadores de informação, recebendo entradas de outros neurônios e gerando saídas com base em uma função matemática específica. Uma das funções mais utilizadas em ANN é a sigmoide, que introduz um comportamento não linear na rede, permitindo a aprendizagem de padrões complexos nos dados (Vasilakos, Kavrouidakis e Georganta, 2020). Neste estudo, foi utilizado o algoritmo MultiLayer Perceptron (MLP), cujo treinamento é baseado na retropropagação do erro e na otimização dos pesos sinápticos ao longo das iterações. O princípio fundamental do treinamento e da classificação com ANN-MLP baseia-se no ajuste das conexões entre os neurônios de acordo com os dados recebidos, permitindo que a rede aprenda e classifique novos pontos com precisão (Hu et al., 2021; Chen et al., 2021)

Um fator essencial no desempenho do modelo é o número de épocas utilizadas durante o treinamento. As épocas representam o número de vezes que o algoritmo percorre todo o

conjunto de treinamento para ajustar os pesos da rede. Um número insuficiente de épocas pode resultar em um modelo subajustado, incapaz de capturar os padrões subjacentes dos dados, enquanto um número excessivo pode levar ao sobreajuste, comprometendo a generalização para novos dados. Em experimentos preliminares, o erro quadrático médio estabilizou-se após aproximadamente 1000 iterações, indicando que a rede atingiu um ponto de convergência adequado para minimizar a função de erro sem sobreajustar os dados (Maxwell, Warner e Guillén, 2021; Vasilakos, Kavroudakis e Georganta, 2020). Devido à complexidade dos dados analisados, foram adotados 24 neurônios na camada oculta, um valor de decaimento de 0,0005 e uma condição de parada de 0,0001, garantindo um melhor ajuste para lidar com dados desequilibrados (Chen et al., 2021). Além disso, o número de épocas foi cuidadosamente ajustado para equilibrar aprendizado eficiente e boa capacidade de generalização sendo testadas com base na avaliação do número de 1 a 50 épocas com passos de 10 em relação a precisão.

2.3.5 Avaliação da acurácia

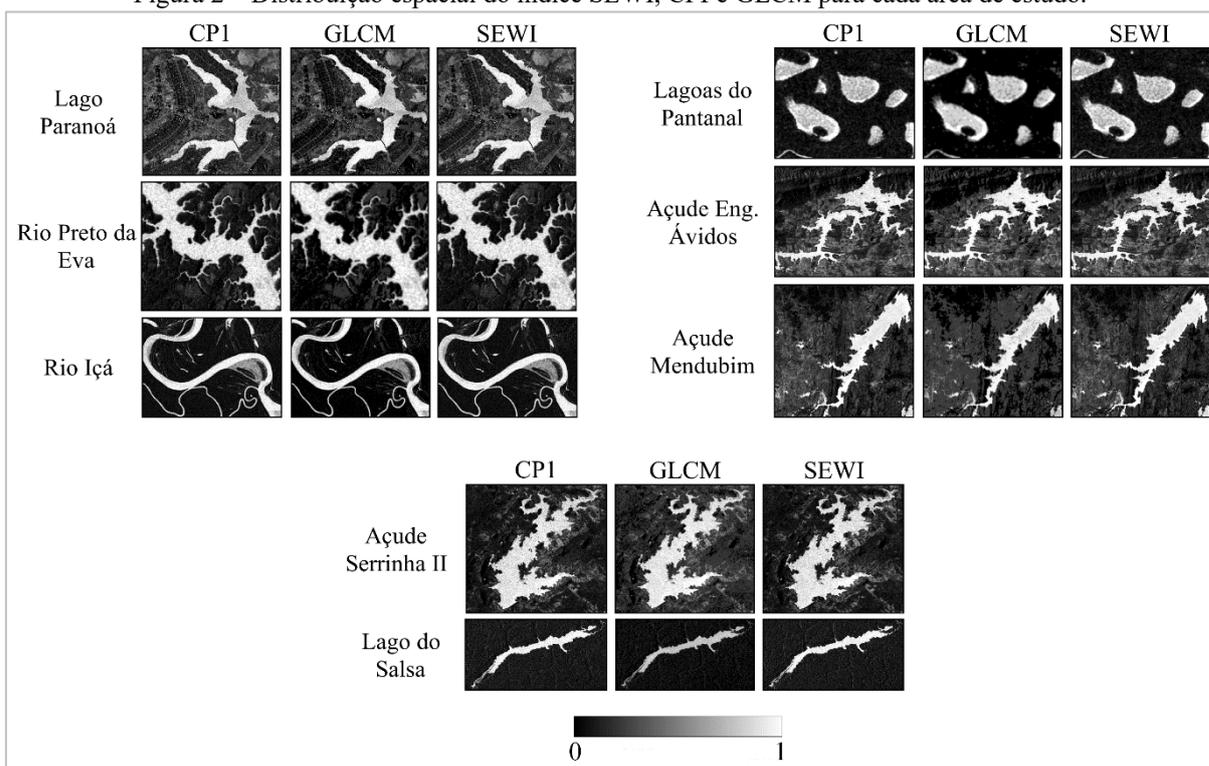
2.3.5. Mapbiomas Beta

Os corpos hídricos detectados pelo produto Mapbiomas Beta 2023 foi utilizado como produto de referência na distribuição de pixels de Água e Não água nas oitos regiões em estudo. O MapBiomas Beta consiste no mapeamento oficial de classes de uso e cobertura do solo georreferenciado, elaborado com base em mosaicos de imagens dos satélites Sentinel-2, com resolução espacial de 10 metros. O período de mapeamento abrange de 2016 a 2023 cobrindo todo o território brasileiro. Esse processo foi realizado de forma colaborativa entre as instituições do MapBiomas, utilizando e algoritmos de aprendizado profundo (deep learning) na plataforma Google Earth Engine e Google Cloud Platforms (Mapbiomas, 2023).

3. RESULTADOS

A Figura 2 mostra a distribuição espacial da primeira componente principal (CP1), o produto de textura GLCM e o índice SEWI para cada área de estudo. De modo geral, o SEWI se destaca como a técnica mais direta para o realce de corpos d'água. A CP1 oferece uma visão mais abrangente dos componentes da imagem, enquanto o GLCM, apesar de identificar diferenças texturais, mostrou limitações na distinção entre água e terra em determinadas regiões.

Figura 2 – Distribuição espacial do índice SEWI, CPI e GLCM para cada área de estudo.



Fonte: Autor (2025).

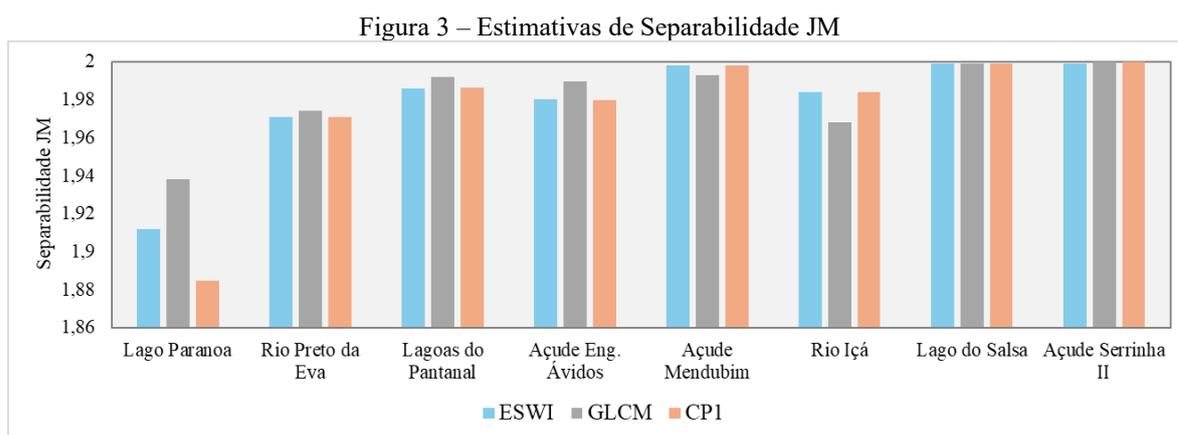
No Lago do Salsa e no Rio Içá, ambos situados no bioma Amazônia, todos os produtos analisados apresentaram uma boa distinção entre os pixels de água e não água, apesar do ruído interno do GLCM. Entretanto, no Rio Preto da Eva, apesar de também estar localizado na Amazônia, observou-se um conjunto de pixels claros fora do corpo hídrico, especialmente no GLCM. Nas lagoas do Pantanal, no Açude Serrinha II, no Lago Paranoá e no Rio Içá, o comportamento visual foi semelhante: os índices CPI e SEWI demonstraram um bom desempenho na identificação dos corpos d'água, enquanto o GLCM apresentou pixels de ruído tanto dentro quanto fora das áreas aquáticas. Essa alta variabilidade nos pixels pode reduzir a precisão do GLCM na detecção da água (Figura 2). O índice SEWI mostrou-se particularmente eficaz na identificação de corpos hídricos, destacando-os em tons mais claros em contraste com o fundo escuro, o que facilita sua diferenciação do entorno. Esse comportamento é mais evidente em imagens do Lago do Salsa, das Lagoas do Pantanal e do Rio Içá, onde a separação entre água e terra é bem definida. Além disso, o SEWI demonstrou menor suscetibilidade a ruídos em áreas urbanas, reforçando sua capacidade de realce hídrico.

A CPI também se revelou eficiente na separação da água do restante da paisagem, mas pode captar interferências de outros elementos, como variações do terreno, como observado no Rio Preto da Eva, e a refletividade de solos degradados, como no entorno do Rio Piranhas, o que reduz a nitidez da distinção em certos casos. Já o GLCM, por ser baseado em textura,

ênfatiza padrões internos das áreas aquáticas, capturando variações que podem indicar vegetação flutuante ou diferentes texturas na superfície da água. Esse efeito é perceptível em locais como as Lagoas do Pantanal, Lago Paranoá e no Açude Serrinha II, mas pode comprometer a diferenciação entre pixels de água e terra. No Rio Içá, o GLCM apresentou um maior contraste entre os pixels de água e não água, sugerindo uma textura hídrica mais homogênea, o que facilitou a distinção. No entanto, essa eficiência não se repetiu em áreas como o Açude Serrinha II e o Lago Paranoá, onde foram observados pixels escuros mesmo dentro das feições aquáticas.

3.1 Análise de separabilidade

A Figura 3 mostra as estimativas de separabilidade JM entre os pixels de “Água” e “Não água” para cada área de estudo. A Separabilidade JM-Distance para todos os parâmetros (CP1, SEWI e GLCM) está próxima do valor máximo de 2,0, indicando que, no geral, os três métodos apresentam uma alta capacidade de distinção entre pixels de água e não água com média gerais iguais de 1,98.



Fonte: Autor (2025).

O Lago do Salsa e o Açude Serrinha II atingiram os valores mais altos para todos os parâmetros, chegando próximos ao limite de separabilidade máxima (1,999 - 1,9999), o que indica uma distinção quase perfeita entre água e não água nesses locais. O Rio Preto da Eva e o Lago Paranoá apresentaram os menores valores de separabilidade para CP1 e SEWI, o que sugere uma maior dificuldade desses índices em diferenciar água e não água nessas regiões. Isso pode estar relacionado a fatores como maior presença de ruídos ou interferências no entorno (vegetação, áreas urbanas, solo exposto) enquanto no Rio Içá, os três parâmetros

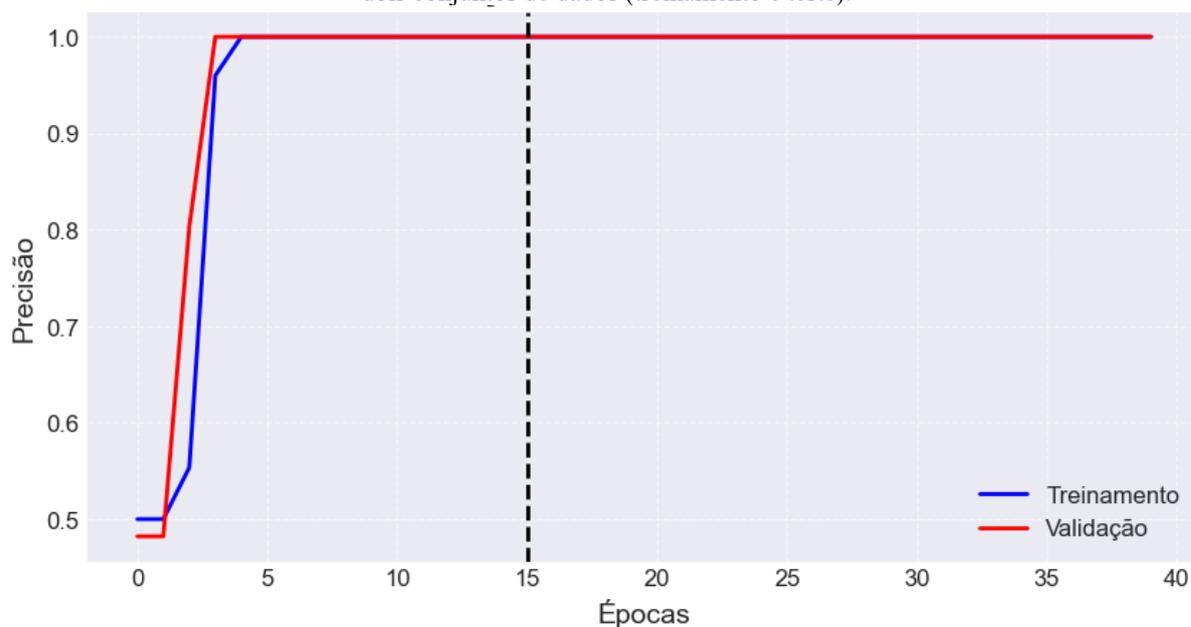
apresentaram desempenho bastante equilibrado e alto, reforçando a eficácia desses métodos em um ambiente com textura hídrica homogênea (Figura 3).

O SEWI e CP1 apresentou valores consistentemente elevados, demonstrando boa separabilidade. Sua capacidade de realçar corpos d'água é evidente, especialmente onde há menor interferência de ruído. Já o GLCM, apesar dos altos valores e equilibrado em relação aos outros produtos, com bom rendimento nas lagoas do Pantanal e Enge Avidos, em locais com mais ruído dentro da água (como observado anteriormente no Açude Serrinha II e Lago Paranoá), sua eficiência pode ser afetada numa amostragem com todos os pixels.

3.2 Análise de treinamento

A Figura 4 mostra a evolução do ajuste do modelo do modelo ANN em relação ao número de épocas baseado na precisão. No geral, a análise do gráfico mostra que a precisão do modelo melhora rapidamente nas primeiras épocas e atinge quase 100% por volta da época 10. Após esse ponto, tanto a precisão de treinamento (linha azul) quanto a precisão de validação (linha vermelha) permanecem constantes e próximas de 1.0.

Figura 4 – Gráfico de desempenho do modelo ANN mostrando a tendência de precisão de aprendizagem para dois conjuntos de dados (treinamento e teste).

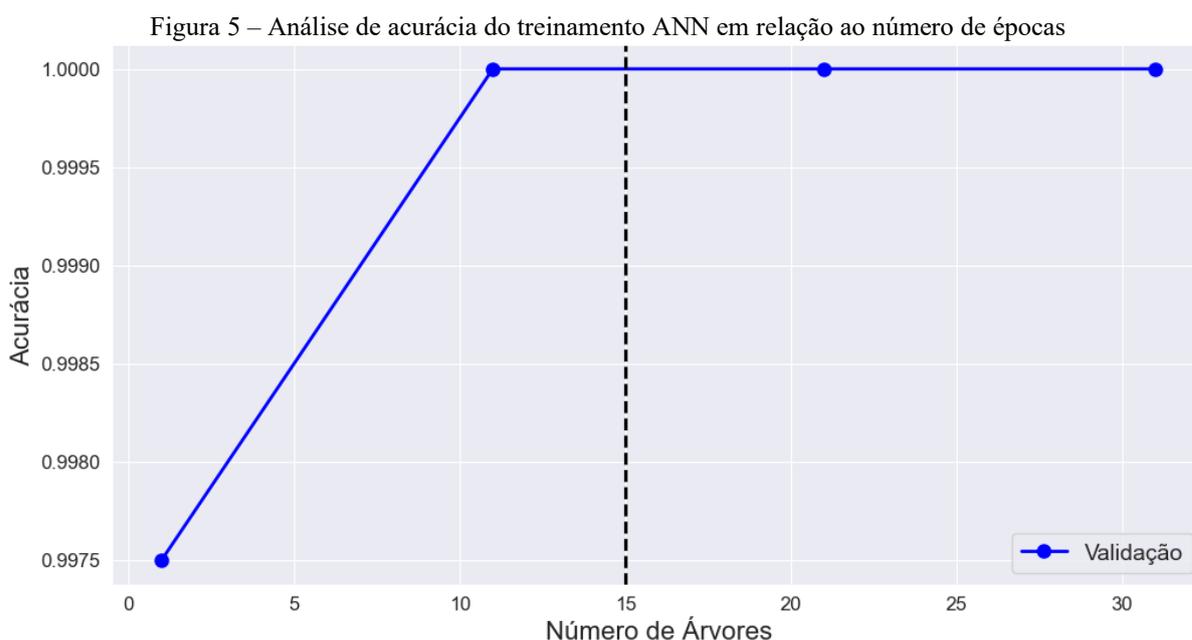


Fonte: Autor (2025).

O modelo aprende rapidamente, alcançando alta precisão antes da época 10. Isso sugere que os pesos da rede foram ajustados eficientemente já nas primeiras iterações. Como as curvas

de precisão de treinamento e validação são praticamente idênticas, não há indicação de *overfitting* significativo. O modelo generaliza bem para dados não vistos, diante disso, após a época 10, a precisão não melhora mais, o que sugere que mais épocas não trazem benefício adicional. A linha tracejada indica que a época 15 foi escolhida para a classificação final. Como a precisão já estava estabilizada há muitas épocas, a escolha de uma época posterior não impacta o desempenho do modelo.

O gráfico mostra a evolução da acurácia do modelo em função do número de árvores no Random Forest, com a linha tracejada indicando que 30 árvores foram utilizadas para a classificação final (Figura 5).



Fonte: Autor (2025).

O modelo começa com uma acurácia ligeiramente inferior (próxima de 0.9975) quando há poucas árvores, porém, há um rápido crescimento na precisão até cerca de 15 árvores, onde a acurácia já atinge praticamente 100%, sugerindo que poucas árvores já são suficientes para atingir um desempenho quase perfeito no conjunto de validação. Dessa forma, a linha tracejada em 15 árvores indica o número escolhido para a classificação final. Como a precisão já era 1.0 nesse ponto, essa escolha foi apropriada, o que evita o custo computacional desnecessário de treinar mais árvores sem ganho adicional em precisão.

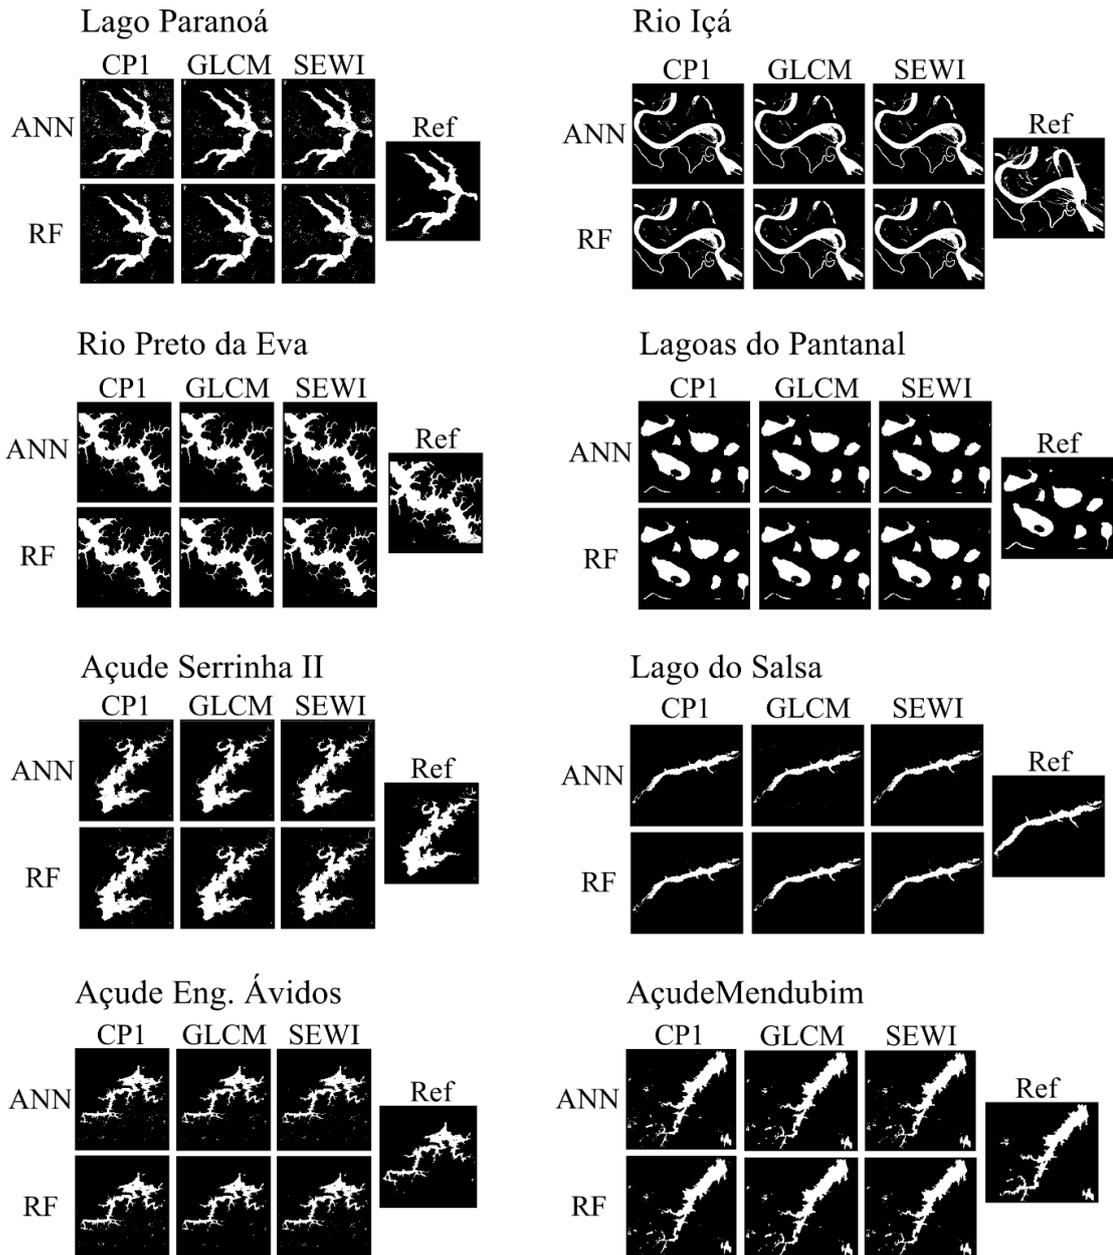
A Figura 6 apresenta a distribuição espacial e temática dos corpos hídricos nas diferentes áreas de estudo, com base nos métodos CP1, GLCM e SEWI e nos classificadores ANN e RF. De maneira geral, os mapas apresentam pequenas variações na identificação dos

corpos hídricos e mostram uma boa consistência em relação ao mapa de referência (Ref). As áreas de Rio Preto da Eva, Lagoas do Pantanal, Açude Mendubim II e Lago do Salsa destacam-se pela precisão na segmentação dos corpos hídricos, demonstrando uma boa concordância entre os diferentes métodos e classificadores.

Em todas as regiões analisadas, os mapas gerados pelos classificadores ANN e RF apresentam padrões semelhantes, conseguindo delinear bem os corpos hídricos principais. No entanto, alguns pontos de atenção foram observados em certas segmentações. O Lago Paranoá foi a área que apresentou a maior distribuição de ruído, tanto dentro como fora do corpo hídrico, independentemente do método utilizado. Os métodos SEWI e CP1 foram os que mais evidenciaram esse ruído, enquanto o GLCM, que é baseado na remoção de textura, apresentou uma segmentação mais limpa. Esse comportamento pode estar relacionado à complexidade do entorno do Lago Paranoá, que inclui área urbana densa, vegetação de diferentes fenologias, campos abertos, áreas com e sem vegetação e pastagens. Essa diversidade de alvos pode ter causado confusão nos classificadores, resultando em pixels de omissão nas partes mais rasas do lago e falsos positivos em regiões externas devido à retrodispersão semelhante à da água. Esse mesmo comportamento, embora com menor intensidade, foi observado no Açude Engenheiro Ávidos e Açude Serrinha II. No Rio Içá, o GLCM apresentou melhor desempenho na detecção das partes mais rasas do corpo hídrico, mas falhou na identificação de corpos d'água menores ao redor do rio. Em contrapartida, os métodos SEWI e CP1 apresentaram maior ruído nas áreas rasas, mas conseguiram detectar corpos hídricos menores que o GLCM não identificou.

No geral, os métodos e classificadores apresentam resultados promissores, mas a escolha ideal depende do tipo de corpo hídrico e das condições ambientais locais. A comparação com a referência sugere que a combinação SEWI + ANN/RF pode ser a mais robusta e equilibrada para a maioria dos casos, pois conseguiu um bom delineamento e identificação dos corpos hídricos, minimizando a omissão e melhorando a generalização dos resultados.

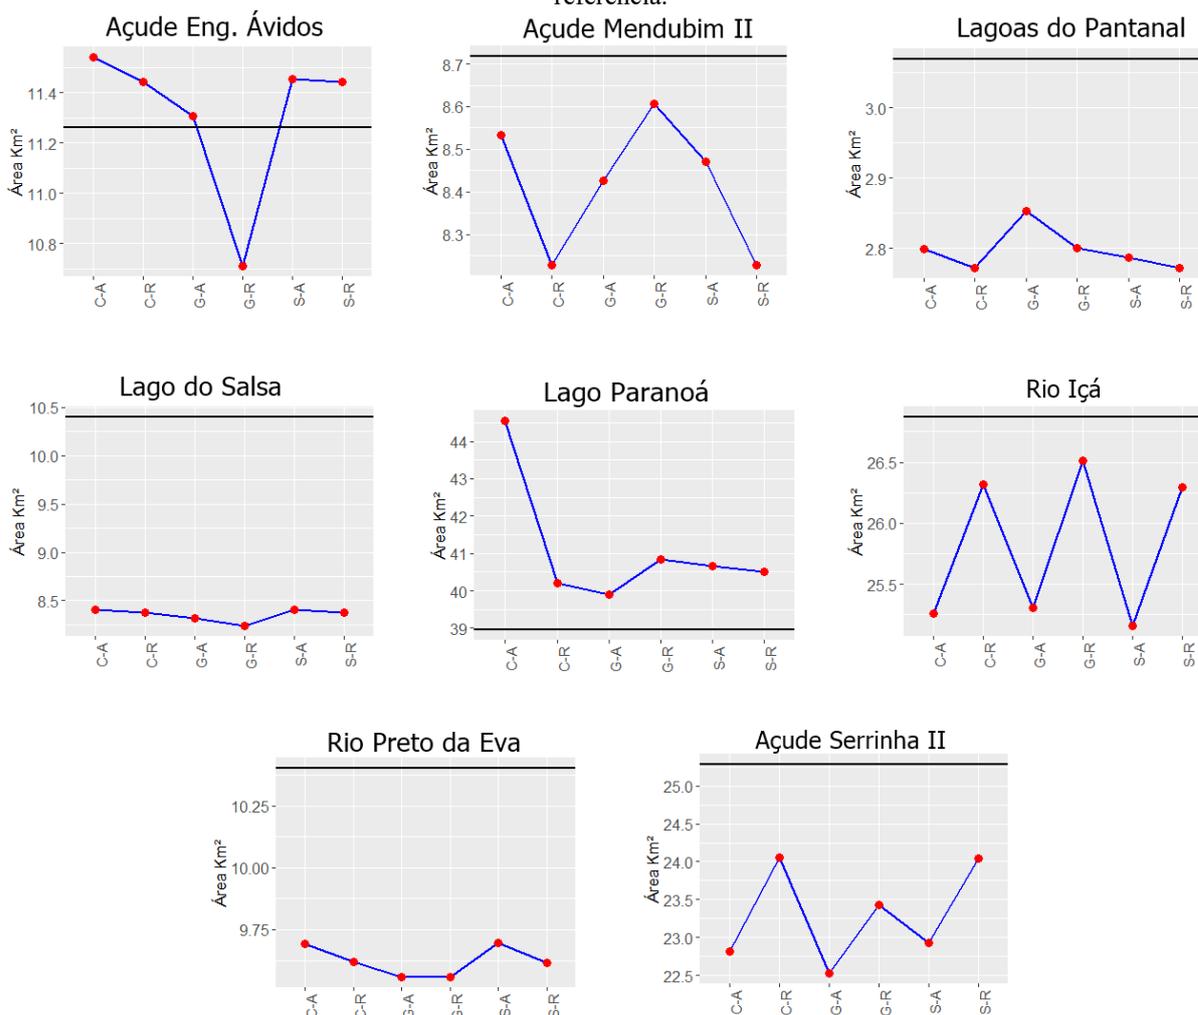
Figura 6 – Corpos hídricos detectados pela combinação de métodos para cada área de estudo.



Fonte: Autor (2025).

A Figura 7 mostra a área de diferentes corpos hídricos do Brasil obtidos pela combinação de métodos CP1, SEWI e GLCM pelos diferentes classificadores ANN e RF e a área de referência. De maneira geral, as áreas estimadas pelos diferentes métodos ficam próximas da referência, indicando que os métodos são eficientes na detecção de corpos hídricos, dessa forma, a diferença entre os classificadores é pequena, o que sugere que a escolha do método de processamento (CP1, GLCM, SEWI) tem mais impacto na estimativa da área do que o classificador utilizado.

Figura 7 – Áreas em Km² dos corpos hídricos detectados pelos produtos. A linha em preto é o a área obtida pela referência.



Fonte: Autor (2025).

A análise dos métodos CP1, GLCM e SEWI para a estimativa de áreas de corpos hídricos revela algumas tendências importantes. O método CP1 demonstrou uma tendência à superestimação em alguns casos, como no Lago Paranoá, onde a área estimada pela ANN foi de 44,55 km², enquanto a referência era 38,96 km². No entanto, esse mesmo método também apresentou subestimações em outros casos, como no Lago do Salsa (ANN: 8,40 km²; RF: 8,38 km²; Ref: 10,40 km²) e no Açude Serrinha II (ANN: 22,80 km²; RF: 24,05 km²; Ref: 25,28 km²).

No Açude Eng. Ávidos, Rio Içá, Rio Preto da Eva e Lagoas do Pantanal, o CP1 apresentou variações pequenas, geralmente inferiores a 1 km², indicando uma boa precisão nesses casos. Os métodos GLCM e SEWI, por outro lado, forneceram estimativas geralmente mais próximas da referência, com variações que não ultrapassaram os 2 km². O GLCM se mostrou menos ruidoso e mais eficiente em ambientes com interferências texturais, enquanto o

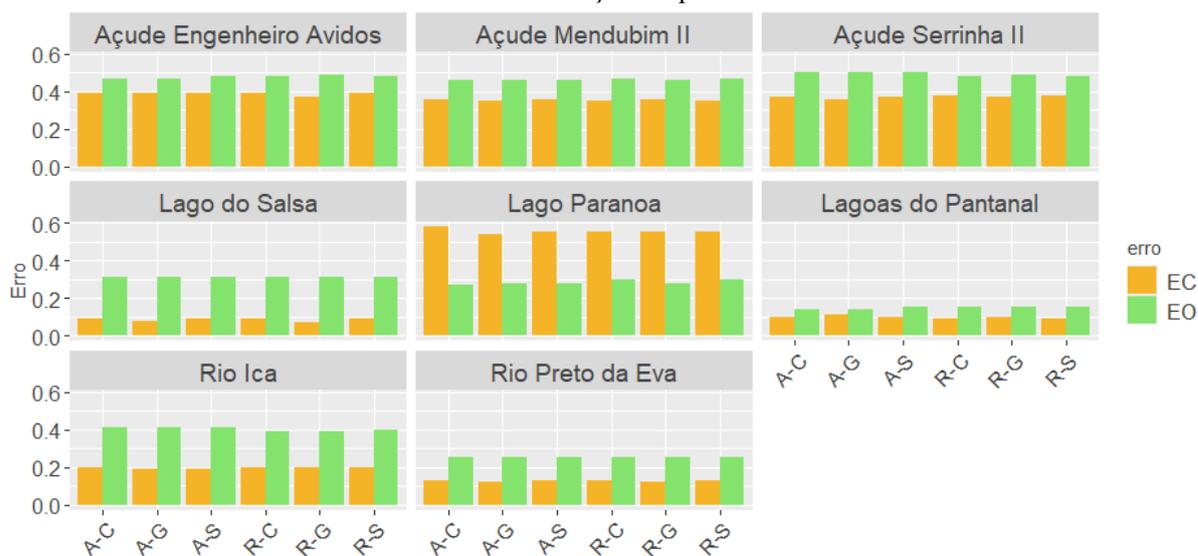
SEWI parece ter melhor desempenho na detecção de corpos d'água menores, ainda que possa introduzir algum ruído em áreas rasas. Ao analisar os resultados por corpo hídrico, nota-se que em locais como Açude Serrinha II, Lago do Salsa, Lago Paranoá, Rio Preto da Eva, Lagoas do Pantanal e Açude Mendubim II, todos os métodos apresentaram subestimação da área do corpo hídrico. Já na comparação entre os classificadores ANN e RF, observa-se que o RF teve melhor desempenho no Lago Paranoá, Rio Icó, Açude Eng. Ávidos e Açude Serrinha II enquanto o ANN foi mais preciso em Rio Preto da Eva, Lagoas do Pantanal, Açude Mendubim II.

No caso específico do Lago do Salsa, ambos os classificadores apresentaram erros mais elevados, pois a área de referência é 10,40 km², mas os métodos CP1, GLCM e SEWI subestimaram a área (~8,3 a 8,4 km²). Isso sugere a possível omissão de pixels de água, principalmente em regiões mais rasas, o que pode ter afetado a precisão da classificação. Em suma, a escolha do método depende da característica do corpo hídrico. Enquanto GLCM e SEWI tendem a ser mais confiáveis para corpos hídricos menores ou em áreas com interferências texturais, o CP1 pode ser útil, mas apresenta maior variabilidade, sendo necessário um ajuste mais refinado para evitar super ou subestimações significativas.

A Figura 8 apresenta os erros de omissão e comissão para a classificação de diferentes corpos hídricos no Brasil, utilizando três métodos de extração de características (CP1, GLCM e SEWI) e dois classificadores (ANN - Rede Neural Artificial e RF - Random Forest). No geral, nenhuma combinação de método e classificador se destaca drasticamente, pois todos apresentam bons desempenhos. Isso reforça que as abordagens utilizadas são robustas e confiáveis para a classificação de corpos hídricos, independentemente da escolha específica entre CP1, GLCM, SEWI, ANN ou RF.

Os Açudes Engenheiro Ávidos, Mendubim II e Serrinha II apresentaram erros de omissão relativamente altos, variando entre 0,21 e 0,25, especialmente nos métodos SEWI e CP1. Por outro lado, os erros de comissão foram moderados, situando-se entre 0,1 e 0,14, com destaque para o método GLCM, que demonstrou um desempenho levemente melhor em alguns casos, como no Açude Serrinha II, onde o erro de comissão foi de 0,11 para RF. Isso sugere que, enquanto os modelos podem estar deixando de identificar corretamente partes dos açudes, eles também apresentam uma menor tendência a classificar erroneamente áreas que não pertencem aos corpos hídricos.

Figura 8 – Gráfico de barras representando as estimativas de Erro de omissão e comissão para cada área de estudo em relação aos produtos.



Fonte: Autor (2025).

No Lago Paranoá, os erros de omissão foram baixos, variando entre 0,02 e 0,05 para os classificadores ANN e RF. No entanto, os erros de comissão foram elevados, situando-se entre 0,29 e 0,33, o que indica que os modelos frequentemente classificam erroneamente outras áreas como pertencentes ao lago. O método CP1 apresentou o maior erro de comissão, atingindo 0,33 para ANN, enquanto os métodos GLCM e SEWI tiveram um desempenho mais equilibrado, mas ainda com valores altos. Já nas Lagoas do Pantanal, os erros de omissão e comissão mostraram-se mais equilibrados, variando de 0,1 a 0,16, o que sugere um desempenho mais consistente dos modelos. O método GLCM apresentou os menores erros de comissão, atingindo 0,14 tanto para ANN quanto para RF, o que pode indicar uma melhor precisão na detecção dessa área.

No caso do Rio Içá, os erros de comissão foram baixos, situando-se entre 0,05 e 0,06, enquanto os erros de omissão foram relativamente mais altos, entre 0,14 e 0,16. Esse resultado sugere que o modelo pode estar deixando de identificar corretamente algumas partes do rio. O classificador RF apresentou um desempenho ligeiramente melhor que ANN, mas a diferença entre ambos não foi significativa. Já no Rio Preto da Eva, a combinação que apresentou o menor erro de omissão foi GLCM-ANN, com um valor de 0,05. O método CP1-ANN também teve um desempenho satisfatório, com erro de omissão de 0,08 e erro de comissão de 0,12. No entanto, o classificador RF demonstrou um desempenho inferior em termos de erro de omissão, com valores variando entre 0,10 e 0,12.

Por outro lado, no Lago do Salsa, o erro de omissão foi bastante uniforme entre todos os métodos e classificadores, mantendo-se em 0,06. Esse resultado indica um bom desempenho

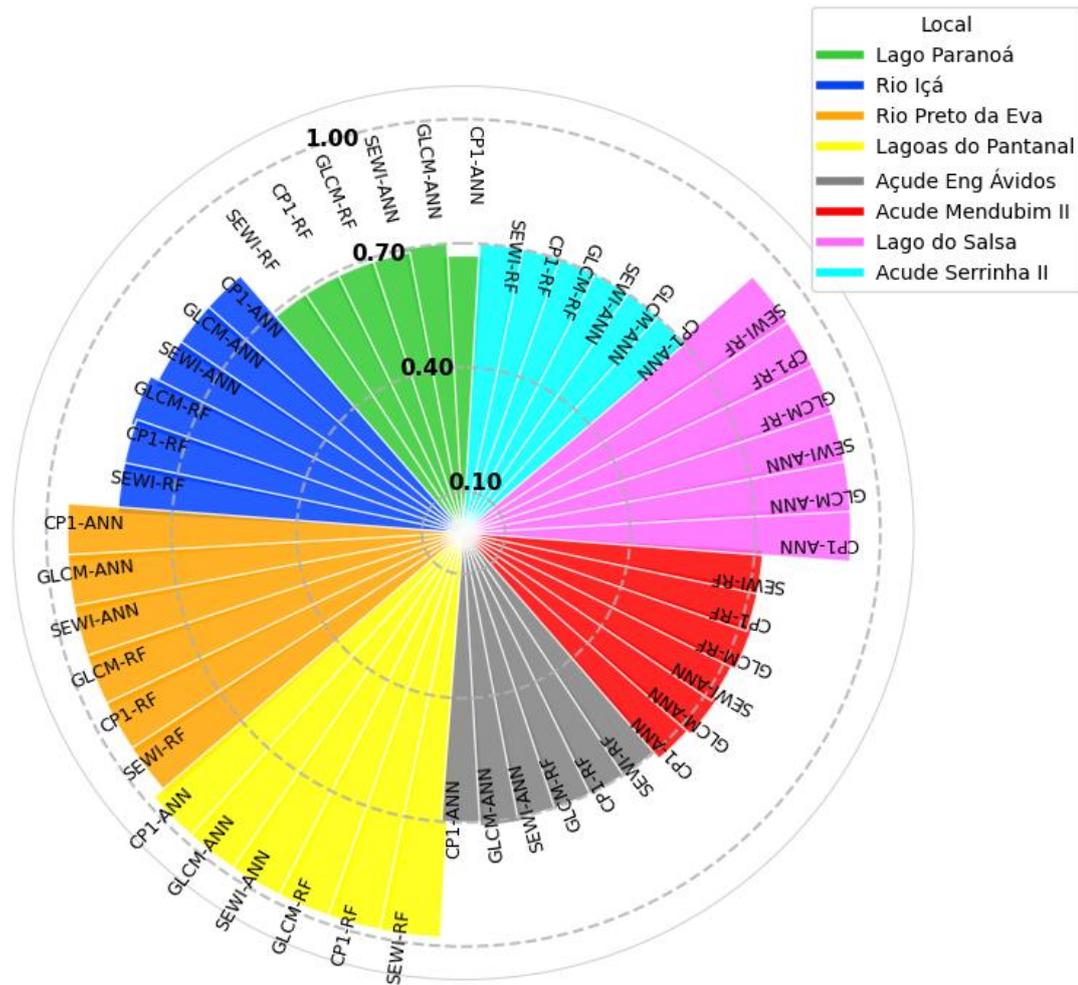
do modelo na detecção do lago, garantindo que poucas áreas sejam erroneamente omitidas. No que diz respeito ao erro de comissão, os métodos CP1 e SEWI apresentaram os melhores desempenhos, ambos com valores de 0,16, enquanto o método GLCM teve um desempenho um pouco pior, variando entre 0,17 e 0,18. Além disso, não houve uma diferença significativa entre os classificadores ANN e RF, pois os valores foram muito próximos.

Por fim, os valores de erro obtidos na análise variam entre 0,02 e 0,33, indicando que os modelos apresentam uma boa precisão geral na classificação dos corpos hídricos. Apesar de algumas variações sutis entre os métodos, como o GLCM apresentando ligeiramente maiores erros de comissão em determinados casos, nenhum método se destacou como significativamente superior ou inferior aos demais. Ambos os classificadores, ANN e RF, demonstraram desempenhos bastante similares, sem uma diferença clara de superioridade. Como os erros são baixos no geral, todos os métodos avaliados se mostram viáveis para essa tarefa, permitindo uma boa detecção dos corpos d'água.

A análise dos valores do coeficiente de Dice-Sørensen para a classificação de corpos hídricos é apresentada pela Figura 9. Os valores do coeficiente de Dice-Sørensen variam entre 0,67 e 0,98, indicando alta similaridade entre os métodos de classificação e as referências de verdade terrestre em que as diferenças entre os métodos GLCM, CP1 e SEWI são pequenas, sugerindo que todos apresentam desempenhos semelhantes na identificação de corpos hídricos.

O classificador RF apresenta ligeiramente melhores resultados para alguns locais, como o Rio Içá, onde GLCM-RF atinge 0,84, enquanto GLCM-ANN obtém 0,82. No entanto, para a maioria dos corpos hídricos, a diferença entre ANN e RF é mínima. O Açude Mendubim II também apresenta uma leve vantagem ao utilizar RF, alcançando 0,73 com GLCM-RF, em comparação com 0,72 obtido por CP1-RF e SEWI-RF. Os valores mais altos do coeficiente de Dice-Sørensen foram registrados para as Lagoas do Pantanal, atingindo 0,98 em todas as combinações, o que indica que esse corpo hídrico é facilmente identificado pelos métodos analisados. Em contrapartida, o Lago Paranoá obteve os menores coeficientes, variando entre 0,67 (CP1-ANN) e um máximo de 0,7 (GLCM-ANN), sugerindo maior dificuldade na classificação dessa região. Esse resultado pode estar associado a características particulares da área ou a limitações dos métodos empregados.

Figura 9 – Barplot circular para as estimativas de coeficiente Dice para cada produto.



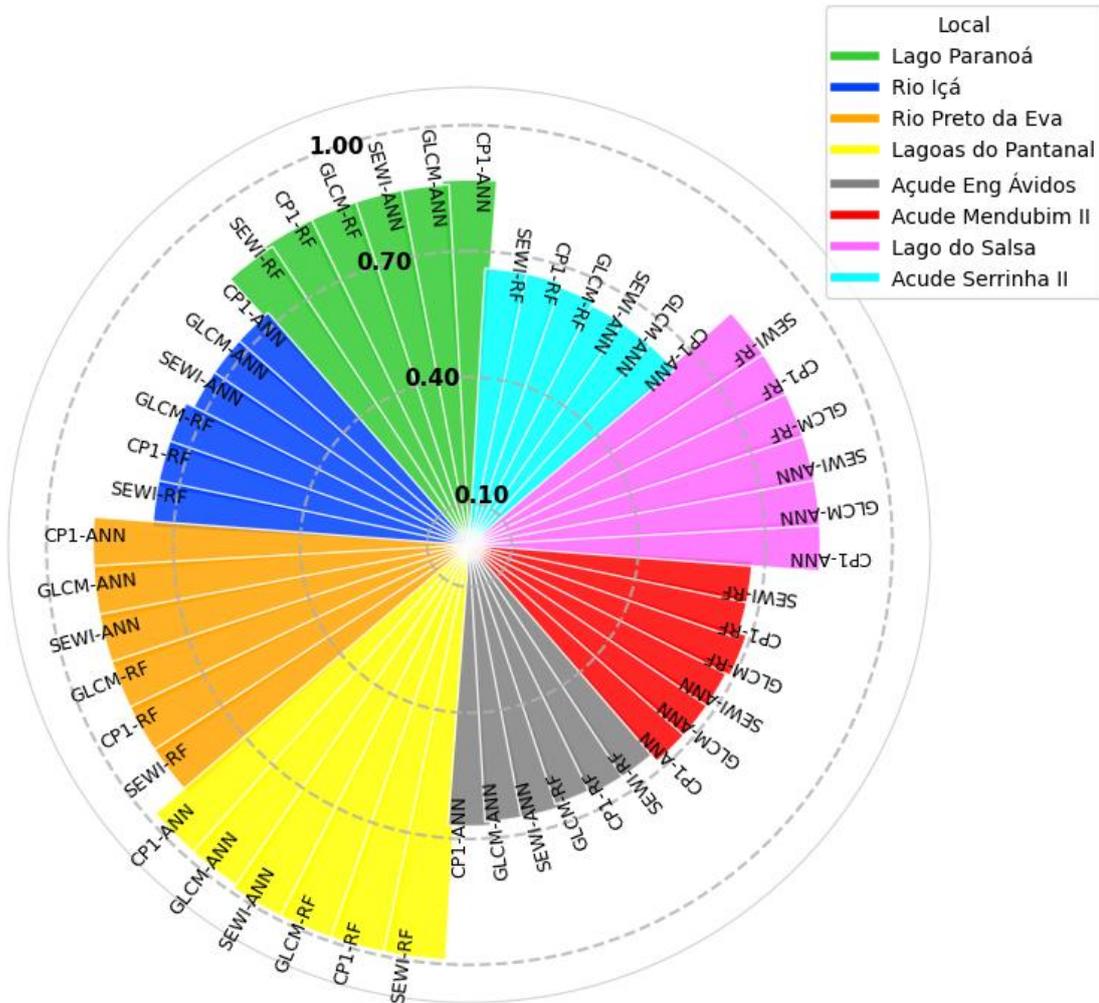
Fonte: Autor (2025).

Entre os métodos testados, GLCM combinado com ANN e RF apresentou os maiores valores médios, o que pode indicar que a textura exerce um papel relevante na segmentação dos corpos hídricos. Já CP1 e SEWI demonstraram desempenho bastante similar, com CP1-RF e SEWI-RF apresentando resultados idênticos. No caso do Rio Preto da Eva e do Lago do Salsa, ambos localizados na região amazônica, todos os métodos demonstraram um desempenho consistente e elevado, atingindo 0,95 e 0,93, respectivamente. Por outro lado, corpos hídricos situados no semiárido, como o Açude Eng. Ávidos e o Açude Serrinha II, apresentaram coeficientes relativamente mais baixos, variando entre 0,7 e 0,71. Essa diferença pode refletir desafios específicos na segmentação dessas áreas, possivelmente devido à variação sazonal da água, à presença de sedimentos ou a características espectrais que dificultam a distinção entre a superfície da água e o entorno.

Complementarmente, a Figura 10 mostra as estimativas de Recall para cada classificação realizada. No geral, todos os métodos têm desempenho próximo de 1, o que indica

alta acurácia na classificação., por outro lado, o classificador RF parece levemente superior ao ANN.

Figura 10 – Barplot circular para as estimativas as estimativas de Recall para cada produto.



Fonte: Autor (2025).

É possível observar que nas Lagoas do Pantanal e Açude Eng. Ávidos apresentam os maiores coeficientes de recall (0,98–0,99) enquanto o Lago Paranoá e Lago do Salsa também apresentam altos valores (0,85–0,87 e 0,83, respectivamente), mas com uma leve variação entre os métodos. Para a maioria das áreas, RF apresentou resultados levemente superiores aos do ANN, especialmente em Açude Eng. Ávidos e Açude Mendubim II, no entanto, a diferença entre ANN e RF não é muito significativa, indicando que ambos os classificadores possuem desempenhos similares. O Açude Serrinha II teve os menores coeficientes de recall (0,64–0,66) enquanto Açude Mendubim II também teve valores mais baixos (0,67–0,69), o que pode indicar uma maior complexidade na diferenciação dessas áreas. Com base na diferença entre métodos, a CP1-ANN obteve o maior valor no Lago Paranoá (0,87) enquanto o GLCM-RF e CP1-RF

apresentaram desempenho equilibrado, enquanto SEWI-RF teve a menor variação entre as áreas. O método SEWI tende a ter valores levemente menores que os outros, especialmente em Lago Paranoá (0,85) e Açude Eng. Ávidos (0,66).

A Tabela 2 apresenta a Acurácia Global (%) de diferentes combinações de métodos de extração de características (GLCM, CP1, SEWI) com classificadores (ANN - Rede Neural Artificial e RF - Random Forest) para a identificação de corpos hídricos em diversas regiões do Brasil. No geral, aproximadamente todos os modelos alcançaram acurácias acima de 92%, com a maioria acima de 97%, indicando alta eficácia na classificação (Tabela 2).

Tabela 2 – Acurácia Global (%)

Combinação	Lago Paranoá	Rio Içá	Rio Preto da Eva	Lagoas do Pantana I	Açude Eng. Ávidos	Açude Mendubim	Lago do Salsa	Açude Serrinha II
CP1+ANN	97,19	92,45	94,35	97,71	98,13	97,62	98,04	96,8
CP1+RF	98,11	93,12	94,17	97,63	98,18	97,69	98,02	97,06
GLCM+ANN	98,43	92,47	94,05	97,52	98,11	97,62	97,95	96,67
GLCM+RF	98,28	93,23	94,05	97,42	98,18	97,57	97,91	96,94
SEWI+ANN	98,23	92,39	94,36	97,67	98,18	97,64	98,04	96,85
SEWI+RF	98,26	93,1	94,16	97,63	98,18	97,69	98,02	97,06

Fonte: Autor (2025).

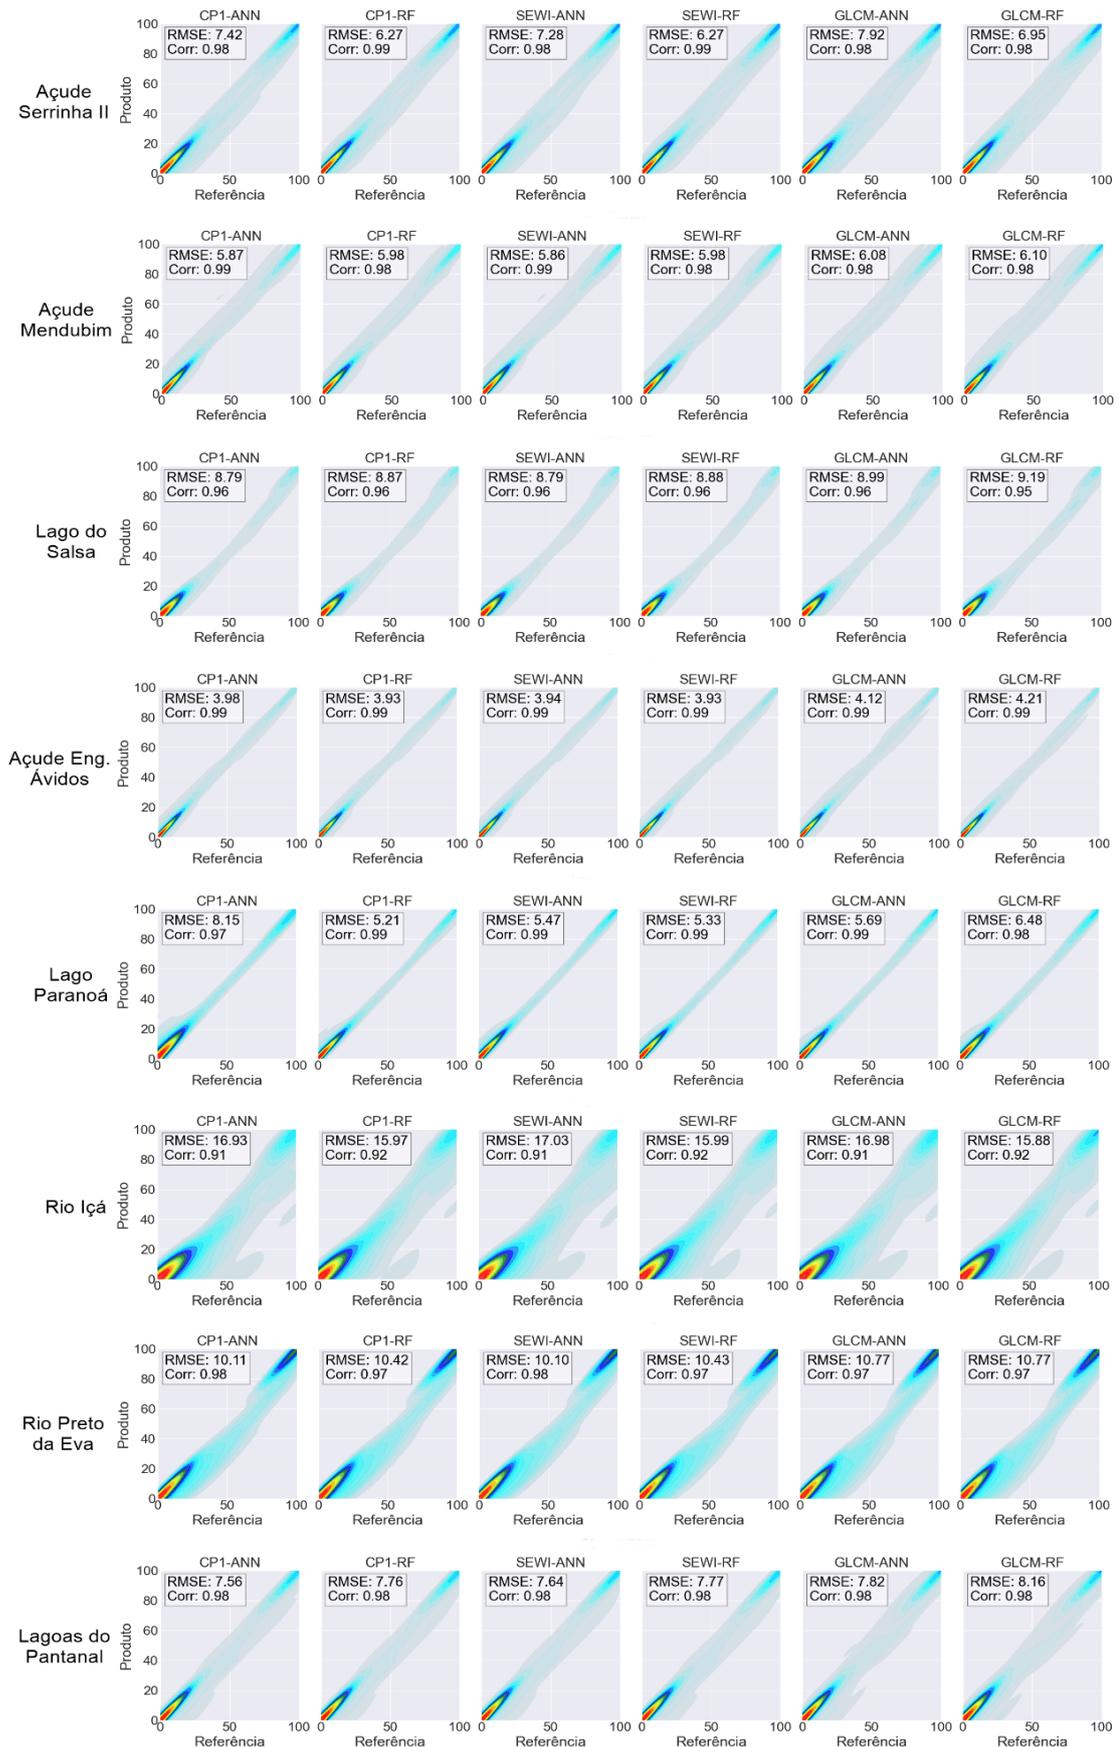
A análise dos dados de Acurácia Global (%) para a classificação de áreas de corpo hídrico no Brasil revela que todos os métodos e classificadores testados apresentam desempenho elevado, com valores acima de 92%, indicando uma eficácia geral consistente na detecção de massas d'água. O Lago Paranoá também apresenta excelente desempenho, com acurácias acima de 97% em todos os casos, sendo que a combinação GLCM-ANN obteve o melhor resultado (98,43%) (Tabela 1). O CP1-RF e o SEWI-RF demonstraram resultados ligeiramente superiores em comparação às redes neurais (ANN) em alguns casos, como no Rio Içá (93,12% e 93,10%, respectivamente, contra 92,45% do CP1-ANN). No entanto, as diferenças entre Random Forest (RF) e ANN são mínimas na maioria dos cenários. O método GLCM, apresentou desempenho competitivo, especialmente no Lago Paranoá (98,43% com ANN), mas não superou consistentemente os demais métodos. Já o SEWI, que combina informações espectrais e índices de água, mostrou resultados muito próximos aos do CP1, indicando que ambas as abordagens são eficazes para mapeamento hídrico.

A Figura 11 relata os gráficos de dispersão obtidos pela combinação de todas as células de proporção de área classificadas como “Água” em relação com os dados de referência. A alta correlação (acima de 0,91 em todos os cenários) indica que todos os métodos conseguem capturar adequadamente a dinâmica das áreas de água em comparação com os dados de referência. Além disso, os valores de RMSE não apresentam diferenças drásticas entre os produtos.

Em geral, os produtos CP1 e SEWI, quando combinados com Random Forest (RF) ou Artificial Neural Networks (ANN), apresentam desempenho semelhante e frequentemente superior ao GLCM, especialmente no que diz respeito ao RMSE. Por exemplo, para o Lago Paranoá, o CP1-RF e o SEWI-RF alcançaram os menores valores de RMSE (5,21 e 5,33, respectivamente), enquanto o GLCM-RF obteve um desempenho pior (6,48), no entanto, a diferença em relação aos outros métodos não é extrema. Esse padrão se repete em outros corpos hídricos, como o Rio Preto da Eva e o Açude Mendubim II, onde CP1 e SEWI mantiveram RMSEs mais baixos em comparação ao GLCM, independentemente do classificador utilizado. A maior discrepância encontrada foi no CP1-ANN no Lago Paranoá que obteve um RMSE de 8,15 enquanto os demais métodos variaram entre 5 ~ 6 enquanto nos demais, a discrepância ficou no entorno de 1.

Quanto à correlação, todos os produtos demonstraram valores elevados (acima de 0,91), indicando uma forte relação com os dados de referência. No entanto, CP1 e SEWI novamente se destacam, especialmente quando combinados com RF, atingindo correlações de 0,99 em múltiplos locais, como no Lago Paranoá e no Açude Eng. Ávidos. O GLCM também apresentou bons resultados em correlação, mas com pequena inferioridade na casa de 0,01 como em alguns casos, visto no Lago do Salsa, onde o GLCM-RF obteve 0,95 contra 0,96 dos demais métodos. Nota-se ainda que, em termos de escolha do classificador, o RF tende a superar ligeiramente a ANN quando combinado com CP1 e SEWI, tanto em RMSE quanto em correlação. Por outro lado, o GLCM mostrou-se mais sensível à escolha do classificador, com desempenho variando mais significativamente entre RF e ANN, embora é possível ressaltar que entre os métodos a diferença é muito pequena, os valores médios gerais reforçam essa afirmação, onde para o RMSE a variação foi de 8~8,6 km² e correlação ficou no entorno de 0,97, dessa forma, todos os produtos podem ser considerados bons, pois conseguem estimar a proporção de água com alta correlação e erros relativamente baixos. No entanto, se o objetivo for otimizar ao máximo a precisão, CP1-RF e SEWI-RF surgem como as melhores opções, enquanto o GLCM pode ser também uma alternativa válida nesta análise.

Figura 11 – Gráficos de dispersão das proporções de células rotuladas como “Água” pelos produtos classificados plotados em relação à proporção rotulada como “Água” pelo conjunto de dados de referência.



Fonte: Autor (2025).

Os atributos derivados da (GLCM) têm se mostrado eficazes na diferenciação entre pixels aquáticos e não aquáticos, como amplamente reconhecido na literatura, tanto para imagens SAR quanto para imagens de sensores orbitais passivos. Rios, lagos e represas geralmente apresentam textura suave e homogênea nas imagens de satélite, em contraste com áreas de vegetação, zonas urbanas ou solos expostos. Essa diferença é refletida em baixos valores de contraste e altos de homogeneidade nas métricas GLCM, evidenciando sua capacidade de realçar distinções estruturais nas superfícies, considerando padrões de direção e distância. Isso é particularmente visível nas distribuições de pixels apresentadas na Figura 2, com destaque para as Lagoas do Pantanal e o Lago do Salsa, bem como nos altos valores de separabilidade estatística observados na Figura 3.

Ye (2015) propôs um método baseado em GLCM para intensificar o contraste de retroespalhamento entre corpos d'água e superfícies não aquáticas em imagens SAR do Kompsat-5, utilizando limiarização para remover pixels erroneamente classificados, resultando em uma precisão geral de 99,00% e coeficiente Kappa de 90,38% na extração de corpos hídricos. De forma semelhante, Wan, Wang e Zhu (2021), utilizando imagens SAR do satélite Gaofen-3 combinadas com GLCM, alcançaram uma acurácia global de 94,74% na classificação de corpos hídricos na China. Esses resultados são compatíveis com os valores encontrados na Tabela 3, que demonstram acurácia global superior a 90%.

Contudo, algumas limitações foram apontadas por outros autores. Corpos d'água com superfícies rugosas ou cobertos por vegetação flutuante podem gerar retroespalhamento intenso, semelhante ao de pastagens ou solos agrícolas, levando a classificações errôneas. Além disso, o ruído granular conhecido como "speckle", comum em imagens SAR, pode afetar as métricas de textura, gerando falsos positivos ou negativos — especialmente nas regiões internas dos corpos hídricos. Tal efeito foi observado no Lago Paranoá (Figura 4), o qual apresentou as menores separabilidades estatísticas entre classes (Figura 5).

Os resultados encontrados neste estudo, estão em correspondência com as pesquisas de Yuan et al. (2023) demonstraram o potencial das imagens SAR Sentinel-1 na extração de água superficial ao combinar coeficientes de retroespalhamento com cinco atributos de textura GLCM, destacando sua aplicabilidade em estudos de longo prazo. Já López-Caloca et al. (2020) integraram GLCM com SVM para identificar água de superfície, obtendo resultados superiores aos métodos de limiar tradicional, especialmente na detecção de corpos d'água altamente dinâmicos. Eles também mostraram que a combinação das características texturais de GLCM com o retroespalhamento ajuda a suprimir o ruído speckle, melhorando os resultados de

classificação, como indicado pela separação clara entre as distribuições bimodais nos histogramas.

Nesse contexto, os classificadores de aprendizado de máquina (ML) têm se mostrado eficazes para aprender as sutilezas texturais das superfícies, reduzindo a incidência de falsos positivos. A combinação entre GLCM e classificadores de ML, como Random Forest (RF) ou redes neurais artificiais (ANN), tem demonstrado bom desempenho em termos de generalização e precisão. Gautam e Singhai (2024) reforçam essa abordagem ao destacar que a integração de GLCM com classificadores de aprendizado profundo fornece informações texturais ricas e menor sensibilidade a variações de iluminação, o que resulta em eficiência computacional, menor complexidade e precisão aprimorada. Em seus experimentos com imagens do satélite GF-2, os autores reportaram desempenho superior com redes profundas como ResNet-101 e VGG-16, alcançando 98,56% de acurácia, enquanto outros métodos variaram entre 92% e 93%.

Da mesma forma, Yu et al. (2022) obtiveram uma precisão geral de 94,13% e um coeficiente Kappa de 0,89 ao aplicar GLCM combinado com Random Forest (GLCM+RF), superando métodos como o limiar de Otsu, KNN e SVM. Os resultados deste estudo estão em conformidade com a literatura, especialmente nas distribuições espaciais de pixels apresentadas na Figura 3, onde se observa uma separação nítida entre pixels de água e não água, sendo os primeiros visivelmente mais escuros em comparação com os produtos SEWI e CP1, como evidenciado nas Lagoas do Pantanal e no Rio Içá.

Por outro lado, os resultados não apresentaram diferenças marcantes em relação a outros métodos, tampouco um padrão claro de superioridade ou limitação. Ainda assim, destacou-se uma melhor generalização na remoção de ruído granular, sobretudo em regiões rasas, como no Rio Içá. Nessa perspectiva, a combinação dos métodos com algoritmos como ANN e RF demonstrou-se eficaz na classificação dos corpos hídricos analisados neste estudo.

Em relação aos classificadores RF e ANN, ambos os algoritmos são capazes de lidar bem com dados multivariados e não lineares, o que significa que, quando os dados de entrada são bem representativos e discriminativos, mesmo métodos com arquiteturas diferentes podem alcançar desempenhos equivalentes. O Random Forest, por exemplo, é robusto a ruído e relativamente eficiente em problemas com variáveis correlacionadas, enquanto as redes neurais artificiais têm maior capacidade de modelar relações complexas, mas também requerem ajustes mais cuidadosos e maior volume de dados para evitar sobreajuste. Nesse caso, é possível que os dados usados na classificação tenham sido suficientemente informativos para que ambos os métodos extraíssem os mesmos padrões relevantes de maneira eficaz. No entanto, quando os dados são relativamente bem adequados e as classes de interesse (como corpos hídricos)

apresentam retroespalhamento radar bem diferenciadas do restante do terreno, ambos os métodos podem atingir desempenhos elevados e similares. Além disso, o pré-processamento adequado das imagens de radar, como a filtragem de ruído e a normalização feitos neste estudo nas polarizações VV e VH, pode reduzir a complexidade inerente aos dados, minimizando as diferenças entre os classificadores. Outro aspecto relevante é que, se o conjunto de treinamento foi representativo e balanceado, ambos os algoritmos tiveram condições de aprender efetivamente os padrões associados à água, resultando em acurácias altas (Yuan et al. 2023; Gautam e Singhai, 2024; Engram et al., 2024; Pech-May et al., 2023).

Com base nas combinações do método PCA e os classificadores, foi demonstrado uma eficácia na extração das informações mais relevantes dos dados, suprimindo a maior parte do ruído e apresentando resultados consistentes, com preservação de bordas e ausência de superestimações significativas em todos os classificadores utilizados, em concordância com os estudos de Li et al. (2024) e He et al. (2024). Nesse contexto, Li et al. (2024) comprovaram que o método PC1, aplicado a imagens GeoFen-3 (SAR), oferece uma alternativa econômica e precisa para o mapeamento de sistemas de canais de maré em zonas estuarinas e costeiras globais, alcançando uma precisão geral de 99,6%. De forma semelhante, He et al. (2024) empregaram o produto PC1-RF em imagens Sentinel-1, obtendo separabilidades estatísticas superiores a 1, com precisões entre 89,84% e 93,73% e coeficientes Kappa variando de 0,85 a 0,91 no estuário do rio Liaohe, na China.

Neste estudo, a PC1 foi aplicada por meio de sua capacidade de redução de dimensionalidade dos três recursos espectrais, gerando um raster que sintetiza informações específicas de alvos aquáticos e não aquáticos. Essa abordagem melhorou a detecção de objetos terrestres e o reconhecimento de alvos nas imagens, além de eliminar características redundantes durante a classificação, otimizando a interpretação e a generalização dos modelos de machine learning. As combinações PC1+ANN e PC1+RF apresentaram erros médios de comissão e omissão de 0,28 e 0,35, respectivamente, enquanto outras combinações tiveram desempenho semelhante (0,27–0,36), sem variações significativas. Resultados análogos foram observados por Bioresita et al. (2025), que utilizaram PC1+RF e GLCM+RF para detecção de corpos d'água na Indonésia, registrando erros de omissão e comissão próximos a 0,26 em imagens Sentinel-1.

Poucos estudos exploram a análise de PCA para detecção de corpos hídricos em imagens combinadas com classificadores de machine learning. Dessa forma, este trabalho representa um avanço pioneiro nessa abordagem, com resultados promissores: acurácias globais acima de 90% para os classificadores testados e corpos hídricos visualmente detectáveis e

separáveis, com valores de separabilidade próximos ao máximo. Portanto, a aplicação da PC1 utilizando as polarizações VV, VH e o índice SEWI como dados de entrada mostra-se uma estratégia viável e eficiente para o mapeamento de corpos hídricos.

Observa-se um desempenho expressivo do índice SAR Enhanced Water Index (SEWI) na detecção de corpos hídricos, tanto visualmente quanto por meio de métricas estatísticas, apresentando elevados valores de separabilidade espectral e notável identificação de pixels correspondentes à água, inclusive quando analisados por produtos híbridos como CP1 e GLCM, além dos classificadores de machine learning empregados. A capacidade de retrodifusão das imagens SAR em superfícies aquáticas permite a implementação de índices espectrais específicos que realçam esses alvos em imagens orbitais. Dentre esses, destaca-se o Sentinel-1A Water Index (SWI), aplicado por Tian et al. (2017) com limiar de classificação de 0,2 para o mapeamento do Lago Poyang, alcançando acurácias globais de 96,52% ($\kappa = 0,8981$) e 96,16% ($\kappa = 0,9102$) nos anos de 2015 e 2017, respectivamente. De forma semelhante, Silva Júnior e Silva Júnior (2021) utilizaram as combinações SDWI+ANN e SWI+ANN para detectar a Barragem de Carpina, em Pernambuco, atingindo acurácias entre 96% e 98% quando comparadas a mapas oficiais de corpos hídricos. Resultados análogos foram observados no presente estudo, com acurácias globais consistentemente superiores a 92%, atingindo valores superiores a 98% em corpos d'água como o Lago Paranoá e o Açude Eng. Ávidos, evidenciando uma alta concordância geral com os dados de referência. Contudo, destaca-se que acurácias globais elevadas podem ocultar limitações em métricas específicas, como os erros de omissão (EO) e de comissão (EC), os quais indicam tendências de subdetecção e sobredetecção, respectivamente. Por exemplo, no caso do Rio Içá, ambos os classificadores apresentaram EO elevados (0,41 para ANN e 0,40 para RF), sugerindo que uma parcela significativa da superfície aquática não foi identificada. Em contraste, os valores de EC foram relativamente baixos (0,19 para ANN e 0,20 para RF), apontando para uma baixa incidência de falsas classificações de áreas como água. Esse comportamento pode estar associado à dificuldade do índice SEWI em representar adequadamente corpos hídricos com características espectrais ou geomorfológicas particulares, como os observados no Rio Içá.

Por outro lado, em ambientes com corpos hídricos mais homogêneos, como as lagoas do Pantanal, os classificadores apresentaram desempenho significativamente superior, com valores de recall próximos de 0,99 e coeficiente de Sørensen-Dice de 0,98, indicando uma concordância quase perfeita com os mapas de referência. Este desempenho pode ser atribuído à maior estabilidade e uniformidade espectral dessas feições, facilitando sua detecção automática. Um aspecto relevante observado foi a discrepância entre a alta acurácia global e

valores moderados de Sørensen-Dice em alguns casos, como no Açude Serrinha II, que apresentou AG de aproximadamente 97%, mas coeficiente de Sørensen-Dice de apenas 0,7. Essa divergência sugere que, embora a maioria das classificações esteja correta em termos absolutos, a sobreposição espacial entre as áreas classificadas como água e as áreas reais é limitada, possivelmente devido a erros de delimitação ou inconsistências localizadas.

De maneira comparável, o índice SDWI (Sentinel-1 Dual-polarization Water Index) tem apresentado desempenho robusto, conforme evidenciado por Li et al. (2023), que obtiveram acurácia global de 98,71% ao combiná-lo com classificadores baseados em aprendizagem profunda. Da mesma forma, Du et al. (2023) aplicaram o SDWI para extrair áreas alagadas do Lago Salgado, em Hoh Xil, utilizando segmentação por limiar e observaram que os dados derivados da combinação das polarizações VV e VH superaram os resultados obtidos com polarizações individuais. A curva estatística do SDWI permitiu, ainda, a determinação rápida e precisa dos limites dos corpos hídricos.

Em síntese, os resultados indicam que a integração do índice SEWI com algoritmos de machine learning é uma estratégia promissora para o mapeamento de corpos d'água, embora seu desempenho esteja fortemente condicionado às características regionais e morfológicas dos alvos. A similaridade nos desempenhos obtidos com os classificadores ANN e RF sugere que a escolha entre eles pode ser guiada por critérios secundários, como tempo de processamento ou facilidade de implementação, sem comprometer significativamente a acurácia do mapeamento.

4 CONCLUSÃO

Neste estudo, foram utilizadas imagens do satélite Sentinel-1, cobrindo nove corpos hídricos do Brasil, com o objetivo de analisar o desempenho da extração de áreas alagadas por meio da aplicação do índice SEWI, seu produto de textura (GLCM) e a primeira componente principal (PC1), combinados com os algoritmos de classificação Random Forest (RF) e Redes Neurais Artificiais (ANN). Além disso, foi avaliada a eficácia da abordagem de aprendizado integrado sob diferentes métodos. A comparação dos resultados foi realizada por meio de interpretação visual e análise quantitativa da acurácia. As principais conclusões são as seguintes:

(1) O índice SEWI demonstrou-se eficaz na separação de pixels de água e não água, o que é particularmente vantajoso, considerando a maior complexidade das imagens de radar na

distinção entre alvos da superfície terrestre, em comparação com sensores ópticos passivos. Essa eficácia foi mantida mesmo após a aplicação de técnicas de redução de textura (GLCM) e de dimensionalidade (PC1), com boa separabilidade estatística e identificação visual clara das áreas alagadas — inclusive em ambientes com ruído significativo, como observado na Lagoa Paranoá.

(2) A forma dos corpos hídricos e a cobertura do solo em seu entorno influenciaram na detecção. Corpos hídricos rodeados por áreas de maior complexidade de classes, como o Lago Paranoá, apresentaram superestimções. Por outro lado, os corpos d'água localizados no bioma amazônico mostraram melhor desempenho devido à menor complexidade do entorno, embora áreas rasas — comuns nessa região — tenham ocasionado omissões nos resultados. Corpos hídricos com formas mais compactas, como as lagoas do Pantanal e o Lago do Salsa, apresentaram melhores resultados. No Nordeste, onde o corpo hídrico principal é cercado por diversos corpos menores, recomenda-se uma análise visual prévia, pois o método identificou também os corpos secundários, o que pode gerar interpretações equivocadas em regiões onde esse padrão não é comum. No geral, mesmo diante da diversidade morfológica dos corpos hídricos analisados, o método obteve boa precisão na identificação das áreas de água.

(3) Os classificadores RF e ANN apresentaram desempenho semelhante, com acurácia global superior a 90% e variações de precisão entre corpos hídricos inferiores a 2%. A elevada qualidade dos dados de radar Sentinel-1, expressa pelo índice SEWI, contribuiu para uma clara distinção entre áreas alagadas e outras classes, facilitando o processo de classificação. Quando as características espectrais e texturais da água são bem definidas — como nas combinações com GLCM e PC1 —, a complexidade do modelo de classificação tem menor influência no desempenho final, permitindo que diferentes algoritmos produzam resultados similares.

(4) Com base no desempenho observado, conclui-se que a metodologia empregada é promissora para o monitoramento automático e preciso dos corpos hídricos no Brasil, permitindo estimar a distribuição espacial da água e contribuindo com informações valiosas para a gestão hídrica em níveis local, regional e nacional. Além disso, o índice SEWI mostrou-se adequado para mapear a distribuição regional dos corpos d'água, possibilitando a criação de mapas contínuos e de longo prazo da dinâmica hídrica. O enriquecimento do acervo de imagens Sentinel-1, aliado ao uso de classificadores avançados, apresenta grande potencial para o mapeamento em

larga escala de águas superficiais, com o apoio de dados de sensoriamento remoto de alta resolução espacial e temporal.

(5) Este estudo ressalta a importância para a gestão de recursos hídricos ao propor e validar uma metodologia inovadora e automatizada para a detecção de corpos d'água utilizando imagens SAR do Sentinel-1 e o índice espectral SEWI, combinado com técnicas de aprendizado de máquina supervisionadas e não supervisionadas. A abordagem demonstra alta acurácia (acima de 95%) e robustez em diferentes contextos geográficos do Brasil, permitindo monitoramento contínuo, preciso e em alta resolução temporal. Isso viabiliza a identificação de variações sazonais e antrópicas na superfície da água, oferecendo suporte essencial para o planejamento, alocação e conservação de recursos hídricos, além de fortalecer a capacidade de resposta a eventos extremos como secas e inundações, em linha com os Objetivos de Desenvolvimento Sustentável.

REFERÊNCIAS

- ADUGNA, T.; XU, W.; FAN, J. Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. **Remote Sensing**, v. 14, n. 3, p. 574, 2022.
- ALONSO-SARRIA, F.; VALDIVIESO-ROS, C.; MOLINA-PÉREZ, G. Detecting Flooded Areas Using Sentinel-1 SAR Imagery. **Remote Sensing**, v. 17, n. 8, p. 1368–1368, 2025. Multidisciplinary Digital Publishing Institute. Acesso em: 15/4/2025.
- BALLING, J.; HEROLD, M.; REICHE, J. How textural features can improve SAR-based tropical forest disturbance mapping. **International journal of applied earth observation and geoinformation**, v. 124, p. 103492–103492, 2023. Elsevier BV. Acesso em: 13/1/2024.
- BHADRA, T.; HAZRA, S.; SINHA RAY, S. P.; BARMAN, B. C. Assessing the groundwater quality of the coastal aquifers of a vulnerable delta: A case study of the Sundarban Biosphere Reserve, India. **Groundwater for Sustainable Development**, v. 11, p. 100438, 2020.
- BIORESITA, F.; LARASTIKA, T. S. F.; TAUFIK, M.; HAYATI, N.; PUTRI TASLYANTO, C. A. Integration of Texture and PCA Information from Sentinel-1 SAR Data for Land Cover-Analysis using Random Forest Classifier Method in Sidoarjo Regency, Indonesia. **Forum Geografia**, v. 39, n. 1, p. 38–52, 2025. Universitas Muhammadiyah Surakarta. Disponível em: <<https://journals2.ums.ac.id/index.php/fg/article/view/6045>>. Acesso em: 6/5/2025.
- CHEN, L.; LI, S.; BAI, Q.; et al. Review of Image Classification Algorithms Based on Convolutional Neural Networks. **Remote Sensing**, v. 13, n. 22, p. 4712, 2021. Disponível em: <<https://www.mdpi.com/2072-4292/13/22/4712>>.
- CHUGHTAI, A. H.; ABBASI, H.; KARAS, I. R. A review on change detection method and accuracy assessment for land use land cover. **Remote Sensing Applications: Society and Environment**, v. 22, p. 100482, 2021.
- DU, Q.; LI, G.; CHEN, D.; et al. Extracting water body data based on SDWI and threshold segmentation: A case study in permafrost area surrounding Salt Lake in Hoh Xil, Qinghai-Tibet Plateau, China. **Research in Cold and Arid Regions**, v. 15, n. 4, p. 202–209, 2023. Elsevier. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2097158323000460?via%3Dihub>>.
- ENGRAM, M.; MEYER, F. J.; BROWN, D. R. N.; et al. Detecting early winter open-water zones on Alaska rivers using dual-polarized C-band Sentinel-1 synthetic aperture radar (SAR). **Remote Sensing of Environment**, v. 305, p. 114096, 2024. Elsevier. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S003442572400107X>>.
- FAKHRI, F.; GKANATSIOS, I. Quantitative evaluation of flood extent detection using attention U-Net case studies from Eastern South Wales Australia in March 2021 and July 2022. **Scientific Reports**, v. 15, n. 1, 2025. Nature Portfolio. Disponível em: <<https://www.nature.com/articles/s41598-025-92734-x>>.
- FILIPPONI, F. Sentinel-1 GRD Preprocessing Workflow. *Proceedings*, v. 18, n. 1, p. 11, 2019. GAO, M.; DONG, W.; CHEN, L.; WU, Z. Automatic Extraction of Water Body from

SAR Images Considering Enhanced Feature Fusion and Noise Suppression. **Applied Sciences**, v. 15, n. 5, p. 2366–2366, 2025. Multidisciplinary Digital Publishing Institute.

GAUTAM, S.; SINGHAI, J. Enhanced Water-body Texture Extraction from GF-2 Satellite Imagery Using Transfer Learning Approach with Gray Level Difference Matrix. 2024 **IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)**, p. 1–6, 2024.

GIGLIO, L.; BOSCHETTI, L.; ROY, D. P.; HUMBER, M. L.; JUSTICE, C. O. The Collection 6 MODIS burned area mapping algorithm and product. **Remote Sensing of Environment**, v. 217, p. 72–85, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0034425718303705>>.

HE, J.; WANG, C.; HAN, Y.; et al. Wetland mapping in the Liaohe River Estuary using multi-source remote sensing image feature selection. **International Journal of Remote Sensing**, v. 45, n. 18, p. 6624–6650, 2024. Taylor & Francis.

HU, X.; ZHANG, P.; ZHANG, Q.; WANG, J. Improving wetland cover classification using artificial neural networks with ensemble techniques. **GIScience & Remote Sensing**, v. 58, n. 4, p. 603–623, 2021. Taylor & Francis.

JIN, S.; LIU, Y.; FAGHERAZZI, S.; et al. River body extraction from sentinel-2A/B MSI images based on an adaptive multi-scale region growth method. **Remote Sensing of Environment**, v. 255, p. 112297, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0034425721000158?via%3Dihub>>.

JING, F.; SHAOHAI, H.; XIAOLE, M. SAR image de-noising via grouping-based PCA and guided filter. **Journal of Systems Engineering and Electronics**, v. 32, n. 1, p. 81–91, 2021.

KADAM, S.; KADAM, A.; JAMDADE, S.; et al. Evaluation of Random Forest algorithms for mapping of land use land cover using remote sensing data for Baitarani River. **International Journal of Information Technology**, 2025.

KAJÁRI, B.; TOBAK, Z.; TÚRI, N.; BOZÁN, C.; VAN LEEUWEN, B. Prediction of Inland Excess Water Inundations Using Machine Learning Algorithms. **Water**, v. 16, n. 9, p. 1267, 2024. MDPI AG.

KUBENDIRAN I.; RAMAIAH M. Modeling, Mapping and Analysis of Floods Using Optical, Lidar and SAR Datasets—a Review. **Water Resources**, v. 51, n. 4, p. 438–448, 2024. Pleiades Publishing.

KUPIDURA, P. The Comparison of Different Methods of Texture Analysis for Their Efficacy for Land Use Classification in Satellite Imagery. **Remote Sensing**, v. 11, n. 10, p. 1233, 2019.

LI, H.; XU, Z.; ZHOU, Y.; HE, X.; HE, M. Flood Monitoring Using Sentinel-1 SAR for Agricultural Disaster Assessment in Poyang Lake Region. **Remote Sensing**, v. 15, n. 21, p. 5247–5247, 2023. Multidisciplinary Digital Publishing Institute.

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**, v. 14, n. 1, p. 30, 2021. Acesso em: 8/3/2023.

LI, P.; LI, S.; LI, Z.; LIANG, C.; WANG, H. Detailed detection and extraction of estuarine tidal channels with multispectral and full-polarised SAR remote sensing. **Earth Surface Processes and Landforms**, v. 49, n. 12, p. 3968–3988, 2024. Wiley. Acesso em: 6/5/2025.

LIBONATI, R.; DACAMARA, C.; SETZER, A.; MORELLI, F.; MELCHIORI, A. An Algorithm for Burned Area Detection in the Brazilian Cerrado Using 4 μm MODIS Imagery. **Remote Sensing**, v. 7, n. 11, p. 15782–15803, 2015.

LÓPEZ-CALOCA, A. A.; TAPIA-SILVA, F. O.; LÓPEZ, F.; et al. Analyzing short term spatial and temporal dynamics of water presence at a basin-scale in Mexico using SAR data. **GIScience & Remote Sensing**, v. 57, n. 7, p. 985–1004, 2020. Taylor & Francis. Acesso em: 6/5/2025.

MAXWELL, A. E.; WARNER, T. A.; GUILLÉN, L. A. Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review. **Remote Sensing**, v. 13, n. 13, p. 2450, 2021.

MELION, K.; LEGESSE, A. Machine Learning for Urban Land Use/ Cover Mapping: Comparison of Artificial Neural Network, Random Forest and Support Vector Machine, A Case Study of Dilla Town. **Heliyon**, v. 0, n. 0, 2024. Elsevier. Disponível em: <[https://www.cell.com/heliyon/fulltext/S2405-8440\(24\)15177-8](https://www.cell.com/heliyon/fulltext/S2405-8440(24)15177-8)>.

NOI, P. T.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors (Basel, Switzerland)**, v. 18, n. 1, p. 18, 2017. MDPI. Disponível em: <<https://www.ncbi.nlm.nih.gov/pubmed/29271909>>.

PARENTE, C.; ALCARAS, E.; FIGLIOMENI, F. G. Coastline Automatic Extraction from Medium-Resolution Satellite Images Using Principal Component Analysis (PCA)-Based Approach. **Remote Sensing**, v. 16, n. 10, p. 1817, 2024. Acesso em: 22/11/2024.

PECH-MAY, F.; AQUINO-SANTOS, R.; DELGADILLO-PARTIDA, J. Sentinel-1 SAR Images and Deep Learning for Water Body Mapping. **Remote Sensing**, v. 15, n. 12, p. 3009–3009, 2023. Multidisciplinary Digital Publishing Institute.

QIN, C.-H.; LI, W.-B.; ZHANG, T.-Y.; et al. Improved DeepLabv3+ Based Flood Water Body Extraction Model for SAR Imagery. **IEEE International Geoscience and Remote Sensing Symposium**, v. 0, p. 1196–1199, 2024. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10640606?casa_token=Uk6SH3p9alcAAAAA:hOeiH2W5ggFQYOhcEjih23KWeJ5oUNOKzWBrNTDS2JFa2BHI9Qd8Hg7jbUkKShywV89mBLYMrm8>.

QIN, Y.; YIN, X.; LI, Y.; et al. High-precision flood mapping from Sentinel-1 dualpolarization SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, p. 1–1, 2025. Institute of Electrical and Electronics Engineers. Disponível em: <<https://ieeexplore.ieee.org/document/10947589>>. Acesso em: 6/5/2025.

QUAN, Y.; ZHANG, R.; LI, J.; et al. Learning SAR-Optical Cross Modal Features for Land Cover Classification. **Remote Sensing**, v. 16, n. 2, p. 431–431, 2024. Multidisciplinary Digital Publishing Institute.

SCHLAFFER, S.; CHINI, M.; DORIGO, W.; PLANK, S. Monitoring surface water dynamics in the Prairie Pothole Region of North Dakota using dual-polarised Sentinel-1 synthetic aperture radar (SAR) time series. **Hydrology and Earth System Sciences**, v. 26, n. 3, p. 841–860, 2022.

SONG, Huina; WANG, Bingyan; QIAN, Xiaojun; GU, Yuehan; JIN, Guodong; YANG, Rui. Enhancing Water Extraction for Dual-Polarization SAR Images Based on Adaptive Feature Fusion and Hybrid MLP Network. *Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, [S.L.], v. 18, p. 6953–6967, 2025. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/jstars.2024.3523550>.

TANMAY, B.; AVINASH CHOUHAN; DIBYAJYOTI CHUTIA; ALEXY BHOWMICK; RAJU, N. Flood Detection Using Multispectral Images and SAR Data. *Communications in Computer and Information Science*, p. 294–303, 2020. **Springer Nature**. Disponível em: <https://www.researchgate.net/publication/342399304_Flood_Detection_Using_Multispectral_Images_and_SAR_Data>.

TAVUS, B.; KOCAMAN, S.; GOKCEOGLU, C. Flood damage assessment with Sentinel-1 and Sentinel-2 data after Sardoba dam break with GLCM features and Random Forest method. **Science of The Total Environment**, v. 816, p. 151585, 2022.

TIAN, B.; ZHANG, F.; LANG, F.; et al. A Novel Water Index Fusing SAR and Optical Imagery (SOWI). **Remote Sensing**, v. 14, n. 21, p. 5316, 2022. MDPI AG. Disponível em: <<https://www.mdpi.com/2072-4292/14/21/5316>>.

TIAN, H.; LI, W.; WU, M.; et al. Dynamic Monitoring of the Largest Freshwater Lake in China Using a New Water Index Derived from High Spatiotemporal Resolution Sentinel-1A Data. **Remote Sensing**, v. 9, n. 6, p. 521, 2017.

VASILAKOS, C.; KAVROUDAKIS, D.; GEORGANTA, A. Machine Learning Classification Ensemble of Multitemporal Sentinel-2 Images: The Case of a Mixed Mediterranean Ecosystem. **Remote Sensing**, v. 12, n. 12, p. 2005, 2020.

WAN, J.; WANG, J.; ZHU, M. Water Extraction from Fully Polarized SAR Based on Combined Polarization and Texture Features. **Water**, v. 13, n. 23, p. 3332, 2021. MDPI AG.

YANG, Shengping; GAO, Hua; LI, Yue; GUO, Yaqi; FAN, Linmiao; LIAO, Mingsheng. Sentinel-1-Based Analysis of the 2024 Tuanzhouyuan Dike Breach Disaster in Dongting Lake and Regional Risk Assessment. *Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, [S.L.], v. 18, p. 17449–17459, 2025. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/jstars.2025.3586897>.

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

YUAN, Q.; WU, L.; HUANG, Y.; GUO, Z.; LI, N. Water-Body Detection From Spaceborne SAR Images With DBO-CNN. **IEEE Geoscience and Remote Sensing Letters**, v. 20, p. 1–5, 2023.

ZHANG, X.; LIN, X.; FU, D.; et al. Comparison of the Applicability of J-M Distance Feature Selection Methods for Coastal Wetland Classification. **Water**, v. 15, n. 12, p. 2212, 2023.

ZHAO, F.; FENG, S.; XIE, F.; ZHU, S.; ZHANG, S. Extraction of long time series wetland information based on Google Earth Engine and random forest algorithm for a plateau lake basin – A case study of Dianchi Lake, Yunnan Province, China. **Ecological Indicators**, v. 146, p. 109813–109813, 2023.

ZHAI, M. et al. Water Body Extraction Methods for SAR Images Fusing Sentinel-1 Dual-Polarized Water Index and Random Forest. **Sensors**, v. 25, n. 15, p. 4868, 2025.