

Mapeamento de Campos de Murundus na Bacia do Rio Claro (MG) Utilizando o Google Earth Engine

Mapping Murundus Fields in the Rio Claro River Basin (MG) Using Google Earth Engine

Henrique Pinto Rivani¹

Alex Garcez Utsumi²

Resumo

As áreas úmidas são zonas de transição entre ambientes aquáticos e terrestres que abrigam diversas espécies animais e vegetais, fornecendo diversos serviços ecossistêmicos. Os campos de murundus são áreas úmidas típicas do Cerrado brasileiro, com importante papel na biodiversidade local e no regime hídrico. O presente estudo teve como objetivo detectar os campos de murundus na bacia do rio Claro (MG) por meio de imagens do satélite Sentinel 2. Para isso, utilizou-se a plataforma Google Earth Engine para implementar um algoritmo baseado em aprendizado de máquina (Random Forests) visando mapear a área de estudo a partir de quatro combinações distintas de dados de entrada. Os resultados indicam que a utilização conjunta de todas as bandas Sentinel-2 e do índice da água por diferença normalizada foi a mais eficiente, apresentando 71,95% de acurácia do produtor, 79,42% de acurácia do usuário e F-measure de 75,5%. Além disso, observa-se que a combinação entre as bandas do infravermelho próximo e do red-edge resultam em um índice F-measure satisfatório (69,39%), indicando que essas regiões espectrais fornecem informações importantes para detectar as áreas úmidas. O desenvolvimento de tecnologias que auxiliem na detecção e monitoramento dos campos de murundus pode auxiliar na preservação desses habitats. Devido ao seu processamento na nuvem, o GEE apresenta potencial para mapear as áreas úmidas em grandes extensões.

Palavras-Chave: Áreas úmidas; Random Forests; Sentinel-2; Red-edge.

¹ Universidade Federal do Triângulo Mineiro (UFTM), Graduando em Engenharia Ambiental, Uberaba-MG / d201810609@uftm.edu.br / ORCID: <https://orcid.org/0000-0003-4657-6016>

² Universidade Federal do Triângulo Mineiro (UFTM), Professor do Departamento de Engenharia Ambiental, Uberaba-MG / alex.utsumi@uftm.edu.br / ORCID: <https://orcid.org/0000-0002-8955-6050>

Abstract

Wetlands are transition zones between aquatic and terrestrial environments that are home to several animal and plant species, providing several ecosystem services. Murundus fields are typical wetlands of the Brazilian Cerrado, with an important role in local biodiversity and water regime. The present study aimed to detect the murundus fields in the Claro river basin (MG) using Sentinel 2 satellite images. For this, the Google Earth Engine platform was used to implement an algorithm based on machine learning (Random Forests) aiming to map the study area from four distinct combinations of input data. The results indicate that the joint use of all Sentinel-2 bands and the normalized difference water index was the most efficient, presenting 71.95% producer accuracy, 79.42% user accuracy and F-measure of 75.5%. Furthermore, it is observed that the combination of the near-infrared and red-edge bands result in a satisfactory F-measure index (69.39%), indicating that these spectral regions provide important information to detect wetlands. The development of technologies that assist in the detection and monitoring of murundus fields can aid in the preservation of these habitats. Due to its processing in the cloud, GEE has the potential to map wetlands over large areas.

Keywords: Wetlands; Random Forests; Sentinel-2; Red-edge.

Introdução

As áreas úmidas (AU) são ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanente ou periodicamente inundados ou com solos encharcados (JUNK *et al.*, 2013). Essas regiões são essenciais para regulação do regime hídrico, permitindo a recarga de aquíferos e purificação de água, além de inúmeros serviços ecológicos para a manutenção do equilíbrio das espécies locais.

O reconhecimento da importância das funções ecossistêmicas das AU se deu no início do século XX, juntamente com a necessidade de proteção e gestão sustentável. Embora o Brasil seja membro da Convenção de Ramsar desde 1993, houve pouco avanço na concepção e aplicação de critérios para proteção das AU (GOMES E MAGALHÃES JÚNIOR, 2018). Dessa forma, é necessário o desenvolvimento de tecnologias que possam contribuir para a localização e obtenção de informações sobre esses locais. Nesse sentido, o sensoriamento remoto tem se mostrado uma ferramenta eficiente para a detecção de AU, uma vez que obtém mais rapidamente informações de extensas áreas, quando comparado a inspeção em campo.

Os sensores remotos utilizam a radiação eletromagnética para a identificação dos diversos objetos da superfície. A quantidade e qualidade da energia eletromagnética refletida e emitida pelos objetos terrestres resultam das interações entre a energia eletromagnética e estes objetos (ZHU *et al.*, 2018). Essas interações são determinadas pelas propriedades físico-químicas e biológicas desses objetos e podem ser identificadas nas imagens e nos dados de sensores remotos. No entanto, segundo Shelestov *et al.* (2017), a aquisição, o armazenamento e o processamento de dados de satélite em larga escala se tornaram um problema devido ao grande volume de dados disponíveis nas últimas décadas.

Recentemente, os programas baseados em nuvem, como o *Google Earth Engine* (GEE), têm possibilitado o rápido processamento de dados de observação da Terra, bem como facilitado o acesso a técnicas de Aprendizado de Máquina para classificação do uso e cobertura do solo (HIRD *et al.*, 2017; MAHDIANPARI *et al.*, 2018; SILVA *et al.*, 2021). Devido ao seu processamento de dados na nuvem, o GEE traz a oportunidade de aplicar métodos robustos para o mapeamento de áreas úmidas, independente dos recursos computacionais dos usuários (MERCHANT *et al.*, 2022).

Nesse contexto, estudos recentes têm alcançado avanços significativos no mapeamento de áreas úmidas ao utilizar servidores de grande capacidade de processamento e armazenamento de dados por meio da internet. Devido à proximidade dos corpos d'água, as AU geralmente estão localizadas em meio a formações florestais, dificultando sua detecção por sensores ópticos (WANG *et al.*, 2022). Por esse motivo, alguns autores já demonstraram a viabilidade da utilização de radares para detectar as AU em diferentes regiões, eliminando a interferência dos dosséis densos da vegetação (MAHDIANPARI *et al.*, 2020; VALENTI *et al.*, 2020).

Por outro lado, as AU também podem estar presentes em regiões sem a presença de formações florestais, seja por motivos naturais ou antrópicos. Nesse cenário, para Niculescu *et al.* (2020) é possível a utilização de sensores ópticos para o mapeamento das áreas úmidas, uma vez que possuem comportamento espectral distinto das demais fisionomias. Nesse

sentido, Hardy *et al.* (2020) utilizaram o GEE para desenvolver uma ferramenta para detecção de AU em regiões tropicais dominadas por vegetação herbácea. Para isso, os autores aplicaram a técnica de Modelo Linear de Mistura Espectral em imagens do satélite Landsat e obtiveram alta acurácia, mesmo quando extrapolou o modelo de classificação para todo o continente africano. Já no Brasil, são escassos os estudos que utilizam sensores remotos ópticos para a detecção de áreas úmidas (KANDUS *et al.*, 2018).

Os campos de murundus são formações típicas do bioma Cerrado, ocorrendo frequentemente em áreas úmidas das planícies e depressões, bem como em brejos de planaltos e serras. Essas feições são frequentemente encontradas na chapada do Triângulo Mineiro (MG), sendo caracterizadas por morrotes de forma arredondada convexa, semelhantes aos encontrados na região sudoeste goiana e até mesmo em Áreas de Proteção Permanentes (APPs) no Distrito Federal. Os campos de murundus ocorrem em fisionomias de campo limpo do Cerrado, sendo cobertos por vegetação rasteira e arbustos, e possuem um importante papel no regime hídrico, pois interferem na infiltração e recarga do nível freático (QUEIROZ, 2012; RAMOS *et al.*, 2014; MONTEIRO, 2019).

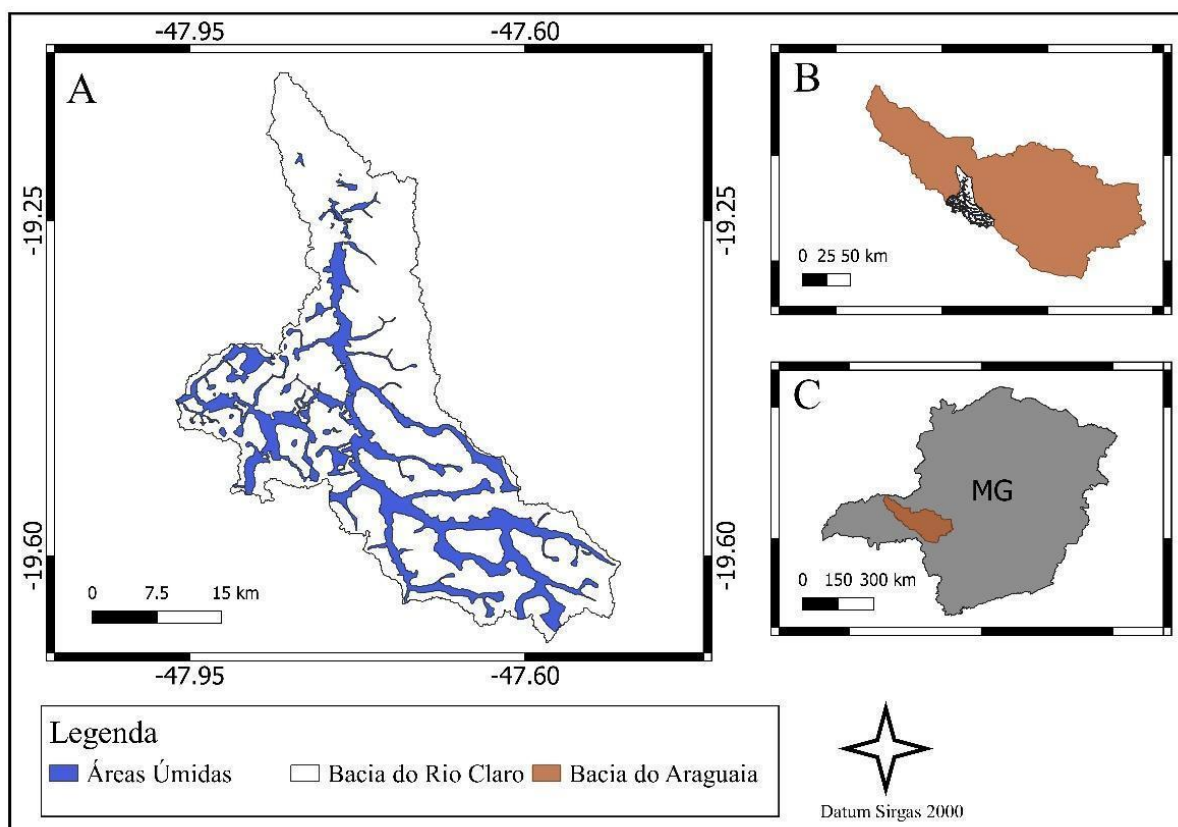
Devido às intensas transformações referentes ao uso do solo no Cerrado, é crescente o número de conflitos relativos à utilização da água nas últimas décadas. A bacia do rio Claro, situada no Triângulo Mineiro (MG), está inserida nesse contexto de conflitos uma vez que é utilizada para diversos fins, tais como irrigação de culturas agrícolas, manutenção da biodiversidade, turismo e abastecimento da população (PAULA, 2014). Considerando a relevância e as características desse tipo de área úmida, o presente trabalho visa realizar o mapeamento dos campos de murundus da bacia do rio Claro a partir de sensores remotos ópticos (Sentinel-2) utilizando a plataforma *Google Earth Engine*.

Caracterização da Área de Estudo

O local de estudo do presente trabalho é a bacia do rio Claro, a qual abrange uma área de aproximadamente 1.106,16 km² (Figura 1). O rio Claro é tributário do rio Araguaia e

está inserido na bacia do rio Paranaíba, que ocupa grande parte do Triângulo Mineiro. De acordo com Mendonça e Danni-Oliveira (2011), o clima sofre maior influência das massas de ar continental e Atlântica, sendo marcado pela alternância entre a estação seca e a úmida. A região da bacia do rio Claro possui elevada produção agrícola e, por esse motivo, a maioria dos usuários são classificados na finalidade irrigação (SANTOS E MARTINS, 2018). Devido à grande demanda pelo uso da água, alguns pontos da bacia possuem conflitos em relação à disponibilidade (IGAM, 2013).

Figura 1 - Localização da área de estudo. A) Bacia do rio Claro; B) Bacia do Araguaia; C) estado de Minas Gerais.



Fonte: Elaborado pelos autores, 2022.

As áreas úmidas presentes na região são denominadas de campos de murundus, sendo também conhecido por murundum e covoal. Os campos de murundus são ecossistemas

particulares do Cerrado, os quais permanecem temporária ou permanentemente alagados. São regiões com alta relevância ambiental devido a sua flora e fauna endêmicas, além de amortecer as variações hidrológicas e estocar carbono do solo. Sua origem é controversa, estando dividida entre a hipótese da formação por cupins e a hipótese da erosão diferencial (GIBBS, 2000; CUNHA *et al.*, 2015; QUIRINO, 2019). A Figura 2 contém uma imagem dos campos de murundus na área de estudo.

Figura 2 - Campos de murundus na bacia do rio Claro (MG).

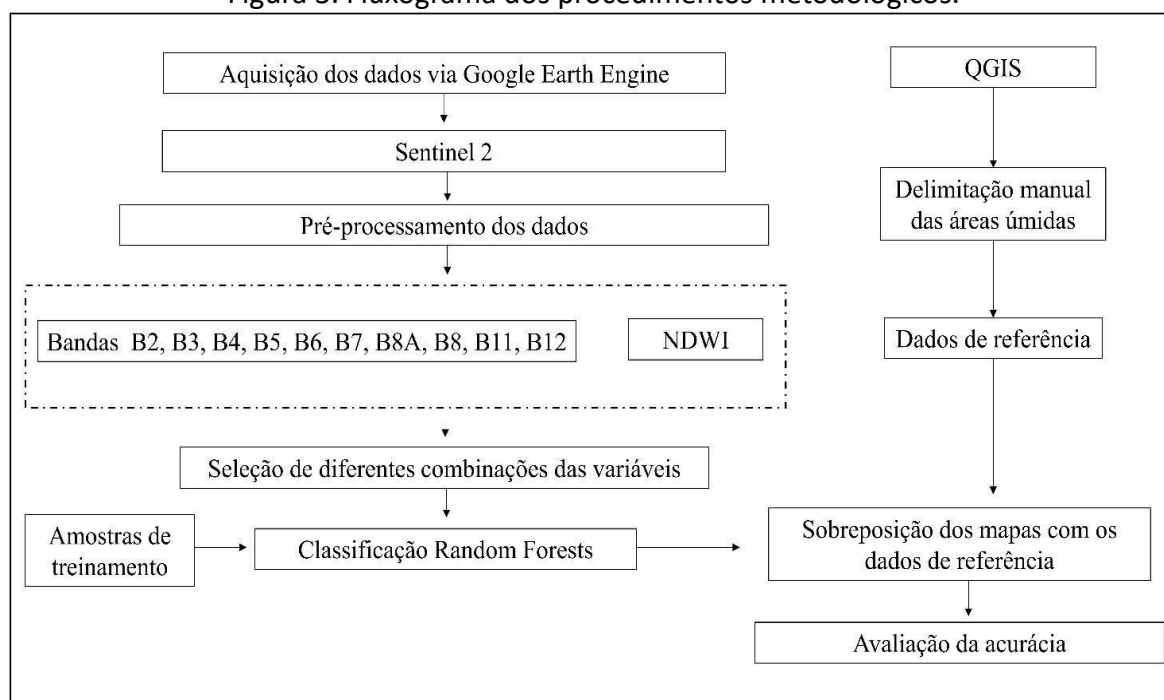


Fonte: Google, 2022.

Metodologia

Para alcançar os objetivos do presente estudo foram desenvolvidos os seguintes passos: seleção da área de estudos; aquisição e pré-processamento dos dados; classificação das imagens e avaliação da acurácia da classificação. O fluxograma com as principais etapas desenvolvidas é apresentado na Figura 3.

Figura 3. Fluxograma dos procedimentos metodológicos.



Fonte: Elaborado pelos autores, 2022.

AQUISIÇÃO E PRÉ-PROCESSAMENTO DOS DADOS

Foram obtidas imagens de reflectância da superfície do satélite Sentinel-2 via catálogo do GEE. O programa Sentinel teve início em 2014 e objetiva monitorar os recursos naturais. Os satélites Sentinel-2 realizam coletas sobre a vegetação, solos, rios e dados para correção atmosférica com capacidade de revisita de cinco dias. O satélite ainda apresenta resoluções espaciais que variam de 10 a 60 metros. Para este estudo foram utilizadas as bandas presentes nas resoluções de 10 e 20 metros, sendo elas: B2, B3, B4, B5, B6, B7, B8A, B8, B11 e B12.

Foram desenvolvidos códigos em linguagem Javascript para criar uma coleção de imagens referente a todo o ano de 2020. Em seguida, foi criado um filtro de 10% de nuvens nas imagens, e depois obtida a mediana de cada pixel. Por fim, foi realizado recorte das imagens para a área de estudo. Por meio do desenvolvimento de algoritmos na plataforma, gerou-se o Índice de Diferença Normalizada da Água (NDWI), conforme a (Equação 1). O NDWI

é útil para identificação de água dentro da vegetação a partir das bandas B8, correspondente à região espectral do infravermelho próximo (NIR), e B12, a qual corresponde à região do infravermelho de ondas curtas.

$$NDWI = \left(\frac{NIR - SWIR}{NIR + SWIR} \right) \quad (1)$$

Onde:

NDWI: Índice de Diferença Normalizada da Água;

NIR: Região espectral do infravermelho próximo;

SWIR: Região espectral do infravermelho de ondas curtas.

CLASSIFICAÇÃO DAS IMAGENS

O processamento dos dados foi executado em Javascript no editor de códigos do GEE. Após testes iniciais com diferentes dados de entrada, optou-se por utilizar quatro combinações distintas para realizar a classificação dos campos de murundus (Tabela 1). Dessa forma, três combinações foram geradas a partir de diferentes regiões espectrais do Sentinel-2 (visível, Red-Edge, NIR e SWIR) e uma combinação recebeu o Índice de Diferença Normalizada da Água (NDWI).

Tabela 1. Combinações de dados de entrada para a classificação das áreas úmidas.

Combinações	Dados de entrada
1	Sentinel-2 (B2, B3, B4, B5, B6, B7, B8A, B8, B11, B12)
2	Sentinel-2 Red-Edge (B5, B6, B7, B8A) e NIR (B8)
3	Sentinel-2 visível (B2, B3, B4) e SWIR (B11, B12)
4	Sentinel-2 (B2-B12), NDWI

Fonte: Elaborado pelos autores, 2022.

Utilizou-se o algoritmo Random Forests para realizar a classificação das imagens. Esse método foi proposto e desenvolvido inicialmente por Breiman (2001), o qual elaborou uma técnica de agregação de classificadores do tipo árvores de decisão, construídos de forma que sua estrutura fosse composta de maneira aleatória. Para determinar a classe de uma instância,

o método desenvolvido combina o resultado de várias árvores de decisão por meio de um mecanismo de votação. No final do processo, cada árvore irá emitir uma classificação e, desta forma, a classificação final será a classe que receber mais votos entre todas as árvores do Random Forests.

Foi realizada a coleta de amostras de treinamento do algoritmo a partir da criação de polígonos no layout do GEE. Utilizou-se uma composição colorida RGB 432 para interpretação visual da área de estudo, bem como imagens de alta resolução do Google disponíveis no GEE para identificar os alvos. Para realizar a classificação foram escolhidas apenas duas classes, áreas úmidas (50 amostras) e áreas não-úmidas (200 amostras).

AVALIAÇÃO DA ACURÁCIA DA CLASSIFICAÇÃO

Os dados de referência para a avaliação da acurácia foram gerados de forma independente, a partir da delimitação manual das AU. Assim, os dados de referência e os dados gerados pelas classificações foram sobrepostos no software Qgis, obtendo a acurácia do produtor (Equação 2) e a acurácia do usuário (Equação 3). Em seguida, calculou-se o índice F-measure (Equação 4), correlacionando os resultados obtidos por ambas as acurácias. É importante destacar que o método de avaliação da acurácia utilizado no presente estudo fornece uma informação mais acurada do que aquela extraída da matriz de confusão. Isso se deve à sobreposição de toda área de referência com o mapa classificado, ao contrário de estudos que possuem erros inerentes à geração de amostras para validação (RADOUX, 2011).

$$AP = \left(\frac{\text{Área de AU corretamente classificada}}{\text{Área de referência de AU}} \right) \times 100 \quad (2)$$

$$AUS = \left(\frac{\text{Área de AU corretamente classificada}}{\text{Área total de AU classificada}} \right) \times 100 \quad (3)$$

$$F_{\text{measure}} = \left(\frac{2 \times AP \times AUS}{AP + AUS} \right) \quad (4)$$

Onde:

AP: Acurácia do produtor;

AUS: Acurácia do usuário.

Resultados e Discussões

O resultado das avaliações das acurácias das classificações das áreas úmidas pode ser visualizado na Tabela 2. De modo geral, todas as quatro combinações de dados de entrada da classificação tiveram resultados satisfatórios. É possível destacar que a combinação entre o NDWI e todas as bandas do Sentinel-2 obteve o maior valor do índice F-measure (75.5%). Entretanto, nota-se que o NDWI contribuiu pouco para o aumento do índice, uma vez que utilizando-se apenas as bandas do Sentinel-2 obteve-se um resultado do índice F-measure muito próximo.

Tabela 2. Avaliação da acurácia das classificações das áreas úmidas.

Resultados	Sentinel (B2-B12)	Sentinel e NDWI	Sentinel (Red-Edge e NIR)	Sentinel (Visível e SWIR)
Área de referência (ha)	24975	24975	24975	24975
Área total classificada (ha)	22468	22626	19384	22439
AU corretamente classificada (ha)	17821	17970	15393	14887
Acurácia do produtor (%)	71,35	71,95	61,63	59,60
Acurácia do usuário (%)	79,31	79,42	79,41	66,34
F-measure (%)	75,11	75,5	69,39	62,78

Fonte: Elaborado pelos autores, 2022.

Em relação a combinação que utilizou apenas as bandas do Red-Edge e NIR, observa-se que essas regiões espectrais fornecem uma classificação satisfatória, mesmo utilizando apenas cinco bandas. Por outro lado, a utilização exclusiva das bandas do visível e SWIR proporcionaram o pior resultado (F-measure= 62,78%). Diante desses resultados, é possível

constatar que as bandas que contribuem com informações mais relevantes para a detecção dos campos de murundus são o Red-Edge e NIR.

Resultado similar foi constatado por Amani *et al.* (2018), os quais utilizaram o *Random Forest* para classificar AU no Canadá, a partir de imagens *Rapideye* e obtiveram uma acurácia global de 86%. Os autores afirmam que o NIR seguido das bandas do *Red-Edge* são mais eficientes na detecção das AU, pois fornecem informações específicas sobre suas características bioquímicas e biofísicas, tornando mais fácil e eficiente o processo de distinção entre as classes escolhidas para o estudo. Ao utilizar essas regiões espectrais é possível gerar resultados mais precisos, que se traduzem em uma acurácia mais elevada em comparação as bandas do SWIR por exemplo, as quais apresentam uma menor capacidade de separação entre as classes.

Ao classificar áreas úmidas na Turquia, Kaplan e Avdan (2019) utilizaram uma abordagem distinta visando melhorar a eficiência de detecção desses alvos. Os autores utilizaram as bandas do Red-Edge do satélite Sentinel-2 para detectar diferentes subclasses de AU, resultando em uma melhora de 27% na detecção. Os autores recomendam que a classificação das áreas úmidas deve ser feita com mais de uma classe, devido a sua complexa estrutura. É importante destacar que as AU apresentam diferentes fisionomias de acordo com cada bioma e que a análise das melhores variáveis para detectar esses alvos deve considerar o tipo específico de área úmida. Nesse sentido, a área de estudo do presente trabalho é dominada por apenas uma classe de área úmida, os campos de murundus. Apesar disso, a região espectral do Red-Edge também se mostrou eficaz no mapeamento dessas feições, uma vez que possibilitou a diminuição dos erros de classificação entre outras classes de uso do solo.

Um dos principais motivos para o bom desempenho da detecção dos campos de murundus utilizando apenas sensores ópticos está relacionado com a fisionomia da vegetação. Esse tipo de área úmida apresenta vegetação esparsa, composta por pequenos arbustos e gramíneas. Por esse motivo, é possível obter uma assinatura espectral própria dos campos de murundus, a qual é resultante da interação da radiação com o solo e a vegetação rasteira. Por

outro lado, outros tipos de área úmidas podem apresentar maiores quantidades de formações florestais, impossibilitando a aquisição da informação por meio de sensores ópticos. Nesses casos, recomenda-se a utilização de sensores que utilizam a região espectral das microondas, as quais conseguem atravessar o dossel e coletar informações da superfície do solo.

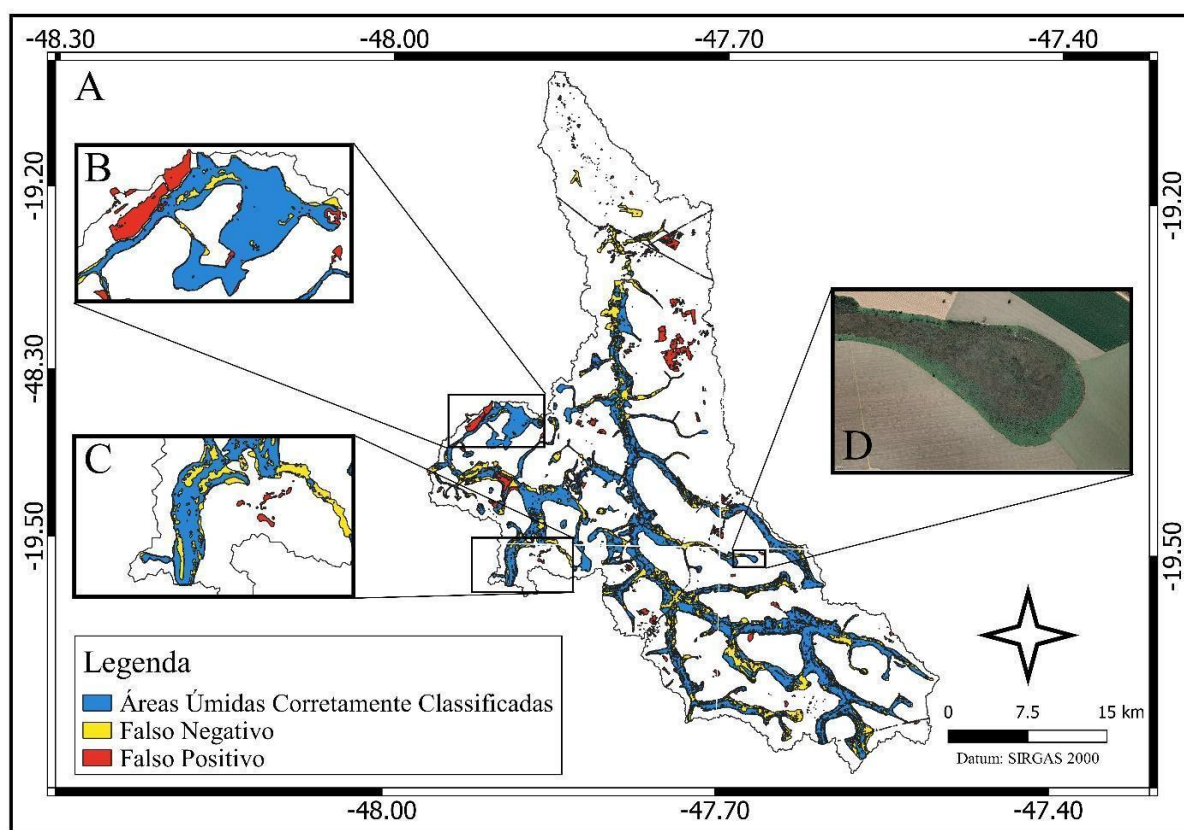
Nota-se, na Tabela 2, que a acurácia do usuário foi superior à acurácia do produtor em todas as classificações, indicando que o erro de omissão (falso-negativo) foi o principal problema durante a classificação dos campos de murundus. Em estudos na área do sensoriamento remoto é possível observar diversos problemas relacionados às confusões espectrais durante o processo de classificação de imagens. Penha *et al.* (2017) destacam certas adversidades no mapeamento, como por exemplo a presença de alvos escuros na imagem, acarretando erros de comissão e omissão. Dessa forma, algumas regiões apresentaram confusões espectrais entre as AU, solo exposto e agricultura, tornando complexa a delimitação dos locais com AU. Isso ocorre devido à heterogeneidade desses alvos, os quais apresentam uma mistura de diferentes classes, dificultando a criação de um padrão espectral único.

Apesar das confusões espectrais citadas, nota-se que o algoritmo de classificação Random Forests apresentou um desempenho muito bom no mapeamento dos murundus. Diferentemente dos classificadores supervisionados paramétricos, os quais assumem uma distribuição normal dos dados, os classificadores não-paramétricos, como o Random Forests, não fazem restrições sobre a distribuição da frequência e por isso se aproximam mais da realidade. A eficiência da utilização do classificador Random Forests foi estudada por Simioni *et al.* (2020), que comparou quatro classificadores do tipo machine learning diferentes, sendo eles, Classification and Regression Tree (CART), Artificial Neural Network (ANN), Random Forests (RF) e por fim k-Nearest Neighbors (k-NN). Os dados obtidos pelos autores demonstraram que os classificadores Random Forests e o k-Nearest Neighbors apresentaram os melhores resultados.

A Figura 4 contém o resultado do melhor mapeamento automático das áreas úmidas, demonstrando as áreas em que houve omissão (falso-negativo) ou classificação errada das AU

(falso-positivo). Nota-se que o classificador conseguiu detectar a maioria das regiões com áreas úmidas (área em azul). Assim, foi possível detectar automaticamente 22626 ha de AU diante de 24975 ha computados nos dados de referência, representando 71,95% de acurácia do produtor, quando foi utilizada todas as bandas do Sentinel-2 e o NDWI.

Figura 4 - A) Classificação das áreas úmidas a partir da combinação 4 de dados de entrada; B) Detalhes do mapeamento das áreas úmidas; C) Detalhes do mapeamento das áreas úmidas; D) Imagem de satélite do campo de murundu.



Fonte: Elaborado pelos autores, 2022.

Segundo Shimabukuro e Ponzoni (2017), a utilização de bandas espectrais obtidas em diferentes regiões do espectro eletromagnético é importante para o processamento de dados. No entanto, alguns alvos, como as áreas úmidas, podem apresentar zonas de confusão espectral devido à mistura de classes. Tendo em vista que a utilização de bandas espectrais individuais pode não ser suficiente para atingir os resultados esperados, é possível acrescentar

uma série de variáveis que forneçam um produto com menor mistura de classes, como por exemplo a criação de índices espectrais.

Nesse sentido, Valenti *et al.* (2020) utilizaram o GEE para gerar índices espectrais visando detectar áreas úmidas na Bacia dos Grandes Lagos (Estados Unidos). De acordo com os autores, o índice que apresentou a melhor acurácia foi o Índice de Extensão da Água Superficial Dinâmica. O estudo apresentou uma acurácia global de 86,2%, sendo que a acurácia do usuário foi de 70% para áreas úmidas, enquanto a acurácia do produtor foi de 82,7%. Ferrão (2021) utilizou igualmente o GEE para a detecção, delimitação e análise de AU na bacia Hidrográfica do rio Gravataí (RS) e constatou que o índice NDWI foi eficiente.

Em contrapartida, o presente estudo não obteve melhoras significativas ao adicionar o índice NDWI às bandas Sentinel-2. Uma das razões poderia ser a generalização criada pela composição de imagens utilizadas, uma vez que foi realizada a mediana de todas as imagens do ano de 2020. Assim, os campos de murundus apresentam diferenças de acordo com a época do ano. Em períodos de chuva, o nível da água fica próximo à superfície, uma vez que o solo fica saturado. Já em períodos de estiagem o nível é rebaixado e os campos de murundus deixam de ser um local de produção de água. Diante disso, os autores recomendam que, para estudos futuros, as imagens de entrada sejam separadas entre a estação seca e a chuvosa, visando analisar a influência das diferenças sazonais na detecção remota dessas feições.

Considerações Finais

Estudos que visam mapear as áreas úmidas são de grande importância para compreensão da dinâmica desses ambientes e sua relação com o entorno. O presente estudo investigou por meio da plataforma GEE, a eficiência das bandas do satélite Sentinel-2 para detectar campos de murundus na bacia do rio Claro. De acordo com os resultados obtidos, a combinação Sentinel-2 com NDWI se mostrou a mais eficaz para o mapeamento semiautomático desses alvos.

Os resultados obtidos mostram que a utilização do algoritmo Random Forests apresenta um grande potencial no mapeamento dos campos de murundus a partir da

utilização exclusiva de sensores ópticos. Isso é possível devido a fisionomia dessas feições, as quais são dominadas por vegetação rasteira e arbustos, e pelas características espectrais do Sentinel-2. Nesse sentido, as bandas do Red-Edge e do infravermelho próximo se destacaram como importantes regiões espectrais para a detecção das áreas úmidas, demonstrando sensibilidade em detectar suas características bioquímicas e biofísicas. Além disso, o GEE permitiu adquirir e processar informações de maneira rápida e gratuita, demonstrando seu potencial em detectar e monitorar os campos de murundus em grandes extensões.

Referências

- AMANI, M.; SALEHI, B.; MAHDAVI, S.; BRISCO, B. Spectral analysis of wetlands using multi-source optical satellite imagery. **ISPRS Journal of photogrammetry and remote sensing**, v. 144, 119-136, 2018. DOI: <https://doi.org/10.1016/j.isprsjprs.2018.07.005>.
- BREIMAN, L. "Random Forests". Machine Learning. 2001. doi:10.1023/A:1010933404324.
- ESQUERDO, J. C. D. M.; ANTUNES, J. F. G. Monitoramento temporal de variáveis espectrais em áreas do pantanal utilizando dados AVHRR/NOAA-17. **Revista Brasileira de Cartografia**, v. 62, n. 4, 11. 2010.
- MONTEIRO, M. C. Mudanças na cobertura e uso da terra e impactos ambientais nas áreas úmidas na Chapada do Bugre (Triângulo Mineiro) entre 1987 e 2018. 2019. 125 f. Dissertação (Mestrado em Geografia) - Universidade Federal de Goiás, Goiânia, 2019.
- CUNHA, C. N. C.; PIEDADE, M. T. F.; JUNK, W. F. Classificação e delineamento das áreas úmidas brasileiras e de seus macrohabitats. Instituto Nacional de Ciência e Tecnologia em Áreas Úmidas – INAU. – Cuiabá: EdUFMT, 2015.
- GIBBS, J. P. Wetland loss and biodiversity conservation. **Conservation biology**, v. 14, n.1, p. 314-317, 2000.
- GOOGLE. Google Earth website. <http://earth.google.com/>, 2022.
- GOMES, C. S.; MAGALHÃES JÚNIOR, A. P. Sistemas de classificação de áreas úmidas no Brasil e no mundo: panorama atual e importância de critérios hidrogeomorfológicos. **Geo UERJ**, Rio de Janeiro, n. 33, 2018. DOI: <https://doi.org/10.12957/geouerj.2018.34519>.
- 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 Sensing**, v. 12, n. 7, 2020. DOI: <https://doi.org/10.3390/rs12071182>.

HIRD, J. N.; DELANCEY, E. R.; MCDERMID, G. J.; KARIYEVA, J. Google Earth engine, open-access satellite data, and machine learning in support of large-area probabilistic wetland mapping. **Remote Sensing**, v. 9, n. 12, dezembro, 2017. DOI: <https://doi.org/10.3390/rs9121315>.

INSTITUTO MINEIRO DE GESTÃO DAS ÁGUAS (IGAM). Outorga de lançamento de efluentes na Bacia do Ribeirão da Mata. Instituto Mineiro de Gestão das Águas. Belo Horizonte. 2013.

JUNK, W. J.; PIEDADE, M.T.F; LOURIVAL, R; WITTMANN, F; KANDUS, P; LACERDA, L.D; BOZELLI, R.L; ESTEVES, F.A; CUNHA, C.N; MALTCHIK, L; SCHÖNGART, J; SCHAEFFER-NOVELLI, Y; AGOSTINHO, A.A. Brazilian wetlands: their definition, delineation, and classification, for research, sustainable management, and protection. **Aquatic Conservation: Marine and Freshwater Ecosystems**, v. 24, n. 1, 5-22, 2013. DOI: <https://doi.org/10.1002/aqc.2386>.

KANDUS, P.; MINOTTI, P. G.; MORANDEIRA, N. S.; GRIMSON, R.; TRILLA, G. G.; GONZÁLEZ, E. B.; MARTIN, L. S.; GAYOL, M. P. Remote sensing of wetlands in South America: status and challenges. **International Journal of Remote Sensing**, v. 39, n. 4, 2018. DOI: <https://doi.org/10.1080/01431161.2017.1395971>.

KAPLAN, G.; AVDAN, U. Evaluating Sentinel-2 Red-Edge Bands for Wetland Classification. **Proceedings**, v. 18, n. 1, 2019. DOI: <https://doi.org/10.3390/ECRS-3-06184>.

MAHDIANPARI, M.; SALEHI, B.; MOHAMMADIMANEH, F.; HOMAYOUNI, S. E.; Gill, E. The first wetland inventory map of newfoundland at a spatial resolution of 10m using Sentinel-1 and Sentinel-2 data on the Google Earth engine cloud computing platform. **Remote Sensing**, v. 11, n. 1, dezembro, 2018. DOI: <https://doi.org/10.3390/rs11010043>.

MAHDIANPARI, M.; JAFARZADEH, H.; GRANGER, J. E.; MOHAMMADIMANESH, F.; BRISCO, B.; SALEHI, B.; HOMAYOUNI, S.; WENG, Q. A large-scale change monitoring of wetlands using time series Landsat imagery on Google Earth Engine: a case study in Newfoundland. **GIScience & Remote Sensing**, v. 57, 1102-1124, 2020. DOI: <https://doi.org/10.1080/15481603.2020.1846948>.

MENDONÇA, F.; DANNI-OLIVEIRA, I. M. Climatologia: Noções Básicas e Climas do Brasil. Chapter 1, 9-34, 2011.

MERCHANT, M. A.; OBADIA, M.; BRISCO, B.; DEVRIES, B.; BERG, A. Applying Machine Learning and Time-Series Analysis on Sentinel-1A SAR/InSAR for Characterizing Arctic Tundra Hydro-Ecological Conditions. **Remote Sensing**, v. 14, 1123-1137, 2022. DOI: <https://doi.org/10.3390/rs14051123>.

NICULESCU, S.; BOISSONAT, J. B.; LARDEUX, C.; ROBERTS, D.; HANGANU, J.; BILLEY, A.; CONSTANTINESCU, A.; DOROFTEI, M. Synergy of High-Resolution Radar and Optical Images Satellite for Identification and Mapping of Wetland Macrophytes on the Danube Delta. **Remote Sensing**, v. 12, n. 14, 2020. DOI: <https://doi.org/10.3390/rs12142188>.

PAULA, C. O. Conflicts of the use of water in river basin light and impacts in agricultural activity. 2014. 99 f. Dissertação (Mestrado em Ciências Agrárias) - Universidade Federal de Uberlândia, Uberlândia, 2014. DOI <https://doi.org/10.14393/ufu.di.2014.390>.

PONZONI, F.J.; SHIMABUKURO, Y.E. Mistura Espectral modelo linear e aplicações. Oficina de Textos. São Paulo – SP, 2017.

QUEIROZ, R. R. Os Impactos da Ação Antrópica sobre a Microbacia Hidrográfica do Córrego do Atoleiro. 2012. Dissertação – ICPD, Brasília, 2012.

RADOUX, J.; BOGAERT, P.; FASBENDER, D.; DEFOURNY, P. Thematic accuracy assessment of geographic object-based image classification. **Int. J. Geogr. Inf. Sci**, 25, 895–911. 2011.

RAMOS, M. V. V.; HARIDASAN, M.; ARAÚJO, G. M. Caracterização dos solos e da estrutura fitossociológica da vegetação de veredas da chapada do Triângulo Mineiro. **Fronteiras: Journal of Social, Technological and Environmental Science**, v. 3, n. 2, p. 180-210, 2014.

SANTOS, P. T.; MARTINS, A. P. Análise da Vulnerabilidade Ambiental da Bacia Hidrográfica do Rio Claro (GO) Utilizando Geotecnologias. **Revista Do Departamento De Geografia**, v. 36, 155-170, 2018. <https://doi.org/10.11606/rdg.v36i0.143665>.

SHELESTOV, A.; LAVRENIUK, M.; KUSSUL, N.; NOVIKOV, A.; SKAKUN, S. Exploring Google Earth Engine Platform for Big Data Processing: Classification of Multi-Temporal Satellite Imagery for Crop Mapping. **Remote Sensing**, v. 5, 2017. DOI: <https://doi.org/10.3389/feart.2017.00017>.

SILVA, A. G. P.; CREMON, E. H.; BOGGIONE, G. A.; ALVES, F. C. Integração de imagens orbitais ópticas e SAR com processamento em nuvem no mapeamento da cobertura da terra no Cerrado. **Revista Geoaraguaia**. v.11 n. Esp. Geotecnologias p. 85- 106. Ago-2021.

VALENTI, V.; CARCELEN, E. C.; LANGE, K.; RUSSO, N. J.; 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 Journal of selected topics in applied earth observations and remote sensing**, v. 13, 6008-6018, 2020. DOI: 10.1109/JSTARS.2020.3023901.

WANG, Q.; WANG, X.; ZHOU, Y.; LIU, D.; WANG, H. The dominant factors and influence of urban characteristics on land surface temperature using random forest algorithm. **Sustainable Cities and Society**, v. 79, 2022. DOI: <https://doi.org/10.1016/j.scs.2022.103722>.

ZHU, L.; SUOMALAINEN, J.; LIU, J.; HYYPAÄ, J.; KAARTINEN, H.; HAGGREN, H. A REVIEW: REMOTE SENSING SENSORS. **Multi-purposeful Application of Geospatial Data**. Chapter 2, 19-42, 2018. DOI: <https://doi.org/10.5772/intechopen.71049>.