



# Desempenho da classificação supervisionada de Campos de Murundus a partir da integração de dados de radar e ópticos

Performance of supervised classification of Murundus Fields from the integration of radar and optical data

R. H. Roncari\*; A. G. Utsumi

*Instituto de Ciências Tecnológicas e Exatas, Universidade Federal do Triângulo Mineiro, 38025-180, Uberaba-Minas Gerais, Brasil*

\*d202111459@ufmt.edu.br

(Recebido em 11 de junho de 2025; aceito em 09 de outubro de 2025)

As áreas úmidas estão localizadas na interface entre ambientes terrestres e aquáticos, desempenhando funções ecossistêmicas importantes em escala regional e global. Os Campos de Murundus são áreas úmidas típicas do bioma Cerrado, as quais enfrentam ameaças devido à atividade humana e mudanças climáticas, tornando essencial seu monitoramento e conservação. Este estudo tem como objetivo avaliar a acurácia da classificação supervisionada dos Campos de Murundus na bacia do rio Claro, situada no Triângulo Mineiro (MG), a partir da combinação de dados de sensor óptico e de radar. Para isso, foram utilizadas imagens de radar do satélite Sentinel-1 e do modelo digital de elevação Copernicus DEM, bem como imagens ópticas do satélite Sentinel-2A e o índice espectral NDWI. Utilizou-se a plataforma Google Earth Engine (GEE) para criar modelos distintos, variando os tipos de dados de entrada e a escala temporal. Os resultados mostraram que, ao longo de um ano, a utilização combinada de todos os dados obteve a melhor acurácia na classificação, resultando em 91% de acurácia global e índice kappa de 0,79. No entanto, os dados provenientes do sensor óptico apresentaram maior importância relativa na classificação, refletindo em uma acurácia alta (89% de acurácia global e índice kappa de 0,74) mesmo quando não foram utilizados os dados derivados de radar. As imagens do Sentinel-1 mostram-se mais eficazes na detecção dos Campos de Murundus quando o intervalo de tempo abrangeu apenas o verão, devido à sua capacidade de detecção na presença de nuvens.

Palavras-chave: áreas úmidas, Sentinel-1, Google Earth Engine.

Wetlands are located at the interface between terrestrial and aquatic environments, playing important ecosystem functions at both regional and global scales. The Murundus Fields are typical wetlands of the Cerrado biome, which face threats due to human activities and climate change, making their monitoring and conservation essential. This study aims to assess the accuracy of supervised classification of the Murundus Fields in the rio Claro basin, located in the Triângulo Mineiro region (Minas Gerais, Brazil), through the combination of optical and radar sensor data. For this purpose, radar images from the Sentinel-1 satellite and the Copernicus DEM digital elevation model, as well as optical images from the Sentinel-2A satellite and the NDWI spectral index, were used. The Google Earth Engine (GEE) platform was employed to create distinct models, varying the types of input data and the temporal scale. The results showed that, over the course of one year, the combined use of all datasets achieved the best classification accuracy, with 91% overall accuracy and a kappa index of 0.79. However, the optical sensor data had greater relative importance in the classification, resulting in high accuracy (89% overall accuracy and a kappa index of 0.74) even when radar-derived data were not used. Sentinel-1 imagery is more effective in detecting the Murundus Fields when the time interval covers only summer, due to its ability to detect in the presence of clouds.

Keywords: wetlands, Sentinel-1, Google Earth Engine.

## 1. INTRODUÇÃO

As áreas úmidas (AUs) são ecossistemas na interface entre ambientes terrestres e aquáticos, sendo permanentemente ou periodicamente inundados por águas rasas ou com solos encharcados, com comunidades de plantas e animais adaptadas à sua dinâmica hídrica. Essas regiões desempenham um papel importante em escala regional e global devido à sua influência sobre

processos biológicos, ecológicos e hidrológicos, aprimorando a resiliência local contra desastres [1]. Em escala regional, auxiliam na purificação dos recursos hídricos, fornecem habitat para seres vivos e controlam inundações. Em escala global, as AUs fazem parte do ciclo global do carbono e geram uma fração considerável das emissões globais de metano [2].

O Programa de Desenvolvimento Mundial da Água das Nações Unidas alertou que cerca de dois terços das áreas úmidas foram perdidas desde o início do século vinte [3]. Além disso, pequenas mudanças nos padrões do clima, bem como o aquecimento global podem afetar as AUs substancialmente. Nesse sentido, a detecção e o monitoramento das condições desses ambientes têm se tornado um problema importante atualmente [4]. De modo geral, as AUs estão frequentemente localizadas em zonas de difícil acesso, tornando a visita de campo impraticável. Nesse cenário, a tecnologia do sensoriamento remoto tem se mostrado valiosa para mapear esses ecossistemas, pois pode fornecer informações de extensas porções da superfície de forma rápida e acessível.

Vários estudos tiveram sucesso na detecção de AUs a partir de sensores ópticos, porém esses sensores apresentam algumas limitações como, por exemplo, a impossibilidade de obter informações da superfície terrestre na presença de florestas ou nuvens [4, 5]. Em contrapartida, os sensores de Radar de Abertura Sintética (SARs) são capazes de coletar dados independentemente das condições climáticas e iluminação solar, tornando-os mais adequados para monitorar áreas úmidas, uma vez que interagem com alvos em nível macroscópico, coletando informações de macrocaracterísticas, como estrutura, rugosidade da superfície e teor de umidade [6]. Embora a integração de dados ópticos e de radar apresente inúmeras vantagens, permanecem desafios na padronização de metodologias em diferentes tipos e condições de áreas úmidas.

Ao revisar os estudos de detecção de áreas úmidas a partir de SARs, Adeli et al. (2020) [4] comentam que é esperado um aumento na tendência do uso de plataformas de computação em nuvem nos próximos anos, como o Google Earth Engine (GEE), para a detecção desses ecossistemas em larga escala. Nesse sentido, o GEE facilita o acesso a técnicas de processamento digital de imagens, independente dos recursos computacionais dos usuários. Os dados são acessados por meio da linguagem Earth Engine Javascript, a qual foi criada para simplificar as complexidades dos dados geoespaciais [7, 8].

A região do Triângulo Mineiro possui uma fitofisionomia característica de áreas úmidas do bioma Cerrado, denominado Campos de Murundus. Esses ecossistemas possuem fauna e flora singulares e compõem o sistema de recarga e descarga dos aquíferos, possuindo papel perenizador dos cursos d'água; retêm sedimento; são fonte de água para a fauna silvestre; funcionam como zonas de estoque de carbono orgânico devido à sua retenção de sedimentos [9-11]. No entanto, são escassos os estudos relativos à detecção e ao monitoramento desses habitats por meio de sensores remotos. Este trabalho visa analisar o desempenho do mapeamento de Campos de Murundus da bacia do rio Claro a partir de dados de sensor óptico e de radar, utilizando a plataforma Google Earth Engine.

## 2. MATERIAL E MÉTODOS

Para o desenvolvimento do estudo foram realizados os seguintes passos: seleção da área de estudo; aquisição e pré-processamento dos dados; e classificação das imagens e avaliação da acurácia. Todos os processos foram realizados em linguagem JavaScript no editor de códigos do programa Google Earth Engine (GEE). A proposta metodológica baseou-se no trabalho de Chaudhary et al. (2023) [12], sendo realizadas algumas adaptações para a área de estudo. O fluxograma com os principais passos do presente trabalho pode ser observado na Figura 1.

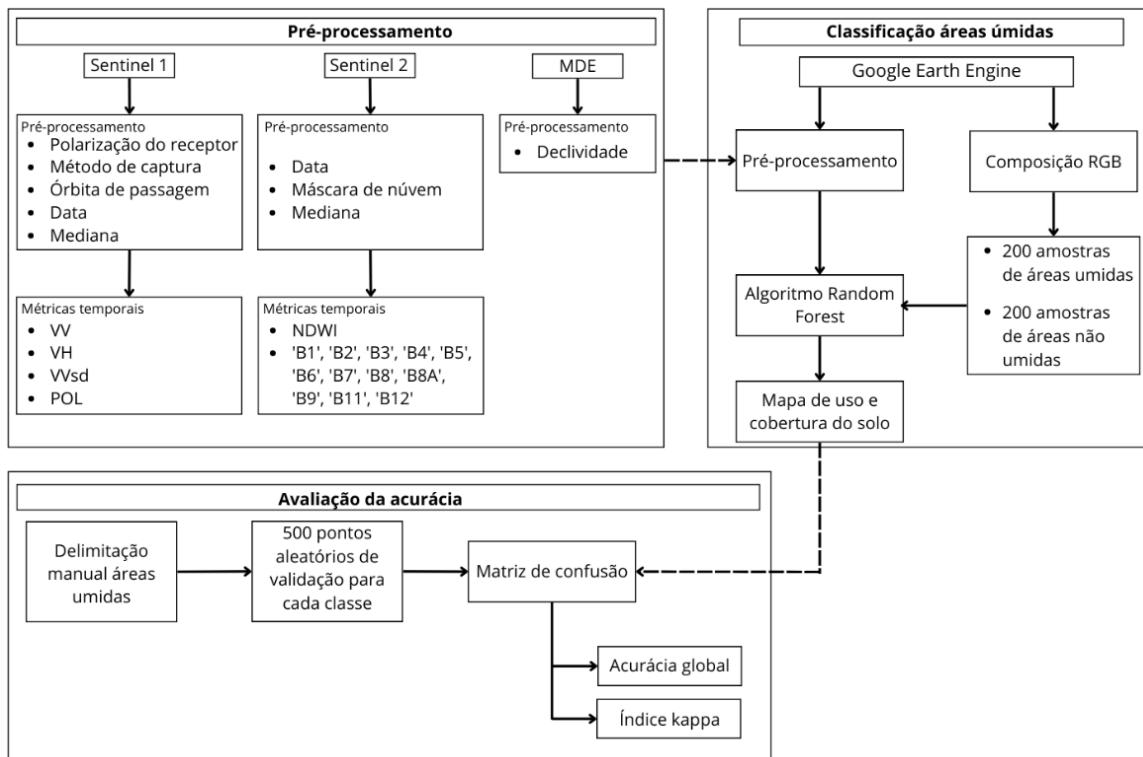


Figura 1: Fluxograma detalhado do procedimento metodológico.

## 2.1 Seleção da área de estudo

A área de estudo do presente trabalho consiste na bacia do rio Claro, com uma dimensão de aproximadamente 1.106,16 km<sup>2</sup> (Figura 2). O rio Claro é tributário do rio Araguari que por sua vez tem como foz o rio Paranaíba, a bacia do Araguari ocupa uma vasta porção do Triângulo Mineiro [13].

Desde 1996, Minas Gerais enfrenta disputas relacionadas ao uso da água, sendo o conflito mais relevante de natureza quantitativa, ou seja, quando a quantidade disponível não é suficiente para atender a todos os usuários. Em 2011 a vazão outorgada em toda a bacia do rio Claro já havia extrapolado o limite máximo outorgável, e com a comprovada ampliação da vazão outorgada, de 2011 a 2017, evidencia-se a tendência de aumento na demanda e a indisponibilidade hídrica na bacia [14].

O clima tropical predominante na região da bacia do rio Araguari, onde se insere a bacia do rio Claro, é caracterizado por duas estações bem definidas: uma estação seca, que ocorre de abril a setembro, e uma estação úmida, que se estende de outubro a março. Essas variações climáticas são influenciadas pela atuação das massas de ar continentais (equatorial e tropical) e atlânticas (polar e tropical) [15].

A geologia da região apresenta dois contextos estruturais distintos. Na porção leste, predominam formações do Pré-Cambriano, representado principalmente pelo Grupo Araxá, parte do setor meridional da Faixa Brasília e o restante do Triângulo Mineiro, na margem oeste da Faixa Brasília, encontram-se rochas da Bacia Sedimentar do Paraná. Além disso, a bacia do rio Claro destaca-se pela significativa produção agrícola, reforçando sua importância econômica e ambiental para a região [15].

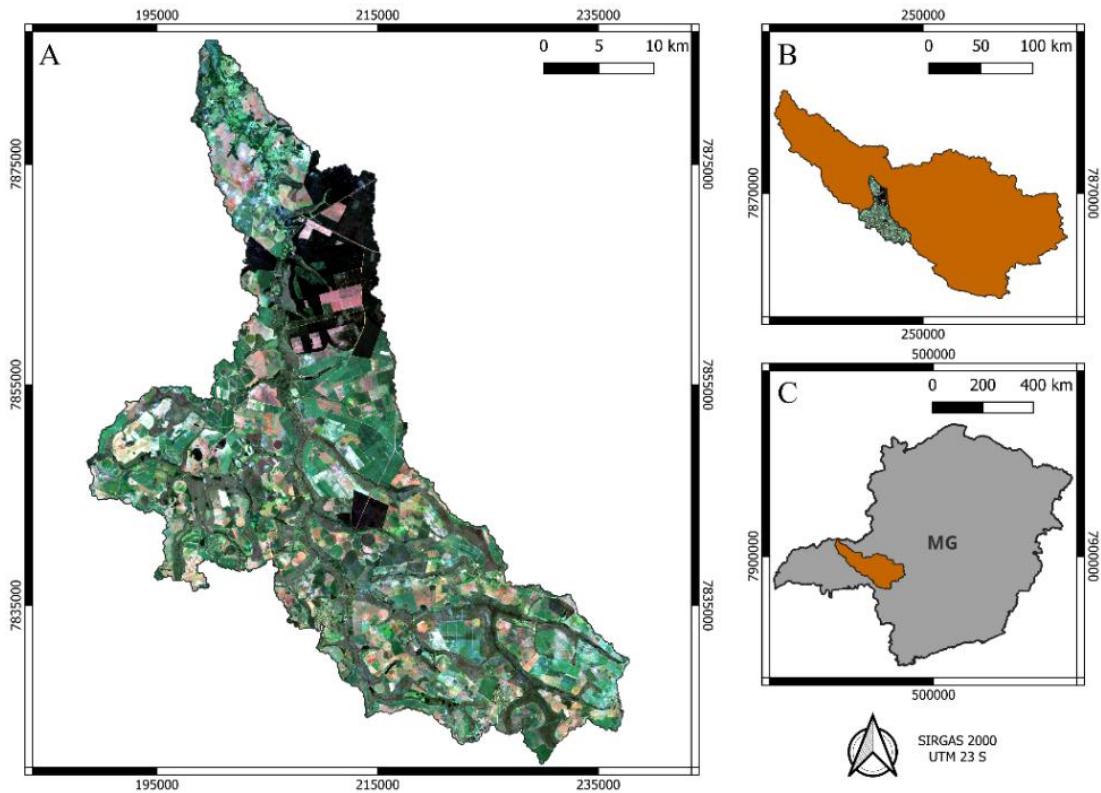


Figura 2: Localização da área de estudo, destacando: (A) Bacia do Rio Claro; (B) Bacia do Araguari; e (C) posição no estado de Minas Gerais.

## 2.2 Aquisição e pré-processamento dos dados

Inicialmente foram obtidas imagens do Radar de Abertura Sintética (SAR) do satélite Sentinel 1, via catálogo do GEE referente aos anos de 2021 e 2022. Para a coleção de imagens obtida foram utilizados filtros de método de captura, órbita de passagem e polarização recebida. A órbita utilizada no estudo foi a descendente, e o método de captura Interferometric Wide Swath (IW). Lançado em 2014, o Sentinel-1 utiliza SAR que opera na banda C (entre 8 e 4 GHz) para observação contínua, operando independentemente das condições climáticas ou da iluminação solar.

A partir do uso de comprimentos de onda mais longos, o Sentinel-1 permite obter dados mesmo sob cobertura de nuvens ou durante a noite. Além disso, sua capacidade de transmitir e receber polarizações diferentes (linear e circular) melhora a discriminação entre várias classes de zonas úmidas, garantindo captura de dados frequente e consistente, esse recurso é essencial para rastrear mudanças nessas áreas e aumentar a acurácia da classificação [6].

A polarização é uma propriedade fundamental das ondas eletromagnéticas que descreve a orientação e o comportamento do vetor de campo elétrico, com tipos e parâmetros específicos que caracterizam seu estado, existem quatro formas de combinar polarizações transmitidas e recebidas pelo Sentinel-1: recepção e transmissão horizontal (HH), recepção e transmissão vertical (VV), transmissão horizontal e recepção vertical (HV) e transmissão vertical e recepção horizontal (VH) [13]. Para o presente estudo, os dados do Sentinel-1 utilizados incluíram a polarização VH, VV, seu desvio padrão (VVsd) e uma polarização normalizada (POL), que foi calculada de acordo com Sun et al. (2020) [16]. A POL, ilustrada na Equação 1, mede a variabilidade do sinal de retroespalhamento da polarização utilizando imagens de polarização VV e VH, realçando as diferenças polarimétricas ligadas à rugosidade e teor de umidade [16]. Portanto, seu uso almejou facilitar a detecção da vegetação encharcada e água superficial.

$$POL = \left( \frac{VH - VV}{VH + VV} \right) \quad (1)$$

Foram obtidas imagens de reflectância da superfície do satélite Sentinel-2A para o mesmo período referente aos anos de 2021 e 2022. Para a coleção de imagens obtida, foi aplicado um filtro para selecionar as imagens com menos de 10% de nuvens nas imagens a fim de minimizar a interferência. O Sentinel-2A, iniciado em 2015 faz parte de uma missão de observação da Terra desenvolvida pela Agência Espacial Europeia (ESA) como parte do programa Copernicus, com objetivo de monitorar a superfície terrestre e fornecer dados essenciais para aplicações ambientais, agrícolas, florestais e de gestão de recursos hídricos.

Adicionalmente, criou-se um segundo conjunto de dados de imagens Sentinel-2A visando analisar a influência da interferência de nuvens no mapeamento. Foi alterado o intervalo de aquisição das imagens para o período chuvoso da região, compreendido entre dezembro de 2020 e março de 2021. Para isso, alterou-se o limiar do filtro de nuvens da coleção do Sentinel-2A para 90%. Em todas as coleções foi obtida a mediana de cada pixel e realizado o recorte da área de estudo.

Além das bandas disponibilizadas no pacote do sensor Sentinel-2A, empregou-se o Índice de Água de Diferença Normalizada (NDWI) proposto por McFeeters (1996) [17], amplamente utilizado para a detecção e o monitoramento dos corpos d'água superficiais, tais como lagos, rios e represas, permitindo distingui-los de áreas secas ou vegetadas. O índice é derivado da razão espectral entre a reflectância da banda B3, correspondente à região do visível verde, e da banda B8, correspondente à região do infravermelho próximo (NIR). A razão espectral realça corpos d'água, uma vez que valores positivos indicam maior contribuição da reflectância na banda verde em relação ao NIR, característica típica de áreas com água superficial ou solo saturado [17]. Nesse contexto, a aplicação do índice teve como finalidade avaliar a disponibilidade hídrica, e identificar áreas sujeitas a inundação, subsidiando o mapeamento de zonas úmidas. O cálculo do NDWI foi implementado por meio de algoritmos desenvolvidos na plataforma, de acordo com a equação 2.

$$\text{NDWI} = \left( \frac{\text{Green-NIR}}{\text{Green+NIR}} \right) \quad (2)$$

Ainda, utilizando um algoritmo na plataforma GEE, foi importada a coleção contendo os dados de elevação do Copernicus GLO-30, que conta com um modelo digital de elevação (MDE) em uma escala global com uma resolução de 30 metros. Dessa forma, foi obtida a declividade do terreno pixel a pixel a partir do processamento do MDE.

Foram desenvolvidos quatro modelos distintos (Tabela 1), utilizando imagens relativas ao período de janeiro de 2021 a dezembro de 2022, cada um possuindo diferentes dados de entrada para o treinamento do algoritmo de classificação. Criou-se um modelo sem dados de radar, a fim de analisar a eficiência das imagens Sentinel-2A na detecção dos Campos de Murundus. Além disso, combinou-se os dados das imagens dos satélites, com subprodutos gerados na etapa do pré-processamento. A definição dos dados de entrada em cada modelo seguiu uma abordagem estratégica, com o intuito de analisar o desempenho dos dados de entrada em diferentes situações.

*Tabela 1: Apresentação dos modelos de classificação.*

Modelo	Dados de entrada	Variáveis derivadas
1	Sentinel-1	VV, VH, VVsd e POL
2	Sentinel-2A	B2-B12, NDWI
3	Sentinel-2A, Copernicus DEM	B2-B12, NDWI, declividade
4	Sentinel-1, Sentinel-2A, Copernicus DEM	VV, VH, VVsd, POL, B2-B12, NDWI, declividade

Adicionalmente, analisou-se a eficiência do Sentinel-1 e Sentinel-2A em um intervalo de tempo que abrangia o período chuvoso da região, entre dezembro de 2020 e março de 2021. Esta

separação de datas teve como finalidade avaliar a influência de um período de alta nebulosidade na classificação dos Campos de Murundus.

### 2.3 Classificação das imagens

A classificação das imagens foi realizada utilizando o algoritmo Random Forest, originalmente proposto por Breiman (2001) [18]. Esse método de aprendizado supervisionado é frequentemente utilizado pois combina múltiplas árvores de decisão construídas de forma aleatória, e pode lidar com conjuntos de dados de diversas fontes. Desse modo, a classificação de uma instância é determinada pelo voto majoritário das árvores, o que contribui para minimizar o risco de sobreajuste (overfitting) e aumentar a confiabilidade dos resultados, mesmo em conjuntos de dados complexos e de alta dimensionalidade [18].

Para o presente estudo utilizou-se 10 árvores de decisão para todos os modelos, e a amostragem foi efetuada considerando duas classes, sendo elas: áreas úmidas e não úmidas, com base em uma composição colorida RGB 432 do Sentinel-2A referente ao período de 2021 a 2022. Ao todo foram geradas 400 amostras para o treinamento do algoritmo de classificação, totalizando 200 amostras para cada classe.

### 2.4 Avaliação da acurácia

Para analisar o desempenho do algoritmo Random Forest, comparou-se os dados de referência com os mapas classificados. Para isso, foram geradas 1000 amostras aleatórias estratificadas por classe, sendo 500 para cada. De acordo com Monard e Baranauskas (2003) [19], a matriz de confusão fornece uma avaliação eficaz do desempenho do modelo de classificação, destacando o número de classificações corretas em comparação com as classificações previstas para cada classe. Sua interpretação é feita da seguinte forma: os pixels corretamente classificados aparecem na diagonal principal da matriz, enquanto os elementos classificados incorretamente são representados pelas entradas fora dessa diagonal. Após a construção da matriz de confusão foi possível obter a acurácia global e o índice kappa.

O índice kappa ( $K$ ), representado na Equação 3, é uma medida estatística usada para avaliar o nível de concordância, eficaz na quantificação da confiabilidade entre avaliadores devido sua sensibilidade aos erros de omissão e inclusão, uma vez que considera todos os elementos da matriz de confusão, ou seja, contabiliza as colunas e linhas marginais, além da diagonal principal [20]. Segundo Cohen (1960) [20] o coeficiente Kappa mede o grau de concordância em escalas nominais assumindo que as unidades são independentes, as classes ou categorias da escala nominal são independentes, mutuamente exclusivas e o classificador e os pontos de referência operam de forma independente.

$$K = 2 \cdot \frac{(TP \cdot TN - FN \cdot FP)}{(TP+FP).(FP+TN)+(TP+FN).(FN+TN)} \quad (3)$$

No índice  $K$ , cada termo possui uma função específica: verdadeiro positivo (TP) representa a quantidade de pixels corretamente classificados como úmidos, verdadeiro negativo (TN) refere-se aos pixels corretamente classificados como não úmidos, falso positivo (FP) indica pixels classificados incorretamente como úmidos e falso negativo (FN) pixels incorretamente classificados como não úmidos. O índice considera toda a matriz de confusão, contemplando tanto acertos quanto erros, e quantifica o grau de concordância real além do acaso. Nesse contexto, o índice  $K$  foi empregado para avaliar a concordância entre a classificação e os dados de referência. Assim, valores próximos de um indicam alto nível de acerto, enquanto valores próximos de zero revelam concordância apenas ao acaso [20].

A acurácia global (AG) é definida pela razão entre o número de amostras corretamente classificadas (V) e o total de amostras avaliadas (T). Diferentemente do índice  $K$ , não distingue os tipos de erro, mas expressa a proporção geral de acertos. Assim, valores mais elevados de AG

indicam classificações mais confiáveis, e consequentemente uma maior qualidade de classificação. A Equação 4 representa a equação da acurácia global.

$$AG (\%) = \frac{\sum V}{\sum T} \cdot 100 \quad (4)$$

A avaliação da acurácia a partir do uso de diferentes tipos de coeficientes de concordância possibilitam maior confiabilidade das imagens classificadas, sob diferentes perspectivas e metodologias. Ambos os indicadores foram importantes para avaliar os modelos gerados, permitindo a análise da confiabilidade das informações obtidas.

### 3. RESULTADOS E DISCUSSÃO

Os resultados de AG e índice K evidenciaram que o modelo 1, baseado exclusivamente nos dados do SAR Sentinel-1, obteve o menor desempenho para o período de estudo. Em contraste, a inclusão de todas as variáveis de entrada no modelo 4 (Sentinel-1, Sentinel-2A e declividade) proporcionou o melhor desempenho de classificação para o mesmo intervalo temporal. Os resultados obtidos para cada modelo podem ser observados na Tabela 2.

*Tabela 2: Avaliação da acurácia global (AG) e índice kappa (K) dos modelos de classificação supervisionada.*

Modelo	AG	K
1 (Sentinel-1)	77%	0,53
2 (Sentinel-2A)	89%	0,74
3 (Sentinel-2A, Copernicus DEM)	90%	0,78
4 (Sentinel-1, Sentinel-2A, Copernicus DEM)	91%	0,79

Resultados semelhantes foram constatados por Chaudhary et al. (2023) [12], que aplicaram o algoritmo Random Forest para o mapeamento e monitoramento das áreas úmidas da cidade metropolitana de Pokhara, localizada na região central do Nepal. Nesse estudo, o modelo de menor erro foi alcançado ao incorporar dados do sensor óptico, de radar e topográficos. Além disso, constatou-se que o Sentinel-1 apresentou desempenho inferior ao Sentinel-2A no mapeamento de áreas úmidas.

Diversos estudos corroboram o ganho de desempenho observado quando múltiplas fontes de dados são integradas. A combinação de dados ópticos e de radar eleva as taxas de acerto em mapeamentos de áreas úmidas, situando-se geralmente entre 80% e 90% de acurácia global [7, 21]. Dessa forma, os resultados obtidos neste estudo encontram-se no limite superior do intervalo reportado na literatura, reforçando a robustez da abordagem adotada para o mapeamento dos Campos de Murundus.

A análise dos quatro modelos de classificação evidenciou a influência dos dados de entrada, bem como do intervalo temporal na acurácia da classificação dos Campos de Murundus. A cartografia final produzida pelo modelo 4 mostra boa correspondência espacial com os Campos de Murundus, com baixa incidência de falsos positivos (Figura 3). Ainda assim, persistem erros pontuais associados a trechos de estrada e margens agrícolas, condizentes com limitações conhecidas de classificações pixel a pixel.

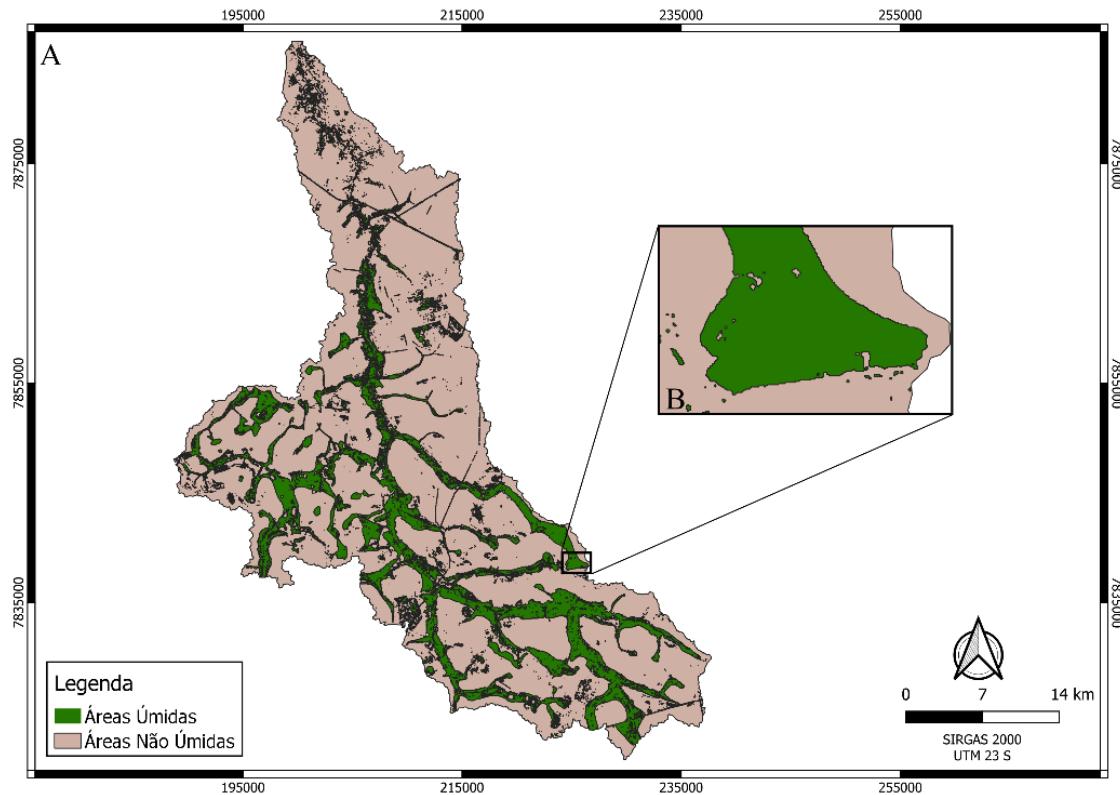


Figura 3: Resultado do mapeamento das áreas úmidas obtido pelo modelo 4 com integração de dados do sensor óptico, radar e declividade.

Estudos de metodologias semelhantes também observaram erros no mapeamento de áreas úmidas inerentes ao processo. Em alguns casos, a extensão de áreas úmidas pode ser superestimada em encostas ou aterros de estradas, e subestimada em pequenas cristas aluviais ou aterros de estradas [21].

De acordo com Breiman (2001) [18], a análise da importância de variáveis permite identificar qual variável de entrada tem maior relevância na construção do modelo de classificação da imagem. A Figura 4 resume a importância de cada variável de entrada no algoritmo Random Forest para o modelo 4.

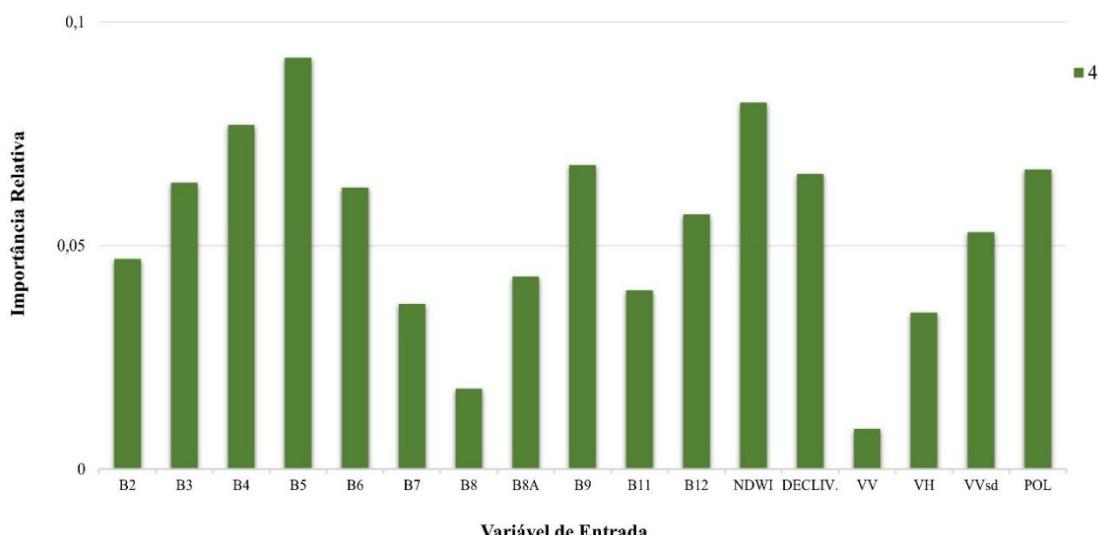


Figura 4: Importância relativa das variáveis de entrada no desempenho do modelo 4.

Entre as variáveis analisadas, o NDWI e a banda red-edge 1 (B5), componente do Sentinel-2A, tiveram destaque devido à sua importância relativa na identificação de áreas úmidas. O índice NDWI permite maximizar a reflectância típica da água utilizando o comprimento de onda do verde, além de minimizar a baixa reflectância dos corpos de água no infravermelho próximo e realçar o contraste entre a água e a cobertura vegetal, fornecendo informações valiosas sobre a extensão e as condições das áreas úmidas, favorecendo assim seu mapeamento [17].

A elevada importância da variável declividade para o modelo 4, juntamente com a comparação entre os modelos 2 e 3, indicou que a sua inclusão contribuiu positivamente para a eficácia dos modelos. Ao comparar os modelos 2 e 3, essa contribuição resultou em um aumento percentual de 1,12% para AG e 5,40% para o índice K. Embora o ganho absoluto nas métricas de avaliação tenha sido pequeno, este incremento é operacionalmente relevante em programas de monitoramento, uma vez que reduz falsos positivos. Em seu estudo Valenti et al. (2020) [22] também demonstraram que a inclusão de variáveis topográficas teve forte influência na classificação de áreas úmidas, reduzindo erros em regiões de encosta no Canadá.

De forma complementar, ao analisar as condicionantes naturais da distribuição espacial dos Campos de Murundus no sudoeste do estado de Goiás, Malheiro et al. (2023) [11], concluíram que esses ambientes predominam em áreas de baixa declividade (0 a 8%, variando de plano a suavemente ondulado) e em regiões com baixa densidade de drenagem (< 62,27 km/km<sup>2</sup>). Esses achados reforçam a relevância do uso de dados topográficos para aprimorar a detecção e a classificação de ambientes úmidos em diferentes contextos geográficos.

O Sentinel-2A, quando utilizado de forma isolada, ou seja, sem complementação de outras informações, obteve melhor desempenho na classificação de áreas úmidas em comparação ao Sentinel-1 (Tabela 2), no entanto, quando submetido ao intervalo específico compreendido em um período chuvoso sob alta interferência de nuvens, seus índices decaíram, especialmente o índice K, resultando em um desempenho inferior ao obtido pelo radar. Enquanto o Sentinel-2A obteve 61% de AG e índice K de 0,23, o Sentinel-1 obteve 78% de AG e 0,53 de índice K. Dessa forma, as métricas do modelo que utilizou exclusivamente dados do Sentinel-1 permaneceram constantes, independentemente da interferência de nuvens. Tal fato evidencia a eficiência do Sentinel-1 para a classificação de áreas úmidas em períodos e/ou locais onde possam existir interferências climáticas.

A avaliação sazonal reforça a complementaridade entre sensores. Em janelas com alta nebulosidade (período chuvoso), a robustez do Sentinel-1 manteve níveis de AG e K estáveis, enquanto o desempenho do modelo com dados exclusivos do sensor óptico foi reduzido. Em síntese, quando a disponibilidade de imagens provenientes do sensor óptico é limitada, o radar sustenta a qualidade da classificação, e quando há boa oferta de observações ópticas, a integração óptico-radar-topográfica maximiza o desempenho (Tabela 2). Essa natureza complementar destaca os potenciais benefícios da combinação de dados SAR e ópticos para aplicações de sensoriamento remoto mais robustas, apesar dos desafios inerentes à integração desses diferentes tipos de dados [23].

Os resultados encontrados corroboram com tendências descritas na literatura. Os autores Adeli et al. (2020) [4] destacam a maior resiliência do radar em ambientes tropicais, enquanto Hardy et al. (2020) [7] enfatizam sua aplicabilidade em regiões com elevada nebulosidade.

No presente estudo, a conservação da acurácia do Sentinel-1 durante a estação chuvosa confirmou sua relevância prática para o bioma Cerrado, devido a persistente cobertura de nuvens que limita severamente o uso de dados de sensores ópticos em períodos críticos para a conservação e gestão hídrica.

#### 4. CONCLUSÃO

O presente estudo evidenciou a eficácia do uso integrado de dados do sensor óptico e de radar na detecção de Campos de Murundus. Entre os modelos avaliados, aquele que combinou imagens do Sentinel-1, Sentinel-2A, NDWI e declividade demonstrou os melhores resultados, alcançando uma acurácia global de 91% e índice kappa de 0,79. Os resultados evidenciam que a integração entre diferentes fontes de dados melhora a classificação.

Ademais, destaca-se a resiliência apresentada pelo Sentinel-1 frente a condições meteorológicas adversas. A análise durante o período chuvoso revelou a robustez do radar em condições desfavoráveis, enquanto o sensor óptico Sentinel-2A apresentou redução de eficiência. Embora o uso isolado do Sentinel-1 não tenha apresentado os melhores resultados, sua capacidade de operar independentemente das condições climáticas representa uma vantagem significativa, especialmente em regiões tropicais marcadas por alta frequência de cobertura de nuvens, onde sensores ópticos apresentam limitações operacionais.

Por fim, verificou-se que a inclusão do índice NDWI e de dados de declividade nos modelos testados resultou em ganhos de acurácia, indicando que essas variáveis desempenham um papel relevante na classificação de áreas úmidas na região de estudo.

Embora os modelos tenham sido treinados com duas classes (úmida e não úmida) a partir de amostras pontuais, o desempenho alcançado indica potencial para aplicação em outras regiões. No entanto, a transferência direta do modelo poderá demandar recalibração e validação adicional, a fim de considerar as variabilidades ambientais entre regiões. Para trabalhos futuros, recomenda-se integrar a validação remota com dados coletados em campo, de modo a ajustar o classificador a diferentes cenários sazonais e reduzir as incertezas associadas ao processo de generalização.

## 5. AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro à pesquisa.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- da Silva DEM, Costa DFS. Classificação das áreas úmidas e seus macrohabitats na planície flúvio-marinha do rio Apodi-Mossoró/RN (litoral semiárido do Brasil). *Rev Bras Geog Fis.* 2022 mar;15(1):602-17. doi: 10.26848/rbgf.v15.1.p583-598
- Chen S, Liu L, Ma Y, Zhuang Q, Shurpali NJ. Quantifying global wetland methane emissions with in situ methane flux data and machine learning approaches. *Earths Fut.* 2024;12(11):e2023EF004330. doi: 10.1029/2023EF004330
- Cowardin LM, Carter V, Golet FC, LaRoe ET. Classification of wetlands and deepwater habitats of the United States. U.S. Fish and Wildlife Service. FWS/OBS-79/31. Washington (DC): U.S. Fish and Wildlife Service; 1979. Disponível em: <https://pubs.usgs.gov/publication/2000109>.
- Adeli S, Salehi B, Mahdianpari M, Quackenbush LJ, Brisco B, Tamiminia H, et al. Wetland monitoring using SAR Data: A meta-analysis and comprehensive review. *Remote Sens.* 2020 Jul;12(14):2190. doi: 10.3390/rs12142190
- Benchelha M, Benzha F, Rhinane H, Zilali A. The contribution of radar remote sensing via sentinel-1 data and photo-interpretation by Google Earth images for wetland mapping. *Int Arch Photogramm Remote Sens Spatial Inf Sci.* 2021 Oct;XLVI-4/W3-2021:45-51. doi: 10.5194/isprs-archives-XLVI-4-W3-2021-45-2022
- Salvia M, Franco M, Grings F, Perna P, Martino R, Karszenbaum H, et al. Estimating flow resistance of wetlands using SAR images and interaction models. *Remote Sens.* 2009 Nov;1(4):992-1008. doi: 10.3390/rs1040992
- Hardy A, Oakes G, Ettritch G. Tropical Wetland (TropWet) Mapping Tool: The automatic detection of open and vegetated waterbodies in Google Earth Engine for tropical wetlands. *Remote Sens.* 2020 Apr;12(7):1182. doi: 10.3390/rs12071182
- Montero D, Aybar C, Mahecha MD, Wieneke S. Spectral: awesome spectral indices deployed via the Google Earth Engine Javascript Api. *Int Arch Photogramm Remote Sens Spatial Inf Sci.* 2022 Ago; XLVIII-4/W1-2022:301-6. doi: 10.5194/isprs-archives-XLVIII-4-W1-2022-301-2022
- Rosolen V, De-Campos AB, Govone JS, Rocha C. Contamination of wetland soils and floodplain sediments from agricultural activities in the Cerrado Biome (State of Minas Gerais, Brazil). *Cat.* 2015 May;128:203-10. doi: 10.1016/j.catena.2015.02.007
- Zedler JB, Kercher S. WETLAND RESOURCES: Status, trends, ecosystem services, and restorability. *Annual Rev.* 2005 Nov;30(1):39-74. doi: 10.1146/annurev.energy.30.050504.144248

11. Malheiro AM, Boeira VN, Bueno GT, Mantovani JR. Condicionantes naturais da distribuição espacial dos campos de murundus no sudoeste do Estado de Goiás. *Soc & Nat.* 2023 nov;36(1):e69038. doi: 10.14393/SN-v36-2024-69038
12. Chaudhary RK, Puri L, Acharya AK, Aryal R. Wetland mapping and monitoring with Sentinel-1 and Sentinel-2 data on the Google Earth Engine. *J For Nat Res Man.* 2023 Nov;3(1):1-21. doi: 10.3126/jfnrm.v3i1.60107
13. Castro WS, De-Campos AB, Zancopé MHC. A influência dos materiais das margens e da vegetação ciliar na erosão de meandros: o caso do rio Claro, afluente do rio Araguaia. *Rev Bras Geomorf.* 2019 Jul 1;20(3):623-40. doi: 10.20502/rbg.v20i3.1584
14. Souza JS, Coelho G. Gestão de recursos hídricos na bacia do Rio Claro - Minas Gerais. 1. ed. Uberaba (MG): Editora IFTM; 2024.
15. Instituto Mineiro de Gestão das Águas (IGAM). Diagnóstico da bacia hidrográfica do rio claro. Belo Horizonte (MG): IGAM; ago 2012. Disponível em: [http://repositorioigam.meioambiente.mg.gov.br/bitstream/123456789/870/1/Diagnostico\\_Bacia%20Hidrografica%20do%20Rio%20Claro\\_2012.pdf](http://repositorioigam.meioambiente.mg.gov.br/bitstream/123456789/870/1/Diagnostico_Bacia%20Hidrografica%20do%20Rio%20Claro_2012.pdf).
16. Sun S, Zhang Y, Song Z, Chen B, Zhang Y, Yuan W, et al. Mapping coastal wetlands of the Bohai Rim at a spatial resolution of 10 m using multiple open-access satellite data and terrain indices. *Remote Sens.* 2020 Dec;12(24):4114. doi: 10.3390/rs12244114
17. McFeeters SK. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *Intern J Remote Sens.* 1996 May;17(7):1425-32. doi: 10.1080/01431169608948714
18. Breiman L. Random Forests. *Machine Learn.* 2001 Oct;45(1):5-32. doi: 10.1023/A:1010933404324
19. Monard MC, Baranauskas JA. Conceitos sobre Aprendizado de Máquina. In: Sistemas inteligentes - Fundamentos e aplicações. São Paulo: Manole; 2003. p. 89-114.
20. Cohen J. A Coefficient of agreement for nominal scales. *Educ and Psychol Measur.* 1960 Apr;20(1):37-46. doi: 10.1177/001316446002000104
21. Rapinel S, Fabre E, Dufour S, Arvor D, Mony C, Hubert-Moy L. Mapping potential, existing and efficient wetlands using free remote sensing data. *J Environ Manag.* 2019 Oct;247:829-39. doi: 10.1016/j.jenvman.2019.06.098
22. Valenti VL, Carcelen EC, Lange K, Russo NJ, Chapman B. Leveraging Google Earth Engine user interface for semiautomated wetland classification in the Great Lakes Basin at 10 m with optical and radar geospatial datasets. *IEEE J Sel Top Appl Earth Obs Remote Sens.* 2020 Oct;13:6008-18. doi: 10.1109/jstARS.2020.3023901
23. Sommervold O, Gazzea M, Arghandeh R. A Survey on SAR and optical satellite image registration. *Remote Sens (Basel).* 2023 Feb;15(3):850. doi: 10.3390/rs15030850