

## IDENTIFICAÇÃO DE CORPOS HÍDRICOS EM SÉRIE TEMPORAL DE RADAR SENTINEL-1

**Evelyn de Castro Porto Costa<sup>1</sup>**

Universidade Federal Fluminense  
Niterói, RJ, Brasil

**Mikaella Pereira dos Santos<sup>2</sup>**

Universidade Federal Fluminense  
Niterói, RJ, Brasil

**Eduardo Thomaz de Aquino Ribeiro<sup>3</sup>**

Universidade Federal Fluminense  
Niterói, RJ, Brasil

**Milton Garcia Rosa<sup>4</sup>**

Universidade Federal Fluminense  
Niterói, RJ, Brasil

**Paula Maria Moura de Almeida<sup>5</sup>**

Universidade Federal Fluminense  
Niterói, RJ, Brasil

**Raúl Sanchez Vicens<sup>6</sup>**

Universidade Federal Fluminense  
Niterói, RJ, Brasil

- 
1. Doutoranda em Geografia, POSGEO-UFF. ORCID: <https://orcid.org/0000-0001-7648-6949>. E-mail: [evelyncosta@id.uff.br](mailto:evelyncosta@id.uff.br).
  2. Mestranda em Geografia, POSGEO-UFF. ORCID: <https://orcid.org/0000-0003-1862-5212>. E-mail: [mikaellasantos@id.uff.br](mailto:mikaellasantos@id.uff.br).
  3. Graduando em Geografia, UFF. ORCID: <https://orcid.org/0000-0002-0892-0309>. E-mail: [eduardo\\_aquino@id.uff.br](mailto:eduardo_aquino@id.uff.br).
  4. Graduando em Geografia, UFF. ORCID: <https://orcid.org/0000-0002-0456-6111>. E-mail: [miltongarciarosa@id.uff.br](mailto:miltongarciarosa@id.uff.br).
  5. Doutora em Meio Ambiente. Docente do POSGEO-UFF. ORCID: <https://orcid.org/0000-0003-1575-3366>. E-mail: [paulamoura@id.uff.br](mailto:paulamoura@id.uff.br).
  6. Doutor em Geografia. Docente do POSGEO-UFF. ORCID: <https://orcid.org/0000-0002-4429-806X>. E-mail: [rsvicens@id.uff.br](mailto:rsvicens@id.uff.br)

Enviado em 1 dez. 2022 | Aceito em 10 jul. 2023

**Resumo:** O presente artigo tem o objetivo de contribuir metodologicamente para o mapeamento de corpos hídricos, alvos bastante específicos que demandam critérios minuciosos para sua correta classificação, devido a sua dinâmica. Assim, o estudo se concentra na identificação e cartografia de corpos hídricos no estado do Rio de Janeiro, utilizando técnicas de sensoriamento remoto multitemporal em imagens de Radar. Como metodologia de pesquisa foi utilizado algoritmo de aprendizado de máquina na plataforma *Google Earth Engine*, em imagens de Sentinel 1 – banda C, para a identificação dos alvos. Foi utilizada uma série temporal mensal de imagens de radar, sendo possível testar suas potencialidades na identificação desses objetos. Como resultados obteve-se a classificação e quantificação das coberturas de água do estado do Rio de Janeiro, considerando os 12 meses do ano de 2018. O resultado permitiu identificar a espacialidade dos corpos hídricos, nos diferentes períodos do ano, sem a interferência atmosférica, o que corresponde a um diferencial metodológico na tentativa de mapear a dinâmica anual da inundação. A validação do mapeamento apontou um excelente Índice Kappa (0,93), destacando a potencialidade do uso de imagens de radar para mapeamento de corpos hídricos.

**Palavras-chave:** Imagem de Radar; Sensoriamento Remoto; Aprendizado de Máquina; Google Earth Engine, Água.

## IDENTIFICATION OF WATER BODIES IN SENTINEL-1 RADAR TIME SERIES

**Abstract:** This article aims to address the study carried out for the identification and cartography of water bodies in the state of Rio de Janeiro, using multitemporal remote sensing techniques in Radar images. It's aims to contribute methodologically to the mapping of water bodies and wetlands, very specific targets that require detailed criteria for their correct classification, due to their dynamics. As a research methodology, machine learning algorithms were used on the Google Earth Engine platform, adopting Sentinel 1 – C-band images to identify these objects. A monthly time series of radar images was used, making it possible to test their potential in identifying these objects. As a result, the classification and quantification of the natural coverage of the state of Rio de Janeiro was obtained, considering the 12 months of the year 2018. The result allowed identifying the spatiality of the water bodies, in the different periods of the year, without atmospheric interference, which corresponds to a methodological difference in the attempt to map the annual flood dynamics. Mapping validation showed an excellent Kappa index (0,93), highlighting the potential of using radar images for mapping water bodies.

**Keywords:** Radar Image; Remote sensing; Machine Learning; Google Earth Engine, Water.

## IDENTIFICACIÓN DE MASAS DE AGUA EN SERIE TEMPORAL DE RADAR SENTINEL-1

**Resumen:** Este artículo tiene como objetivo abordar el estudio realizado para la identificación y cartografía de cuerpos hídricos en el estado de Río de Janeiro, utilizando técnicas de teledetección multitemporal en imágenes Radar. Esta investigación pretende contribuir metodológicamente al mapeo de cuerpos de agua y humedales, que constituyen coberturas muy específicas y que requieren criterios detallados para su correcta clasificación, debido a su dinámica. Como metodología de investigación se utilizaron algoritmos de aprendizaje de máquina en la plataforma *Google Earth Engine*, en imágenes Sentinel 1 – banda C para identificar estos objetos. Se utilizó una serie temporal mensual de imágenes de radar, lo que permitió probar su potencial en la identificación de estas coberturas. Como resultado, se obtuvo la clasificación y cuantificación de la cobertura natural del estado de Río de Janeiro, considerando los 12 meses del año 2018. El resultado permitió identificar la espacialidad de los cuerpos de agua, en los diferentes períodos del año, sin interferencia atmosférica, lo que corresponde a un avance metodológico en el intento de mapear la dinámica de crecidas anuales. La validación del mapeo mostró un excelente índice Kappa (0,93), lo que destaca el potencial del uso de imágenes de radar para mapear cuerpos de agua.

**Palabras clave:** Imagen Radar; Detección remota; Aprendizaje automático; Google Earth Engine, Agua.



## Introdução

Atualmente, os avanços tecnológicos têm extrema importância para a própria transformação da ciência geográfica e outras áreas das ditas ciências naturais. De acordo com Fitz (2008), o estudo do espaço geográfico e de seus aspectos ambientais pressupõem uma série de conhecimentos e informações que podem ser rapidamente trabalhados com as novas tecnologias.

No campo das geociências, essas novas tecnologias podem ser entendidas como as geotecnologias, as quais trazem significativos avanços no desenvolvimento de pesquisas, em planejamento e gestão, manejo e em tantos outros aspectos relacionados à estrutura do espaço geográfico (FITZ, 2008). Mencionando aqui alguns exemplos que são englobados pelas geotecnologias, temos as imagens obtidas através de sensoriamento remoto, e os sistemas de

informação geográfica, os chamados SIGs. Todos muito utilizados no que tange os estudos ambientais.

De acordo com Silva e Pestana (2020), o sensoriamento remoto permitiu que diversas áreas do conhecimento avançassem em suas investigações, como por exemplo no monitoramento da dinâmica da superfície terrestre, auxiliando estudos ambientais em diferentes escalas.

Para Vicens et al. (2019), os diversos dados obtidos por sensoriamento remoto da superfície terrestre e o aumento na resolução dos sensores têm incrementado a incorporação de novas técnicas de mapeamento através de processamento digital de imagens e ferramentas de análise espacial em ambiente GIS.

Para Guo et al. (2017), os dados de sensoriamento remoto por satélite fornecem uma ferramenta eficaz e eficiente para detectar áreas de corpos d'água e extensão de inundação em uma grande área.

A água, em toda sua forma, cobre cerca de 74% da superfície terrestre. Esse recurso natural existe em vários estados na Terra, que incluem água doce, água salgada, água em estado gasoso, chuva, neve e gelo (JENSEN, 2009). Apesar dos corpos hídricos estarem presentes em diversas áreas da superfície terrestre, esse recurso natural, muitas das vezes é invisibilizado e ignorado por parte das entidades gestoras e até mesmo pela sociedade em geral, a exemplo, sendo suprimidos e degradados por processos de aterramento, retilinização e pressão urbana, sendo sua gestão feita de maneira irresponsável e prejudicial a natureza e aos seres humanos.

De acordo com Barbosa et al. (2019), a água é vital para o desenvolvimento socioeconômico, assim como para o bem-estar dos seres humanos. Entretanto, devido as pressões antrópicas, os sistemas aquáticos estão em grande vulnerabilidade, e são sensíveis as mudanças ambientais e climáticas. Consideramos então como um passo muito importante o mapeamento dos corpos hídricos no estado do Rio de Janeiro, sendo possível obter prognósticos para uma melhor gestão desses ambientes e apoiar, em etapas posteriores, na identificação dos wetlands, quais permeiam os corpos hídricos.

A Convenção Ramsar (2013) define os *wetlands* como áreas cobertas com água, sejam naturais ou artificiais, permanentes ou temporárias, estagnadas ou em funcionamento, frescas, doce ou salgadas. No Brasil, os *wetlands* são definidos como ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanente ou periodicamente inundados ou com solos encharcados, com as águas podem ser doces, salobras ou salgadas, com comunidades de plantas e animais adaptados à sua dinâmica hídrica (BRASIL, 2015). Nesse sentido, podemos associar os *wetlands* aos corpos hídricos, tendo em vista sua dinâmica de inundação sazonal, podendo este ser mapeado como corpos hídricos em períodos mais úmidos.

Dessa maneira, um estudo que visa investigar o melhor método de classificação das áreas de corpos hídricos, numa perspectiva de análise multitemporal de sua evolução, no recorte espacial do Estado do Rio de Janeiro, pode nos levar principalmente a uma solução replicável em outras áreas, auxiliando no desenvolvimento de estudos sobre essas zonas alagáveis.

Se tratando de um importante aporte metodológico para mapeamentos e diagnósticos de variáveis na superfície terrestre, temos as imagens de radar. O radar é considerado como um importante tipo de dado para este trabalho, devido a disponibilidade de suas séries mensais de imagens, pois a obtenção de séries mensais de dados de sensores óticos é muito prejudicada por causa da cobertura de nuvens.

De acordo com Jensen (2009), os sensores remotos ativos como o radar, geram sua própria energia que é transmitida do sensor para a superfície do terreno (e tem poucas interferências atmosféricas), interage com o terreno produzindo um retroespalhamento da energia, e é registrada

pelo receptor do sensor remoto. Ainda, é importante ressaltar que o RADAR entre os sistemas ativos, é o mais amplamente utilizado para estudos dos recursos naturais da Terra (JENSEN, 2009). O radar também pode ser considerado como um sensor de radiofrequência, que permite a derivação de informações sobre características físicas, como geometria e forma dos alvos. Ainda, os radares possuem a capacidade de prover imagens de altíssima resolução espacial, de modo a independem de condições atmosféricas (PARADELLA, 2005).

É importante ressaltar que séries temporais de imagens de satélite tornam possível a avaliação de fatores de risco e de potencial presentes em ambientes naturais, como os corpos hídricos, visando uma adequação de uso, exploração, conservação, mitigação e priorização de respostas (JUNIOR, 2018).

Essa pesquisa possui relevância metodológica, tendo em vista a realização de classificação temporal mensal, o que se configura como maiores chances de obtenção de resultados que auxiliem no entendimento da variação desses corpos hídricos sazonalmente, sendo possível determinar, através da amplitude máxima desses corpos hídricos, períodos de maior e menor inundação.

De maneira também relevante nesta pesquisa, temos a utilização do algoritmo de classificação Random Forest em séries temporais. Esse algoritmo de classificação é um dos mais utilizados para classificação de uso e cobertura da Terra usando dados de Sensoriamento Remoto, possuindo maior precisão do que outros classificadores e uma otimização da velocidade de processamento selecionando variáveis importantes (PHAN et al. 2020).

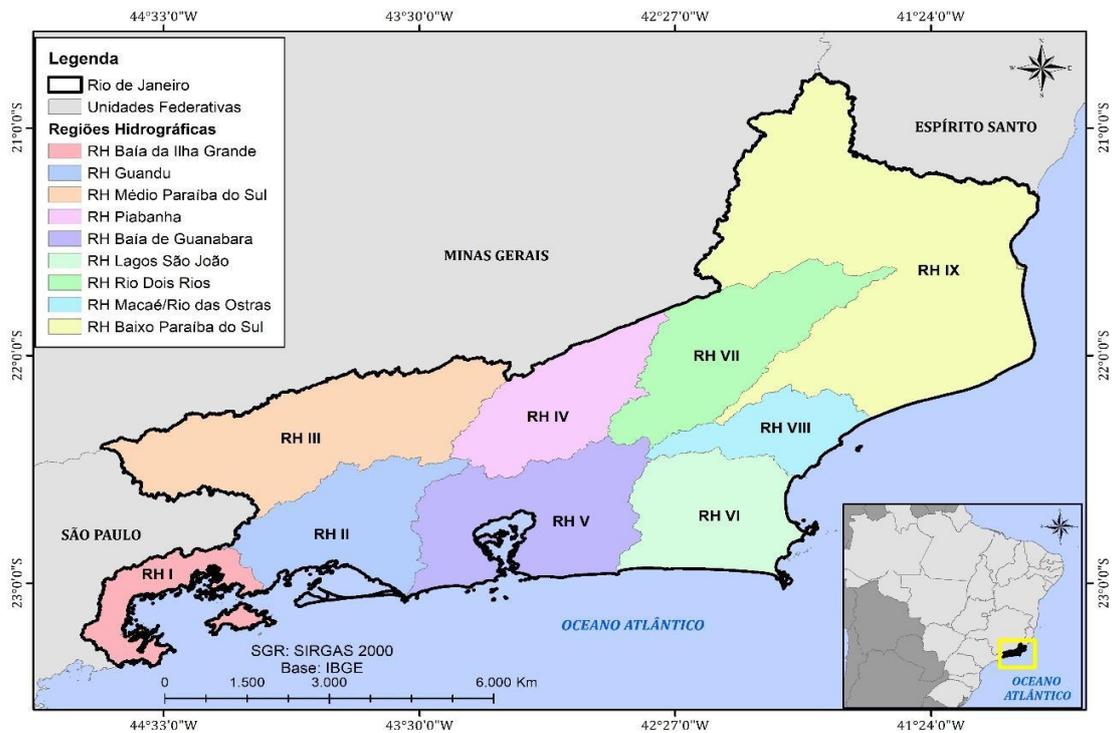
É importante destacar o expressivo avanço do aprendizado de máquina no que tange ao Sensoriamento Remoto. Sabendo que o aprendizado de máquina é advindo da inteligência artificial (IA), e de acordo com Mahesh (2020), o aprendizado de máquina é utilizado para ensinar as máquinas ou computadores a lidar com os dados de maneira mais eficiente, sendo o objetivo dele a aprendizagem com os dados. É importante dizer que ele cada vez mais tem proporcionado variadas possibilidades nos avanços geotecnológicos. Ferreira et al (2020), diz que em diversos estudos têm sido atrelados ao aprendizado de máquina e a análise de séries temporais para melhorar o desempenho nos mapeamentos de uso e cobertura.

De acordo com Noi e Kappas (2018), os métodos de classificação de imagens de sensoriamento remoto são diversos e variam entre algoritmos não supervisionados a algoritmos supervisionados paramétricos e algoritmos de aprendizado de máquina, como redes neurais, k-vizinhos mais próximos, árvores de decisão, máquinas de vetor, florestas aleatórias (*Random Forest*) (NOI e KAPPAS, 2018).

A presente pesquisa também chama atenção para a utilização de uma plataforma popular no âmbito das geotecnologias, como o uso de programação para mapeamento de sistemas terrestres. A plataforma *Google Earth Engine* (GEE), que é baseada em nuvem para processamento computacional de dados geoespaciais em grande escala (GOOGLE, 2022).

A área de estudo (Figura 1), corresponde ao estado do Rio de Janeiro como um todo, com aproximadamente 43.750,45 km<sup>2</sup>. Apesar da abundância de corpos hídricos e *wetlands* de grande diversidade na região hidrográfica do Baixo Paraíba do Sul (RH-IX), outras regiões como a da Baía de Guanabara (RH-V) e a dos Lagos de São João (RH-VI), também é necessário considerar os corpos hídricos alocados em regiões mais interiores.

Figura 1 - Mapa de localização da área de estudos – Estado do Rio de Janeiro



Fonte: Os autores (2022).

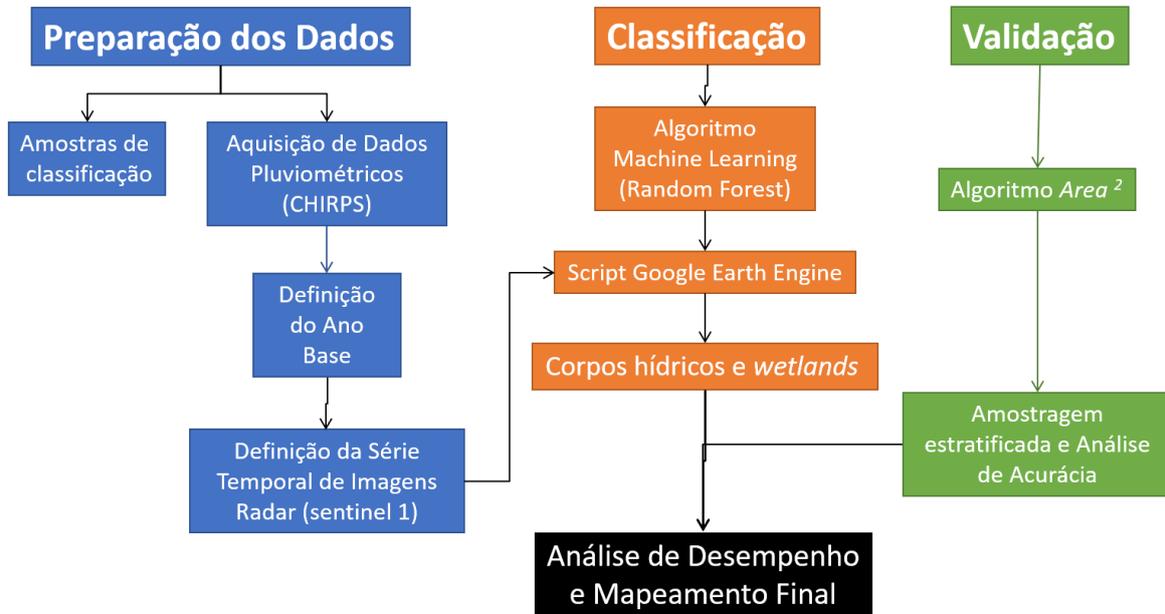
O objetivo da presente pesquisa é contribuir metodologicamente no mapeamento da sazonalidade da água, através de uma análise do desempenho de classificação, utilizando série temporal de imagens de radar e algoritmo de aprendizado de máquina (*Machine Learning*).

Pesquisas sobre sistemas terrestres dinâmicos não são benéficas apenas a comunidade acadêmica e científica, mas são relevantes também para a sociedade em geral, tornando acessível o conhecimento dos seus resultados, trazendo informações da dinâmica que ocorre em determinados espaços, sendo estes fatores importantes para a gestão, preservação e compreensão de áreas ainda pouco estudadas.

## Metodologia

Este trabalho seguiu as etapas metodológicas ilustradas na Figura 2.

Figura 2 - Fluxograma metodológico



Fonte: Os autores (2022).

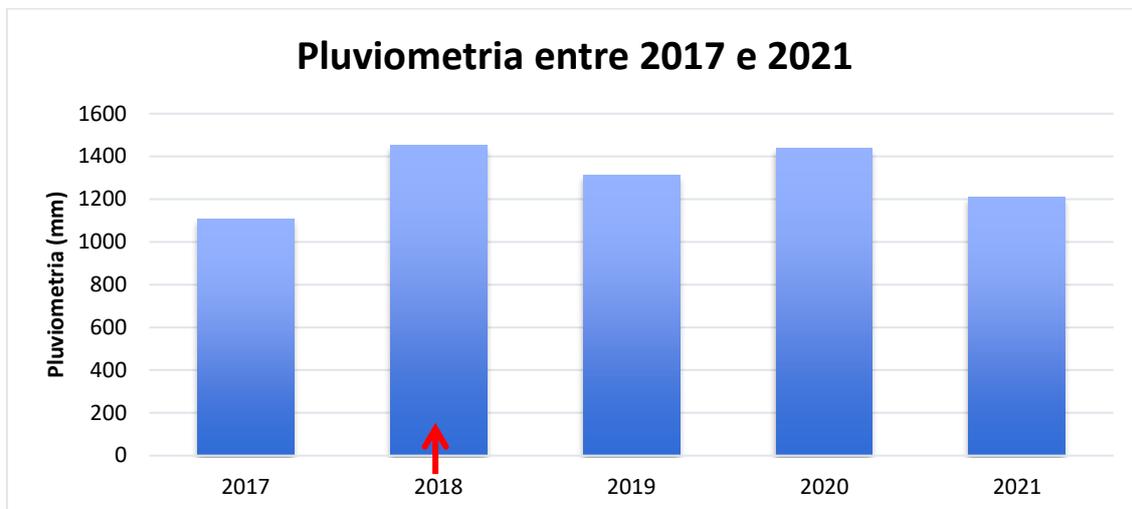
### Preparação dos Dados

Para a preparação e formulação dos dados a serem utilizados foi realizada a busca e avaliação dos dados pluviométricos para todo o Estado do Rio de Janeiro, para que fosse definido o ano-base da classificação. Essa busca foi feita no *Google Earth Engine*, através de um *script* que levanta dados do *Climate Hazards Group InfraRed Precipitation Whit Stations (CHIRPS)*, que de acordo com Rabelo et al (2022), é um produto de precipitação baseado em satélite em grade de longo prazo.

É importante ressaltar que com o avanço tecnológico no campo do Sensoriamento Remoto, a obtenção de dados pluviométricos por satélite se tornou uma alternativa bastante acessível e com tempo de obtenção reduzido, otimizando a aquisição de determinados dados de chuva e mais, sendo possível obter esses dados de áreas onde existem indisponibilidade de estações *in situ*.

Os dados pluviométricos foram coletados em um período de cinco anos, mais especificamente entre o ano de 2017 e 2021 (Gráfico 1) para que fossem avaliados os anos mais úmidos e menos úmidos, se tratando do Rio de Janeiro. Sendo assim, esses dados foram baixados em formato CSV, a partir de um *script* para obtenção destes dados do sensor descrito anteriormente, e trabalhados no software Microsoft Excel do pacote Office 365. Como resultado das análises estatísticas realizadas no software Excel 365, chegou-se ao resultado de que o ano de 2018, foi um dos mais úmidos dos últimos cinco anos (1.452,15 mm), sendo o que melhor atendeu aos objetivos desta pesquisa. Sendo assim, 2018 foi definido como o ano base para empregar a metodologia deste trabalho (Gráfico 1).

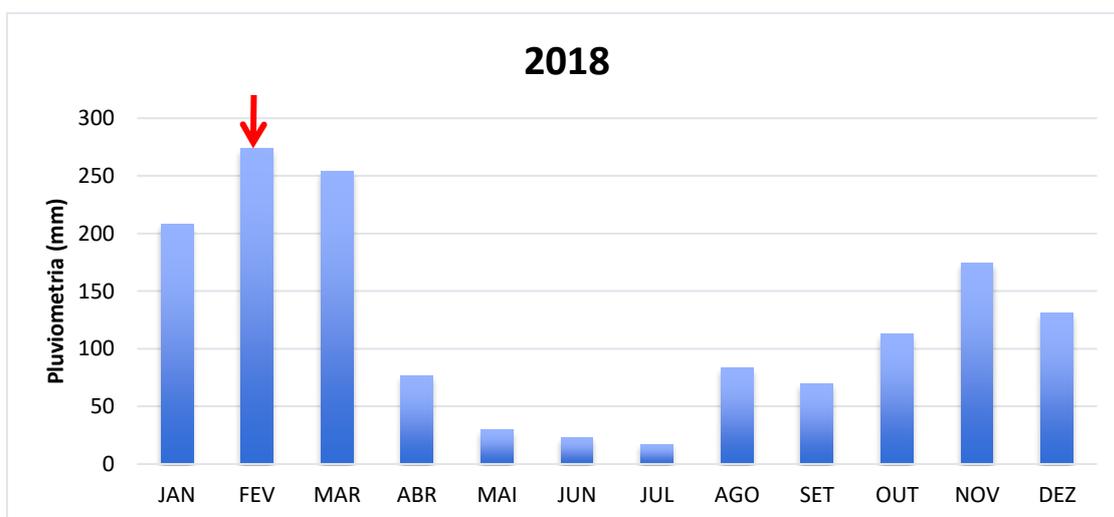
Gráfico 1 - Gráfico de pluviometria (em mm) do estado do Rio de Janeiro entre os anos de 2011 e 2021



Fonte: CHIRPS

Se tratando especificamente do ano de 2018, é possível a visualização da distribuição mensal das precipitações (Gráfico 2). Dentre os doze meses do ano de 2018, podemos verificar através do gráfico que os primeiros três meses do ano foram os mais chuvosos, sendo o mês de fevereiro com o maior índice de pluviosidade (273,69 mm), sendo então usado, dentro do ano de 2018, como o mês base, para a etapa metodológica de classificação deste trabalho.

Gráfico 2 - Gráfico de pluviometria (em mm) ano de 2018



Fonte: CHIRPS

A escolha do ano mais úmido está associada a possibilidade de mapear a água em sua maior amplitude espacial, considerando seu dinamismo sazonal. Ou seja, o ano mais úmido nos permite mapear a água até o seu limite máximo em extensão de alagamento, identificando melhor a sua dinâmica temporal.

Ainda dentro da etapa de preparação dos dados, foi realizado o levantamento das imagens de Radar SAR do satélite Sentinel-1, banda C, para a respectiva área de estudo. Essas imagens já se encontram disponível no acervo do *Google Earth Engine*, sendo implementado um *script* para a visualização dessas imagens. É importante mencionar que o Radar de Abertura Sintética (SAR), possui uma vantagem porque opera em comprimentos de onda que não são impedidos por nuvens ou por falta de iluminação, podendo então obter dados sobre um local tanto de dia ou de noite, sob diversas condições climáticas. Ainda, o Sentinel 1, C-SAR, propicia monitoramento confiável e repetido de uma vasta área (ESA, 2022).

Sendo assim, a opção pela utilização das imagens de Radar e não imagens multiespectrais se deu por um viés metodológico, porque uma importante característica do método de imageamento por Radar é o fato de que a sua aquisição de dados é quase que independe das condições da atmosfera, facilitando sua aplicação em áreas onde a cobertura de nuvens é constante, ou ainda adquirindo informações da superfície terrestre durante períodos de intensa precipitação.

Também na etapa de preparação e aquisição dos dados, foi realizada a coleta de amostras no software *Google Earth Pro*, das classes de água, solo exposto, afloramento rochoso, pastagem, agricultura, áreas urbanas, floresta, areia, mangue, restinga, eucalipto e *wetlands*, utilizadas posteriormente no processo de classificação por *Machine Learning* através do algoritmo de classificação *Random Forest*. A importância de obtenção de distintas classes de uso e cobertura da Terra, se dá no sentido de que as classes possuem diferentes respostas e fazem o papel de auxiliar o classificador na diferenciação do que seja corpos hídricos ou não.

Finalizando a etapa de preparação dos dados para a metodologia deste trabalho, foi realizado um trabalho de campo para o estado do Rio de Janeiro. A realização do trabalho de campo teve como objetivo um melhor reconhecimento da área de estudos, a coleta de amostras por GPS e a obtenção de fotografias georreferenciadas, quais serão utilizadas em etapas posteriores desta pesquisa.

### *Classificação da série temporal*

Na etapa de classificação da pesquisa, foi adotado o aprendizado de máquina como principal técnica. O aprendizado de máquina (*Machine Learning*), se configura como programas computacionais capazes de aprender por si sós, fazendo uso de um aglomerado de dados que representam experiências passadas. Sendo assim, temos como exemplos de aprendizado de máquina: classificação e agrupamento de dados, assim como previsões de séries temporais (CERRI e CARVALHO, 2017).

Os métodos de aprendizado de máquina são bastante amplos, e abrangem algoritmos simples de vizinhos mais próximos a métodos mais complexos como conjuntos de árvores de decisão. De acordo com Chasmer et al. (2020), esses algoritmos são comumente classificadores supervisionados, que dependem de um conjunto de dados de referência ou treinamento para aprender.

Para Paiva et al (2020), nos últimos anos os algoritmos de aprendizado de máquina para classificar o uso e cobertura do solo tem sido essencial para criar modelos que permitam um mapeamento automatizado e recorrente. No âmbito dessa pesquisa foi utilizado o classificador

*Random Forest* (Florestas Aleatórias), que se trata de uma dada combinação de preditores de árvores, onde cada árvore vai depender dos valores de um vetor de forma aleatória, amostrado independentemente e com a mesma distribuição para todas as árvores da floresta (BREIMAN, 2001).

De acordo com Pal (2005), o algoritmo de classificação *Random Forest* é um dos mais usados em classificações de uso e cobertura da terra, já que possui configurações mais simples e capacidade de obtenção de boa acurácia. Foram então adotadas cerca de 3.298 amostras das classes representativas da área de estudos, e após alguns testes, foram utilizadas 500 árvores de decisão para aumentar a possibilidade de classificação do algoritmo.

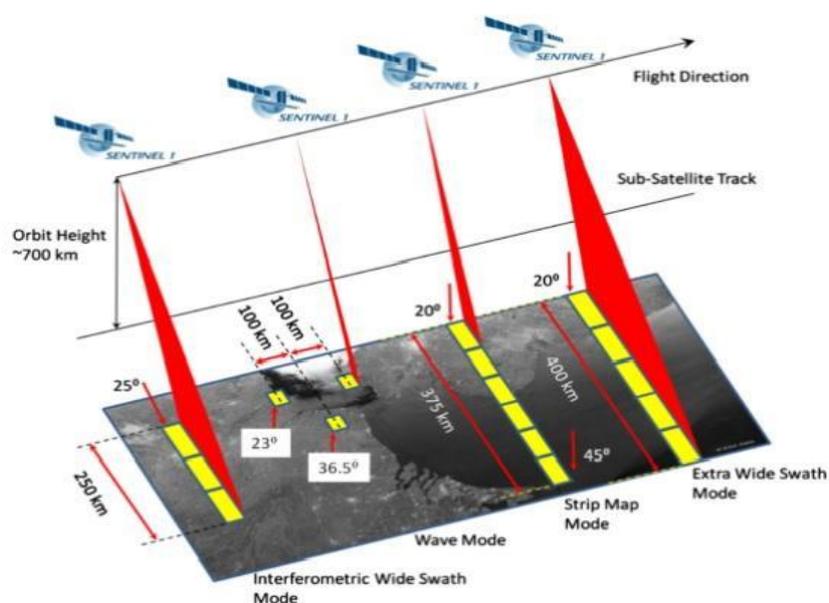
Foram utilizadas as imagens de Radar Sentinel-1A, banda C, com resolução espacial de 10 metros. Esse satélite beneficia diversos serviços, como o monitoramento de florestas, água, solo e agricultura.

No caso do Sentinel-1, a imagem gerada é correspondente ao sistema SAR e suas principais aplicações são para monitorização de gelo e ambientes polares, monitoração de movimentos da superfície terrestre e cartografia de florestas, água, solo e agricultura. Os sistemas SAR são considerados como uma implementação específica dos sistemas RADAR que faz uso do movimento da plataforma e processamento especializado de sinal para a geração de imagens de alta resolução (ESA, 2022).

O SAR do satélite Sentinel-1 opera em quatro modos de aquisição (Figura 3): mapa de tiras (SM), Faixa ampla interferométrica (IW), Faixa extra-larga (EV) e modo de onda (WV). Entretanto, os principais modos livres de conflito são IW sobre terra e WV sobre mar aberto. O modo IW é o modo de aquisição padrão em Terra (ESA, 2022).

Cada cena é formada por uma composição de três observações sobre o solo. A junção das três cenas a) b) c) produz uma imagem de 250 km, com resolução no terreno de 5 x 20 metros (SERVELLO et al. 2015).

Figura 3 - Modos de aquisição das missões Sentinel 1



Fonte: ESA (2019)

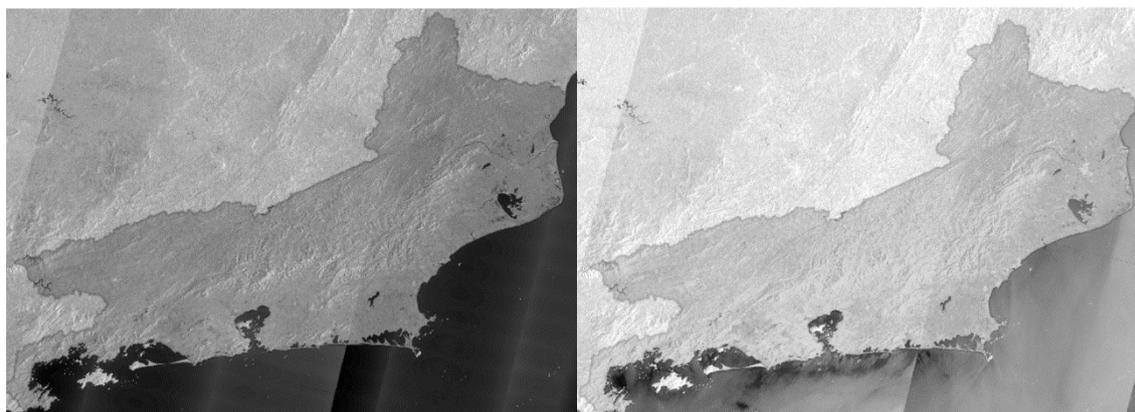
Se tratando das polarizações das imagens de radar, Andrade et al. (2007), diz que diversos radares são projetados para que transmitam a radiação de microondas polarizada horizontalmente e verticalmente. Uma onda eletromagnética transmitida em ambas as polarizações vai resultar em uma onda retroespalhada com variedades de polarizações (ANDRADE et al, 2007).

Ainda de acordo com Andrade et al. (2007) podem existir quatro formas de combinações de polarizações tanto transmitidas como recebidas: HH – recepção e transmissão horizontal; VV – recepção e transmissão vertical; HV – transmissão horizontal e recepção vertical; VH – transmissão vertical e recepção horizontal.

As combinações de polarizações dos sistemas radar também pode ser classificadas em: polarização simples – HH ou VV; polarização dupla – HH e HV, VV e VH ou HH e VV; polarização quádrupla – HH, VV, HV e VH; e completamente polarimétrico – HH, VV, HV, VH, mais a fase relativa entre estas polarizações, componente importante de um radar polarimétrico (ANDRADE et al, 2007).

É importante ressaltar que o satélite Sentinel-1, operado na banda C, tem a capacidade de operar nos modos de dupla polarização (HH-HV ou VV-VH) e polarização única (HH ou VV) (SARAIVA, 2015). O modo mais comum em superfícies continentais é a Interferometric Wide (IW), que é adquirido na polarização VV e VH (figura 4).

**Figura 4** - Imagens de Radar, Sentinel 1 – SAR.



*VH – Transmissão Vertical e Recepção Horizontal    VV – Transmissão e Recepção Vertical*

Fonte: Google Earth Engine

A classificação foi feita para cada um dos 12 meses do ano de 2018, buscando-se identificar a amplitude espacial dos corpos hídricos.

A execução da classificação se deu através do script de classificação adaptado para imagens de Radar no *Google Earth Engine* (GEE). O GEE é acessado e controlado por meio de uma Interface de Programação de Aplicação (API, sigla em inglês) acessível via navegadores web em um Ambiente de Desenvolvimento Interativo (IDE, sigla em inglês), que permite a prototipagem rápida e a visualização dos resultados, sem a necessidade do usuário ser um especialista em desenvolvimento de aplicativos ou programação web (CARVALHO et al, 2021).

Na plataforma GEE o front-end é bastante acessível e de fácil utilização, fornecendo dados interativos e a possibilidade de desenvolvimento de algoritmos. Qualquer usuário da plataforma pode adicionar e selecionar seus próprios dados e coleções, fazendo uso do recurso da nuvem do Google

para realizar e armazenar todo o processamento. Essa plataforma permite com que diversos cientistas e pesquisadores, assim como usuários comuns, consigam minerar uma grande quantidade de dados para detecção de mudanças, mapeamentos de tendências e quantificação de recursos na superfície terrestre (KUMAR E MUTANGA, 2019).

Destaca-se que a classificação realizada no *Google Earth Engine* foi a classificação denominada de pixel a pixel. A classificação denominada de Pixel em Pixel funciona através da utilização, apenas, da informação espectral de cada pixel com o objetivo de encontrar regiões homogêneas. Ainda, se torna relevante dizer que esses classificadores podem ser distintos em métodos estatísticos (utilizando regras da teoria de probabilidade) e determinísticos (que não farão uso da probabilidade) (INPE, 2021).

A maioria dos classificadores trabalham por meio da execução da classificação por pixel, que fará uso somente da informação espectral de cada pixel para que se possa encontrar regiões homogêneas, a partir de medidas de distâncias ou de probabilidades de um pixel ser pertencente a uma classe específica (MENEZES et al, 2012).

A primeira parte da classificação ocorreu de maneira binária: água x não água. Para isso, todas as classes de não água foram agrupadas como 0, sendo as classes corpos hídricos agrupados como 1. Para tanto, foram adotados no script métricas das bandas do Sentinel-1 – banda C, considerando média, mediana, desvio padrão e percentis da banda VV e VH. Ressalta-se que foram geradas métricas para todas as imagens do ano de 2018, considerando a data de início e fim de cada mês daquele ano.

Cabe destacar que essa primeira classificação foi realizada para o mês mais úmido, que segundo os dados do CHIRPS, mencionados anteriormente, se trata do mês de fevereiro de 2018. Após a classificação do mês de fevereiro foi realizada a classificação para os demais meses do ano em estudo, através de *script* com algoritmos para replicação das métricas para os outros meses do ano de 2018.

A classificação realizada foi obtida por meio da adição da coleção dos 12 meses classificados no *software* Quantum Gis (QGIS), através da ferramenta “calculadora raster”, somando todas as classificações, obtendo como resultado uma imagem (raster) única com a amplitude espacial da água no decorrer de um ano, obtendo uma classificação mais completa da água, considerando os períodos secos e úmidos e sua variação sazonal. Ressalta-se que a imagem foi exportada com escala de 10 metros para todo o estado do Rio de Janeiro. Além disso, o raster foi convertido para polígonos, através de *scripts* do GEE.

### *Validação do mapeamento*

No processo de validação deste mapeamento, foi adotada a metodologia por amostragem aleatória e estratificada, no *software* GEE. Para tanto, foi usado o método denominado de AREA<sup>2</sup>, que é a abreviação de Área Estimada & Avaliação de Precisão. Este é um aplicativo do *Google Earth Engine* que fornece suporte abrangente para amostragem e estimativa em uma estrutura de inferência baseada em design (BULLOCK & OLOFSSON, 2018).

O principal objetivo da validação é estimar a precisão específica da classe. A amostragem aleatória estratificada oferece a opção de aumentar o tamanho da amostra em classes que ocupam uma pequena proporção da área para reduzir os erros padrão das estimativas de precisão específicas da classe (OLOFSSON et al, 2014). Foram então adotadas uma quantidade proporcional tanto pela classe de corpos hídricos como pela classe de não água, sendo calculadas pelo próprio *script*, de acordo com a proporcionalidade das classes ao tamanho da área de estudos. Nesse sentido, foram

elencadas cerca de 240 amostras ao total, variadas conforme a quantidade de classes. Foram então adotadas 40 amostras de corpos hídricos (16,7%) e 200 amostras de não água (83,3%). Esse quantitativo de amostras representa cerca de 5% da área de estudos.

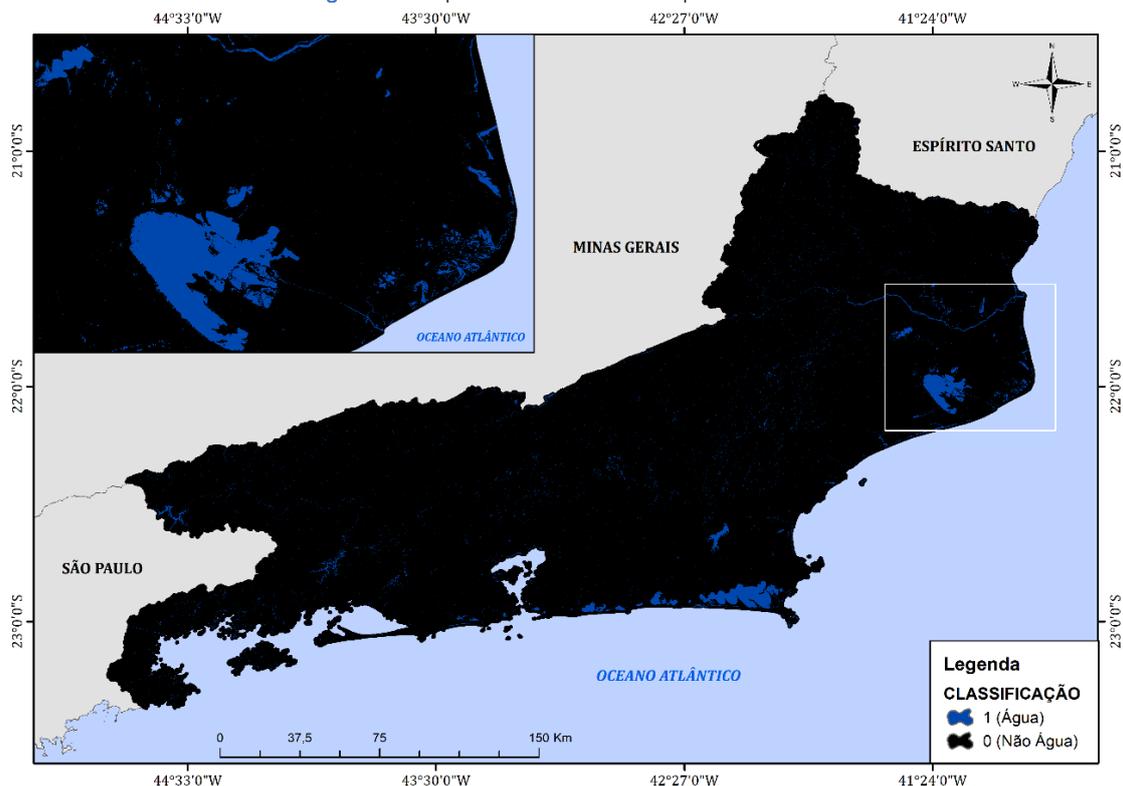
A validação foi realizada por interpretação visual nas imagens de *Google Earth Pro*, considerando imagens de alta resolução do ano de 2018, o que apoia na verificação detalhada do mapeamento. Após, as classes foram inseridas em matriz de confusão para a obtenção da exatidão de produtor e exatidão do usuário.

## Resultados

Como principais resultados obteve-se a classificação (Figura 5) e quantificação das coberturas hídricas naturais do estado do Rio de Janeiro (Tabela 1), considerando a síntese espacial dos 12 meses do ano de 2018, obtido por meio da adição das imagens mensais. Dessa forma, o resultado representa a amplitude máxima dos corpos hídricos. A classificação de maneira temporal permitiu obter como resultado o máximo de cobertura anual dos corpos hídricos, dessa forma, ao considerar o ciclo anual, a classificação identificou a área de maior inundação, considerando os períodos secos e úmidos do ano.

Ao analisarmos o mapa da classificação, é possível a imediata identificação dos corpos hídricos no estado do Rio de Janeiro. Ainda, chama-se a atenção para a captura de corpos hídricos pouco expressivos no sentido de área, o que pode ser considerado um diferencial pela utilização da imagem de radar e de série temporal anual. Em classificações com imagens multiespectrais, pequenos corpos hídricos têm grandes probabilidades de serem subestimados devido à cobertura de nuvens e a dificuldade de se compor o ciclo anual com suficiente resolução temporal, o que dificultaria a detecção de áreas com alagamento em curtos períodos de tempo.

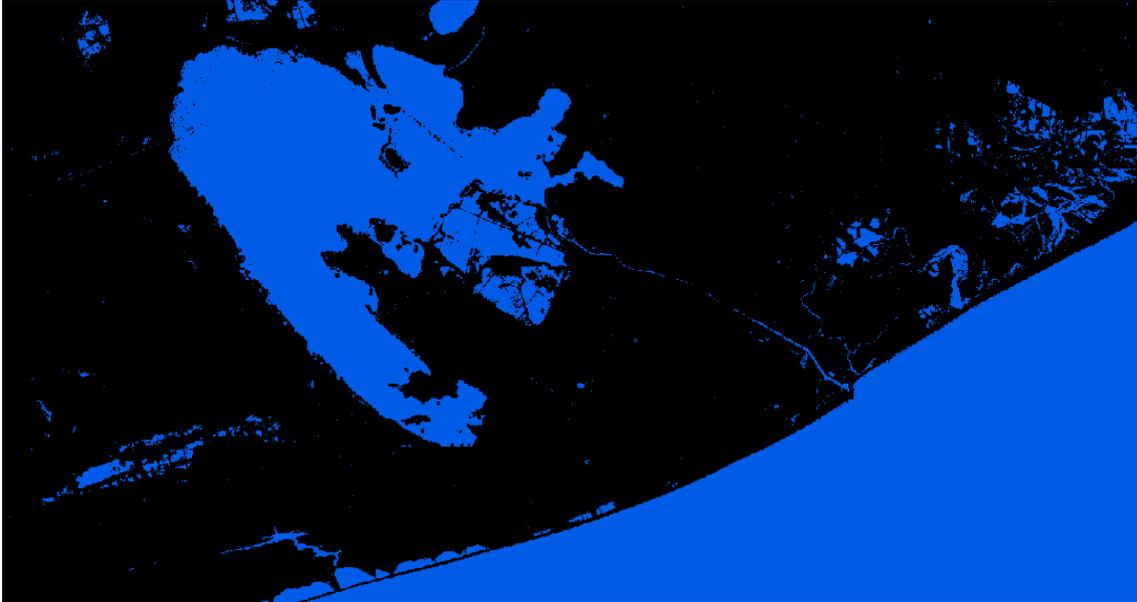
Figura 5 - Mapa de cobertura de corpos hídricos.



Fonte: Os autores, 2022.

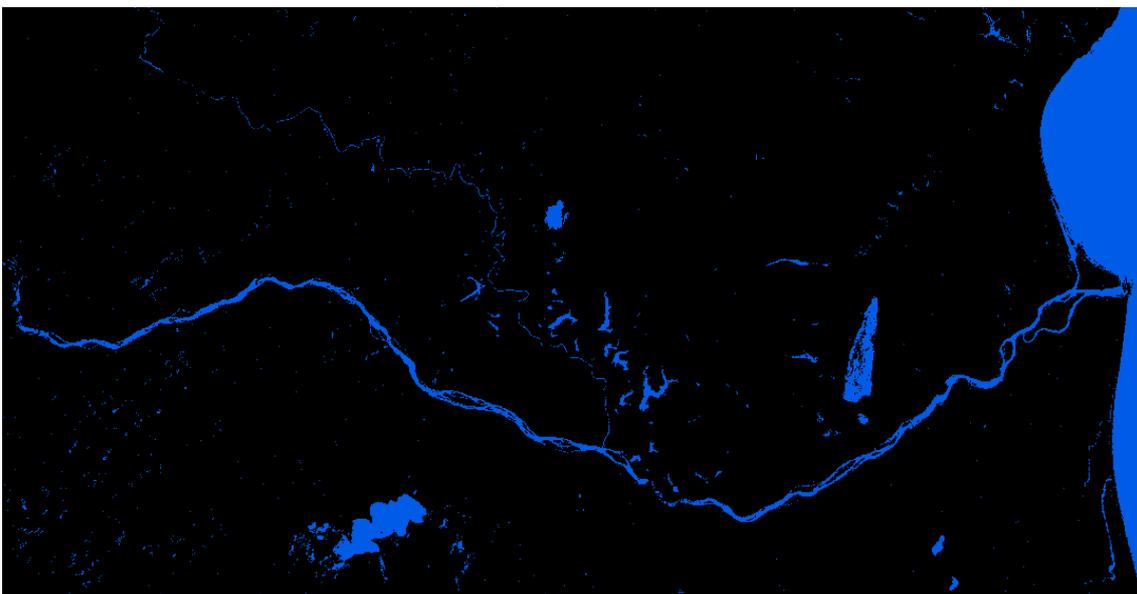
A partir da análise espacial desses objetos ressalta-se a identificação dos espelhos d'água maiores, como as lagoas do leste fluminense, tal como a Lagoa de Araruama e Juturnaíba, além da Lagoa Feia (Figura 6).

**Figura 6** - Detalhamento do mapeamento de espelhos d'água (Lagoa Feia, localizada na divisa dos municípios de Quissamã e Campos dos Goytacazes - RJ).



No Norte Fluminense se destaca o resultado detalhado da detecção de corpos hídricos fluviais, lagunares e costeiros, que apesar da diversidade de ambientes, obteve êxito no mapeamento, captando as formas dos corpos hídricos. (Figura 7).

**Figura 7** - Detalhamento da drenagem fluvial no entorno da Lagoa de Cima e Lagoa do Campelo, localizados em Campos dos Goytacazes



Ressalta-se que além desses espelhos há fragmentos de outros corpos hídricos menores, em diferentes trechos no interior e no litoral do estado do Rio de Janeiro. Observa-se que pela resolução de 10 metros a captação desses alvos foi de maior detalhamento, o que demonstra um expressivo potencial das imagens de radar para a detecção desse objeto.

A obtenção dos resultados quantitativos desta classificação (Tabela 1) pode ser considerado um resultado bastante expressivo, já que a partir da contagem dos pixels classificados é possível, numericamente, identificar a presença dos corpos hídricos sob o estado do Rio de Janeiro. Se tratando da quantificação em pixels, 2,4% dos 100% da classificação são pixels da classe de água. Já na análise poligonal do Rio de Janeiro (Tabela 1), é possível obter como resultado a área total da água existente do território do estado do Rio de Janeiro. Observa-se que é um total de 1.022 km<sup>2</sup> de extensão territorial coberto por água.

**Tabela 1** - Quantificação dos corpos hídricos no Rio de Janeiro

| ID | Classes  | Raster      |      | Polígono        |       |
|----|----------|-------------|------|-----------------|-------|
|    |          | Pixels      | %    | km <sup>2</sup> | %     |
| 1  | Água     | 11.341.434  | 2,4  | 1.022           | 2,33  |
| 2  | Não Água | 463.946.628 | 97,6 | 47.771          | 97,67 |
|    | TOTAL    | 475.288.062 | 100  | 43.793          | 100   |

Fonte: dos autores (2022).

A partir do resultado obtido através da validação do mapeamento (Tabela 2) é possível destacar o excelente desempenho do mapeamento de corpos hídricos. Através da matriz de confusão gerada pela validação do mapeamento se torna possível analisar que a o erro de comissão foi maior que o erro de omissão, e que no geral, o mapeamento obteve um resultado bastante expressivo na sua validação.

Os erros de comissão se referem a classificação errônea de água em áreas de sombras. Dentre as 240 amostras total, apenas 4 foram classificadas equivocadamente como água, sinalizando poucos erros de comissão na classe de "água" e de omissão na classe de "não água".

**Tabela 2** - Matriz de confusão do mapeamento

|                      | Classes  | Verdade |          | Total | Acurácia do Usuário |        | Erro de Comissão |
|----------------------|----------|---------|----------|-------|---------------------|--------|------------------|
|                      |          | Água    | Não Água |       |                     |        |                  |
| Sentinel 1           | Água     | 36      | 4        | 40    | 0,90                | 90,00  | 10,00            |
|                      | Não Água | 0       | 200      | 200   | 1,00                | 100,00 | 0,00             |
|                      | Total    | 36      | 204      | 240   |                     |        |                  |
| Acurácia do Produtor |          | 1,000   | 0,980    |       |                     |        |                  |
| Erro de Omissão      |          | 0,000   | 1,961    |       |                     |        |                  |

Fonte: dos autores (2022).

A validação do mapeamento apontou resultados de excelentes desempenhos (Tabela 3), com uma exatidão global de 0,98 e um Índice Kappa de 0,93. Esse resultado dentro da escala do índice é considerado um excelente resultado de classificação. Além disso, obteve-se 0,98 de aceitação relativa (PO) e 0,73 de taxa hipotética de aceitação (PE). O que representa um bom desempenho de validação, dando confiabilidade ao uso desse mapeamento para diversas finalidades.

Tabela 3 - Quantificação da validação

|                                   |             |
|-----------------------------------|-------------|
| Aceitação Relativa – PO           | <b>0,98</b> |
| Taxa Hipotética de Aceitação – PE | <b>0,73</b> |
| Kappa                             | <b>0,93</b> |
| Exatidão Global                   | <b>0,98</b> |

Fonte: dos autores (2022).

Os resultados atenderam a expectativa proposta de classificar a água em um período anual. Sendo importante mencionar o excelente desempenho do índice Kappa à classificação das imagens Sentinel 1.

### Considerações finais

O objetivo de classificar corpos hídricos em diferentes épocas do ano foi atendido por esta pesquisa, sendo possível realizar seu desenvolvimento através do processamento em nuvem, devido ao grande volume de dados necessários para obter estes resultados.

O desafio metodológico deste trabalho correspondeu ao uso das imagens de radar, do satélite Sentinel-1, banda C. As imagens de radar foram desafiadoras, pois possui muitos parâmetros a serem definidos, tal como, as bandas acessíveis para a área de estudos, tal como as bandas VV e VH.

O uso de limiares necessários para as imagens de radar associadas a necessidade de classificar a cobertura de corpos hídricos, considerando sua dinâmica sazonal no estado do Rio de Janeiro, foram implementados com otimização do tempo de processamento em nuvem, através da plataforma *Google Earth Engine*, e do uso de algoritmos adaptados às imagens SAR e suas especificidades.

Ressalta-se as imagens de radar como importante recurso para esta classificação de corpos hídricos, pois permite uma classificação temporal sem a interferência da atmosfera, principalmente nuvens, que afetam diretamente este resultado. Além disso, o radar possui como diferencial a sua resolução espacial de 10 metros, que entrega um resultado de maior detalhamento a nível de pixel, apoiando a classificação de objetos menores, como o caso da água, que podem ser subestimados nas classificações.

A exploração de metodologias para classificação dos sistemas terrestres dinâmicos é uma vertente de grande relevância para pesquisadores em geoprocessamento. Também é importante ressaltar que o uso de algoritmos computacionais para processamento de imagens de radar é um recurso de grande valia para o sensoriamento remoto.

O uso de radar em classificações de corpos hídricos, alvos complexos no sentido de sua correta identificação, pode ser considerado como um diferencial metodológico e, a abertura de caminhos para diversos outros testes e análises, objetivando um mapeamento cada vez mais detalhado, dando conta de representar corretamente a cobertura desses corpos hídricos e suas dinâmicas sob a superfície terrestre.

A classificação de corpos hídricos, considerando sua respectiva importância, teve através desse mapeamento o avanço de um passo muito significativo e, ademais, abre caminho para análises posteriores, assim como as pretendidas por esses autores.

## Referências

- ANDRADE, N.; S.; O.; ROSA, A.; N.; C.; FARIA, P.; C.; C. (2007); Fundamentos de Polarimetria SAR. *Anais XIII Simpósio Brasileiro de Sensoriamento Remoto*, Florianópolis, Brasil, INPE, p. 4775-4782.
- BARBOSA, C. C. F.; NOVO, E.M.L.M.; MARTINS, V.S (2019). *Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: princípios e aplicações*. 1ª edição. Instituto Nacional de Pesquisas Espaciais. São José dos Campos. 161p.
- BRASIL (2015). *Recomendação CNZU n.º 07, de 11 de junho de 2015*. Brasília, DF. 2015. Disponível em: <https://antigo.mma.gov.br/comunicacao/item/10872-comit%C3%AA-nacional-de-zonas-%C3%BAmidas.html&gt>. Acessado em: 20 de abril de 2022.
- BREIMAN, L (2001). Random Forests. *Machine Learning* 45, 5–32. Disponível em: <https://doi.org/10.1023/A:1010933404324>. Acessado em: 14 de novembro de 2023.
- BULLOCK, E; OLOFSSON, P. (2018) *What is AREA2?* Disponível em: <https://area2.readthedocs.io/en/latest/overview.html>. Acessado em: 14 de novembro de 2023.
- CARVALHO, W. S; FILHO, J.C.M; SANTOS, T.L. (2021); Uso e Cobertura do Solo utilizando a Plataforma Google Earth Engine (GEE): Um estudo de caso em uma unidade de conservação. *Brazilian Journal of Development*, ISSN: 2525-8761.
- CERRI, R.; CARVALHO, A. C. P. L. F. (2017). Aprendizado de máquina: breve introdução e aplicações. *Cadernos de Ciência & Tecnologia, Brasília*, v. 34, n. 3, p. 297-313, set./dez. 2017
- CHASMER, L. et al (2020); Remote Sensing of Boreal Wetlands 2: Methods for Evaluating Boreal Wetland Ecosystem State and Drivers of Change. *Remote Sensing.*, 12, 1321.
- EUROPEAN SPACE AGENCY (ESA) (2019). *Sentinel-1 observation scenario*. Disponível em: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1/instrument-payload>. Acessado em: 14 de novembro de 2023
- FERREIRA, K. R et al (2020). E.O Data Cubes for Brazil Requirements Methodology and Products. *Remote Sensing*. 12, 4033.
- FITZ, Paulo Roberto (2008). *Geoprocessamento sem complicação*. São Paulo: Oficina de Textos.
- GOOGLE, *Google Earth Engine* (2022). Disponível em: <https://earthengine.google.com>. Acessado em: 23 de abril de 2022.
- GUO, M.; LI, J.; SHENG, C.; XU, J.; WU, L. (2017). A Review of Wetland Remote. *Sensors*. 17, 777.
- INPE (2021). *Tutorial do SPRING*, Disponível em: [http://www.dpi.inpe.br/spring/portugues/tutorial/introducao\\_geo.html](http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_geo.html). Acessado em: 23 de jun. de 2021.
- JENSEN, JHON R. (2009) *Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres*. São José dos Campos, SP. 2ª Edição.
- JUNIOR, O.; A.; C. (2018) Aplicações e Perspectivas do Sensoriamento Remoto para o Mapeamento De Áreas Inundáveis. *Revista de Geografia (Recife)* V. 35, No. 4 (especial XII SINAGEO).
- KUMAR, L.; MUTANGA, O. (2019). *Google Earth Engine Applications*. MDPI. Disponível em: <https://www.mdpi.com/2072-4292/11/5/591>. Acessado em: 14 de nov. de 2023.
- MENEZES, P.R.; ALMEIDA, T. (2012). *Introdução ao processamento de imagens de Sensoriamento Remoto*. 1. Ed. Brasília: CNPq, p. 256.
- MAHESH, B. (2020) Machine Learning Algorithms - A Review. *International Journal of Science and Research (IJSR)*. ISSN: 2319-7064. Volume 9 Issue 1, January.
- THANH NOI, P.; KAPPAS, Martin. (2018). Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors* 18, no. 1: 18.
- OLOFSSON, P. et al. (2014) Good practices for estimating area and assessing accuracy of land change. *Remote sensing of Environment*, v. 148, p. 42-57.
- PAIVA, R.; OLIVEIRA, S.; MARTINS, W.; PARENTE, L. (2020) Análise de metacaracterísticas para classificação de uso e cobertura do solo utilizando Random Forest. In: *Anais do workshop de computação aplicada à gestão do meio ambiente e recursos naturais* (WCAMA). Disponível em: <https://sol.sbc.org.br/index.php/wcama/article/view/11021> . Acessado em: 14 de nov. de 2023.

- PARADELLA, W.R. et al; (2005) Radares imageadores nas Geociências: estado da arte e perspectivas. *Revista Brasileira de Cartografia*, v. 57, n. 1, 2005.
- PAL, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1):217–222.
- PHAN, T. N.; KUCH, V.; LEHNERT, L. W. (2020) Land Cover Classification using Google Earth Engine and Random Forest Classifier – The Role of Image Composition. *Remote Sensing*. 12, 2411; doi:10.3390/rs12152411
- RABELO, D.R., SANTOS, M.R., SOUSA FILHO, M.R. (2022). Análise comparativa dos dados pluviométricos de satélite e de superfície em bacia hidrográfica semiárida. *Revista Brasileira de Sensoriamento Remoto*, v.3, n.1, p. 63-75.
- SARAIVA, C.; S.; A. (2015) *Avaliação do Potencial das Imagens Sentinel-1 para Identificação de Culturas Agrícolas*. Universidade de Lisboa. Faculdade de Ciências. Departamento de Engenharia Geográfica, Geofísica e Energia. Dissertação de Mestrado.
- SERVELLO, E. L.; SANO, E. E.; PANTOJA, N. V. (2015) Sentinel-1 SAR: efeito de filtros espaciais no estudo do uso do solo amazônico. In: *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, João Pessoa-PB, Brasil, INPE.
- SECRETARÍA DE LA CONVENCION DE RAMSAR (2013). *Manual de la Convención de Ramsar: Guía a la Convención sobre los Humedales (Ramsar, Irán, 1971)*, 6a. edición. Secretaría de la Convención de Ramsar, Gland (Suiza).
- SILVA, F. S., PESTANA, A. L. M. (2020). Mapeamento da cobertura hídrica da microrregião da Baixada Maranhense com dados do sensor SAR Sentinel 1A. *Revista Brasileira de Sensoriamento Remoto*. v.1, n.2, p.58-71.
- VICENS, R. S.; RODRIGUEZ, J. M.; CRONEMBERGER, F. M. (2019) A Paisagem Físico-Geográfica: Representação Cartográfica. *Revista Brasileira de Geografia*, Rio de Janeiro, v. 64, n. 2, p. 2-17.