



ISSN: 2447-3359

REVISTA DE GEOCIÊNCIAS DO NORDESTE

*Northeast Geosciences Journal*

v. 10, nº 2 (2024)

<https://doi.org/10.21680/2447-3359.2024v10n2ID36390>



## Mapeamento de superfícies impermeáveis no Oeste da Bahia utilizando algoritmo de Aprendizado de Máquina

### *Mapping of impermeable surfaces in Western Bahia using Machine Learning Algorithm*

Gustavo Gonçalves de Souza<sup>1</sup>; Elvis Bergue Mariz Moreira<sup>2</sup>; Admilson da Penha Pacheco<sup>3</sup>; Fabio Corrêa Alves<sup>4</sup>; Henrique dos Santos Ferreira<sup>5</sup>

<sup>1</sup> Universidade Federal do Oeste da Bahia, Centro das Ciências Exatas e das Tecnologias, Barreiras /BA, Brasil. Email: [gustavo.goncalves@ufob.edu.br](mailto:gustavo.goncalves@ufob.edu.br)

ORCID: <https://orcid.org/0009-0004-3732-2510>

<sup>2</sup> Universidade Federal do Oeste da Bahia, Centro das Humanidades, Barreiras/BA, Brasil. Email: [elvis.moreira@ufob.edu.br](mailto:elvis.moreira@ufob.edu.br)

ORCID: <https://orcid.org/0000-0001-6732-3005>

<sup>3</sup> Universidade Federal de Pernambuco, Departamento de Engenharia Cartográfica, Recife/PE, Brasil. Email: [pacheco3p@gmail.com](mailto:pacheco3p@gmail.com)

ORCID: <https://orcid.org/0000-0002-3635-827X>

<sup>4</sup> Universidade Federal do Oeste da Bahia, Centro das Humanidades, Barreiras/BA, Brasil. Email: [fabio.alves@ufob.edu.br](mailto:fabio.alves@ufob.edu.br)

ORCID: <https://orcid.org/0000-0002-2941-8393>

<sup>5</sup> Centro de Integração de Dados e Conhecimentos para Saúde – CIDACS, Salvador/BA, Brasil. Email: [ferreira.hds@hotmail.com](mailto:ferreira.hds@hotmail.com)

ORCID: <https://orcid.org/0000-0003-3134-4984>

**Resumo:** A superfície impermeável urbana é um parâmetro relevante nas mudanças climáticas, ambientais e na sustentabilidade, sendo fundamental na detecção da qualidade ambiental urbana. O mapeamento possibilita mensurar o nível de urbanização que uma cidade se encontra, podendo gerar indicativos de impactos sociais, econômicos e ambientais. Porém, poucos estudos aplicaram imagens de satélite de alta resolução espacial para a análise de cidades com significativo crescimento urbano nos últimos anos, sobretudo no oeste baiano. O objetivo deste trabalho consistiu em mapear as áreas impermeáveis da cidade de Barreiras–BA através de imagens do satélite CBERS–4A e o algoritmo de aprendizado de máquina Random Forest (RF). Utilizou-se as bandas espectrais do visível na data 13/06/2023 para a realização da composição colorida e fusão de imagens na obtenção dos *pixels* com 2m. A imagem fusionada foi classificada com o RF e validada através da matriz de confusão, acurácia global e índice Kappa. Os resultados mostraram que na cidade de Barreiras 41,11% correspondem às superfícies impermeáveis. As métricas de exatidão encontradas significaram 0,79 para o Índice Kappa e 91,7% de Acurácia Global. Os resultados encontrados poderão ser base para futuras pesquisas sobre mapeamento do uso e ocupação do solo em perímetros urbanos.

**Palavras-chave:** Sensoriamento remoto; Urbanização; CBERS–4A.

**Abstract:** Urban impermeable surface is a relevant parameter in climate and environmental change and sustainability, and is fundamental in detecting urban environmental quality. Mapping makes it possible to measure a city's level of urbanization and can provide indications of social, economic and environmental impacts. However, few studies have used high spatial resolution satellite images to analyze cities with significant urban growth in recent years, especially in western Bahia. The aim of this study was to map the impermeable areas of the city of Barreiras-BA using images from the CBERS-4A satellite and the Random Forest (RF) machine learning algorithm. The visible spectral bands on 13/06/2023 were used for color composition and image fusion to obtain 2m pixels. The fused image was classified using RF and validated using the confusion matrix, global accuracy and Kappa index. The results showed that in the city of Barreiras 41.11% correspond to impermeable surfaces. The accuracy metrics found were 0.79 for the Kappa Index and 91.7% for Global Accuracy. The results found can be used as a basis for future research into mapping land use and occupation in urban perimeters.

**Keywords:** Remote sensing; Urbanization; CBERS–4A.

Recebido: 22/05/2024; Aceito: 05/07/2024; Publicado: 12/08/2024.

## 1. Introdução

Desde a segunda revolução industrial no final do século XIX, o mundo tem experimentado uma rápida urbanização em um ritmo sem precedentes e continuará nas décadas futuras (LI *et al.*, 2020; UNO, 2018). A rápida urbanização traz benefícios sociais e econômicos, bem como a grave deterioração do ambiente e de questões sociais, como a poluição do ar e da água, a perda de biodiversidade, o efeito de ilha de calor urbana, problemas de escoamento superficial, desigualdade econômica e social (ZHANG *et al.*, 2021; LI *et al.* 2014). Neste contexto, uma superfície impermeável (SI) pode ser definida como aquela com características feitas pelo homem pelas quais a água não pode infiltrar, como por exemplo, telhados de edifícios, entradas de automóveis e áreas de estacionamento (LI *et al.*, 2020). A presença de SIs com o processo de urbanização contribui para mudanças nas estruturas espaciais urbanas e nas propriedades da superfície terrestre (ZHU, *et al.*, 2022). Estas mudanças ocorrem devido à conversão de superfícies naturais do terreno em superfícies urbanas impermeáveis (SUI) (SHAO, *et al.*, 2024). A SI refere-se a uma superfície de terreno pavimentada com materiais impermeáveis ou de baixa permeabilidade dentro dos limites do desenvolvimento urbano, geralmente incluindo edifícios, estruturas, estradas impermeáveis, ruas pavimentadas, praças, estacionamentos, entre outros (CAI *et al.*, 2022; SHAO *et al.*, 2024).

As áreas de SIs e os espaços verdes (EV), dois componentes principais do ambiente urbano são fundamentais na detecção da qualidade ambiental urbana e na abordagem de questões de mudança ambiental global (KUANG *et al.*, 2021). As SIs, que representam a cobertura do solo mais comum nas áreas urbanas, não só proporcionam comodidade à cidade, mas também exercem impactos ambientais negativos significativos, afetando a capacidade de suporte do ambiente ecológico das aglomerações urbanas. Assim, monitorar as composições urbanas espacial e temporalmente é uma questão crucial para o planejamento e gestão urbana (ZHANG *et al.*, 2021).

O aumento das SUIs alterou e ainda vem alterando severamente o equilíbrio ecológico nas áreas metropolitanas, impactando os regimes hidrológicos e levando à redução dos espaços permeáveis adjacentes (PAREKH *et al.*, 2021). A mudança de superfícies naturais ou seminaturais em superfícies impermeáveis impacta o balanço de radiação na interface terrestre, resultando em um aumento na temperatura da superfície local e nas temperaturas do ar (KOTARBA, *et al.*, 2016). Além disso, a quantidade crescente de superfícies impermeáveis também pode perturbar a recarga da água subterrânea e aumentar o risco de inundações, como evidenciado em vários contextos urbanos (SU *et al.*, 2022).

O sensoriamento remoto tem sido amplamente utilizado para a detecção de superfícies impermeáveis (PAREKH *et al.*, 2021). Em especial, o uso do sensoriamento remoto óptico a partir de imagens disponíveis gratuitamente, com cobertura global e ciclos curtos de revisita se torna útil em aplicações visando informar o desenvolvimento urbano sustentável (SAAH *et al.*, 2019). Na última década, dados de novos sensores orbitais multiespectrais e multitemporais com resoluções espaciais finas surgiram como alternativas essenciais para estimar aspectos como cobertura vegetal, degradação florestal e expansão urbana (NAIKOO *et al.*, 2020). As técnicas de sensoriamento remoto têm sido amplamente aplicadas para analisar composições urbanas espaço-temporais em grandes áreas geográficas e com custos relativamente baixos (ZHANG *et al.*, 2021). Motivado pela importância das superfícies impermeáveis, estudos recentes concentraram-se no monitoramento de superfícies impermeáveis usando dados de sensoriamento remoto (NJOKU; TENENBAUM, 2022; OLIVATTO; INGUAGGIATO, 2023; AMINI *et al.*, 2022; STNGANINI, 2023). Porém, poucos estudos exploraram imagens de satélite gratuitas em resoluções mais finas em estudos urbanos. O satélite CBERS-4A tem sido utilizado em diversos estudos do uso e ocupação do solo devido os seus aspectos espacial, espectral e temporal e pelo fato da disponibilidade gratuita de suas imagens. Em particular, o sensor WPM (Câmera Multiespectral e Pancromática de Ampla Varredura), deste satélite, devido à sua alta resolução espacial de 2 m (INPE, 2022), apresenta-se com alto potencial para atender a múltiplos requisitos de aplicações em estudos urbanos de mapeamento de superfícies impermeáveis.

Em adição às imagens de satélite, o uso de algoritmos de aprendizado de máquina vêm demonstrando muito eficazes em classificações digitais diversas nos últimos anos, incluindo as de áreas urbanas (MARKERT *et al.*, 2020; PAREKH *et al.*, 2021). São exemplos dessas metodologias, técnicas como Árvores de Classificação e Regressão (CARTs) (WANG *et al.*, 2018; WANG *et al.*, 2021), Random Forest (RF) (ZHENG *et al.*, 2023; LIU; YANG; HUANG, 2023), Redes Neurais Artificiais (RNAs) (MAHYOUB *et al.*, 2022) e Máquinas de Vetores de Suporte (SVMs) (BROWN *et al.*, 2022). Lodato *et al.* (2023) aplicaram o RF em imagens Landsat e através de técnicas de sensoriamento remoto e serviços de nuvem inovadores, documentaram a transformação da região costeira no norte de Roma, uma importante área rural, em novos serviços residenciais e comerciais. Dong *et al.*, (2021) investigaram as variações espaciais e temporais de superfícies impermeáveis no sexto anel rodoviário de Pequim usando dados de imagens Landsat de 1997 a 2017, empregando o método (RF). Os resultados mostraram uma melhora de 16,23% na precisão da classificação para as superfícies impermeáveis

altamente refletivas, significando a eficácia do RF no aumento da precisão da detecção de superfícies impermeáveis (DONG *et al.*, 2021).

O investimento na urbanização tem uma grande notoriedade pela população, entretanto, concomitantemente com esse desenvolvimento, a falta de planejamento desencadeia problemas socioeconômicos e ambientais nas cidades de todo o Brasil (TUCCI, 2008). Na cidade de Barreiras, como é o caso de muitas das cidades brasileiras, os sistemas de drenagem não suportam a alta demanda da vazão causada pela impermeabilização e da diminuição da cobertura vegetal do solo. Neste contexto, este estudo tem como objetivo mapear as áreas impermeáveis da cidade de Barreiras no oeste baiano a partir da integração de imagens fusionadas do satélite CBERS-4A com o algoritmo de aprendizado de máquina RF.

## 2. Metodologia

A área selecionada para o presente estudo é o perímetro urbano da cidade de Barreiras, que está localizada na região oeste do Estado da Bahia (Figura 1). Essa área possui ~ 8051,274 km<sup>2</sup> (IBGE, 2021), com altitude média de 452 m.

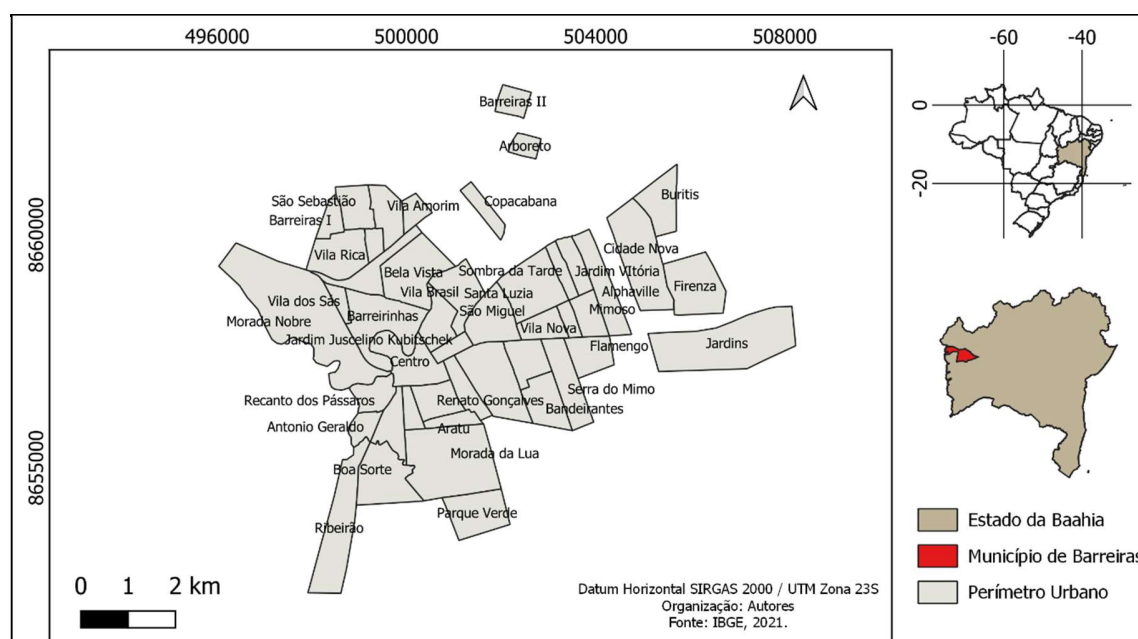


Figura 1 – Localização do perímetro urbano de Barreiras, Bahia.

Fonte: Autores (2024).

Segundo o IBGE (2022), a população de Barreiras era de 137 mil habitantes em 2010, sendo que cerca de 90% dessa população residia em área urbana. A estimativa do último censo do IBGE (2022) indica uma população de 159.734 pessoas e densidade demográfica de 19,84 hab/km<sup>2</sup>.

Para o desenvolvimento do estudo, imagens da Câmera Multiespectral na faixa espectral do visível (B1 azul – 0,45 – 0,52  $\mu\text{m}$ ; B2 verde – 0,52 – 0,59  $\mu\text{m}$ ; e B3 vermelho – 0,63 – 0,69  $\mu\text{m}$ ) e pancromática (0,77 – 0,89  $\mu\text{m}$ ) (WPM) do satélite CBERS-4A foram adquiridas através da divisão de geração de imagens (DGI) do Instituto Nacional de Pesquisas Espaciais. A imagem referente a data de 13/06/2023 foi selecionada uma vez que apresentou menor cobertura de nuvens, e portanto, melhor qualidade radiométrica para prosseguir com o mapeamento das áreas impermeáveis.

As bandas do azul, verde e vermelho (B1, B2 e B3) do satélite CBERS-4A foram fusionadas através da ferramenta mesclar/mosaico do SIG QGIS 3.28. Na sequência, realizou-se os ajustes de nitidez (equalização) da imagem fusionada. Logo após essa etapa foi definido a cor de cada camada e realizou-se alguns ajustes de histograma da imagem produzida para possibilitar uma melhor qualidade da composição colorida.

As bandas multiespectrais do CBERS-4A apresenta no modo multiespectral resolução espacial média de 8 m, no modo pancromático possui alta resolução espacial de 2m (INPE, 2023). Com o auxílio do Software QGIS foi possível unir essas

imagens com um procedimento chamado *Pansharpening*, que consiste na fusão das imagens multiespectrais e pancromática, possibilitando a redução da resolução espacial de 8 m para 2 m.

Neste estudo a classificação digital de imagem foi feita com base no algoritmo de aprendizado de máquina RF, implementado no pacote *Dzetsaka: Classification Tool* do software. As classes selecionadas para a classificação foram: vegetação, solo exposto, água, área urbana e outros (sombra das edificações). Para realizar a classificação foram coletadas 100 amostras para cada classe e selecionadas 22 amostras para a classe Outros. O método de classificação RF foi utilizado para gerar os percentuais de área de cada classe. Basicamente, o RF agrupou as árvores de decisão e classificou os *pixels* que se encaixavam nos parâmetros das árvores. Os parâmetros utilizados no RF são aqueles estabelecidos como padrão no pacote *Dzetsaka: Classification Tool*.

Após a classificação foi utilizada a ferramenta *Classification Report do Semi-Automatic Classification Plugin*, para gerar o percentual de cada classe no perímetro urbano de Barreiras e posteriormente, de cada bairro. No presente trabalho assumiu-se todo tipo de área construída como sendo impermeável, tendo em vista que a modificação da cobertura do solo torna este menos permeável, mesmo que não por completo. Para efeitos de comprovação visual com a imagem classificada, foi utilizada também imagens do *Google Earth* de resolução espacial fina.

Adicionalmente, foi utilizado dados complementares, exemplo do *shapefile* dos bairros do perímetro urbano de Barreiras baseado no zoneamento do Plano Diretor mais atual da cidade, bem como os dados de limites dos bairros disponíveis no *Google Earth*. A partir do raster de classificação do RF de todo perímetro urbano, foi possível recortá-lo por bairros e obter o valor de área de cada classe em km<sup>2</sup> e o percentual de área impermeável por bairro. Sendo assim, tornou-se possível comparar o percentual de impermeabilização de cada bairro e obter o percentual em relação ao perímetro total da cidade com o auxílio do editor de planilhas Excel.

Com base na imagem classificada pelo RF foi gerada a matriz de confusão e calculada a acurácia global, a acurácia por classe (produtor e usuário) e o índice Kappa (CONGALTON, 1991). A matriz de confusão é uma forma de expressar a qualidade obtida a partir da classificação de imagens digitais, através da análise de amostras de validação em conjunto com os dados de classificação (LILLESAND, T.; KIEFER, 1994; RICHARDS, 1993). A acurácia global, por classe e o índice Kappa foram calculados a partir da ferramenta Accuracy do Semi-Automatic Classification Plugin (SCP) do QGIS com base nas equações 1 e 2:

$$F_m = \frac{\sum X_i}{N} * 100 \quad \text{Equação 1}$$

$$k = \frac{N \sum_{i=1}^r (X_{ii}) - \sum_{i=1}^r (X_{i+} X_{+i})}{N^2 - \sum_{i=1}^r (X_{i+} X_{+i})} \quad \text{Equação 2}$$

Na qual, segundo (CONGALTON, 1991):

k = Coeficiente Kappa de concordância;

N = Número total de observações (pontos amostrais);

r = Número de linhas e colunas da Matriz de Confusão;

$X_{ii}$  = Número de observações na linha i e colunas i

$X_{i+}$  = Valores totais das linhas i

$X_{+i}$  = Valores totais das colunas i

O Kappa é um índice que demonstra o nível de concordância dos dados, gerando indicativos de precisão dos resultados da classificação (LILLESAND, T.; KIEFER, 1994; RICHARDS, 1993), apresenta variação de 0 a 1. Além disso, este índice possibilita a comparação de métodos de classificação e também da conferência com classificações prévias. Assim, utilizaram-se as métricas de exatidão e análises comparativas visuais entre a imagem fusionada, classificada e aquelas disponíveis no *Google Earth*.

### 3. Resultados e discussão

A Figura 2 apresenta a imagem fusionada do satélite CBERS-4A e as amostras utilizadas (100) para separar as áreas impermeáveis na classificação. Inspeções visuais iniciais entre a imagem classificada e a imagem complementar do *Google Earth*, possibilitou identificar que a classe sombras de edificações estava sendo erroneamente classificada como água, pela proximidade da assinatura espectral entre ambas as classes. Por esta razão, a classe sombra de edificações foi incluída na presente análise objetivando minimizar erros de classificação. Foram realizados testes antes da classificação final a fim de identificar possíveis problemas de confusão espectral entre as classes mapeadas.

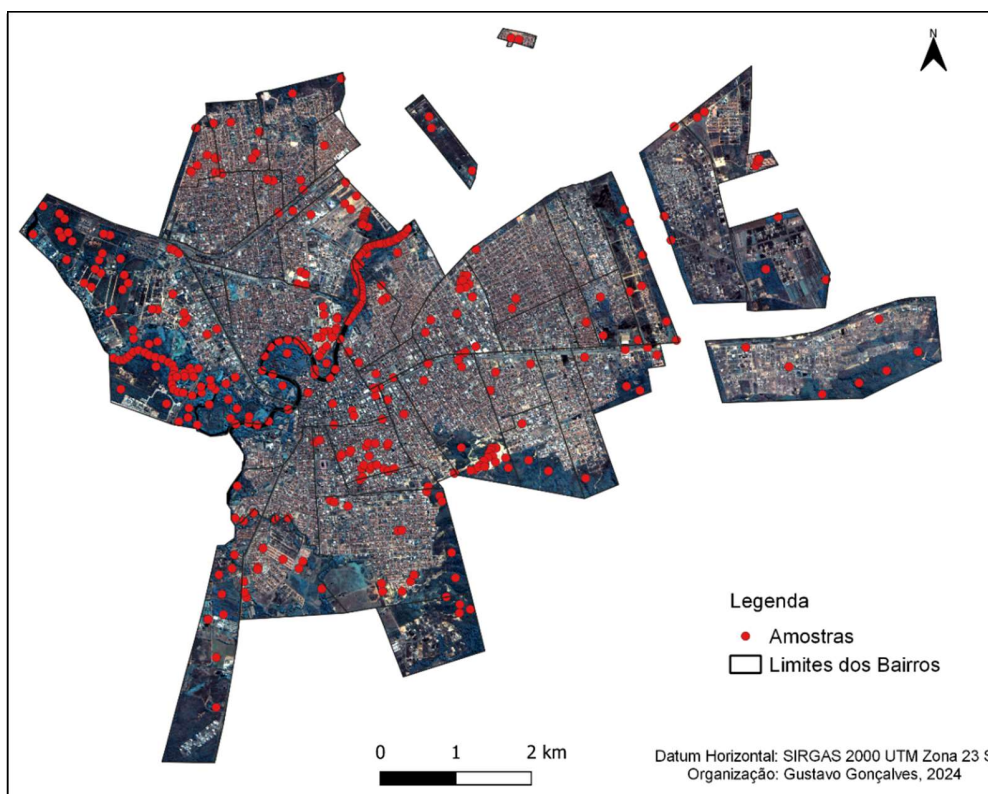


Figura 2 – Imagem fusionada do CBERS-4A destacando as amostras utilizadas para separar as áreas impermeáveis.  
Fonte: Autores (2024).

A Figura 3a-c ilustra a imagem fusionada, imagem do *Google Earth* e a classificação (RF1) de um trecho do bairro Firenzi, onde é exemplificado os erros de classificação devido à confusão entre as respostas espectrais da vegetação e solo exposto, e da vegetação e área urbana. Com o intuito de minimizar esses efeitos, realizou-se um teste a fim de separar a vegetação mais esparsa da classe área urbana. Para isso, incluíram-se novas amostras e adicionou a classe vegetação rasteira. Os resultados dessa classificação não foram satisfatórios, verificou-se em algumas regiões do perímetro urbano confusão dos *pixels* com vegetação rasteira.



Figura 3 – Exemplo de classificação de imagem ilustrando confusão dos pixels de vegetação com área urbana.  
Fonte: Autores (2024).

Na tentativa de separar a vegetação rasteira da classe urbana, adicionou-se mais amostras da vegetação rasteira e realizou nova classificação, entretanto, sem sucesso. Dessa vez, predominou *pixels* da área urbana confundidos como vegetação rasteira, Figura 4a-c.

Tendo como base os resultados das classificações (RF 2) supracitada, decidiu-se permanecer com os resultados da primeira classificação (RF 1) por ser visualmente mais legítima à classe urbana, foco do presente estudo. A alta resolução espacial de 2 m representada pela imagem pancromática não impossibilitou a homogeneização dos *pixels* entre si, isso devido a imagem classificada manter a resolução espacial de 8 m das imagens multiespectrais.

A Figura 5a-c apresenta os alvos com material de telhado cerâmica, onde é possível identificar a homogeneização dos *pixels* através do zoom na imagem fusionada (Figura 5a), o qual aumenta a dificuldade de distinguir visivelmente a cobertura de casa com telha cerâmica de solo exposto, devido à proximidade espectral do que foi coletado para as classes.

Um dos fatores que possibilita realizar a coleta dos pontos e consequentemente uma maior eficácia na classificação, está relacionado com a pureza dos *pixels*. A classe área urbana, por exemplo, é composta por diferentes tipos de alvos com características espectrais diferentes (vegetação, concreto, coberturas de zinco, alumínio, água, solo exposto, etc.). Nesse sentido, quanto mais diversificado for a disposição de materiais impermeáveis no solo, mais possível tornar-se-á a mistura dos *pixels* nesse nível de resolução espacial, o que implica na confusão das classes. Assim, processamento do algoritmo de classificação RF torna-se difícil, ao receber respostas espectrais bem parecidas e com resolução que em parte não auxilia dividir as classes minuciosamente. Uma alternativa para minimizar esses efeitos seria o uso de imagens de mais alta resolução espacial, com as de Veículos Aéreos Não Tripulados (Vants), por exemplo. Entretanto, por imagear uma área menor no terreno, essas imagens não atenderiam o propósito de analisar o perímetro urbano em sua totalidade, necessitando de maior tempo, e recursos financeiros.

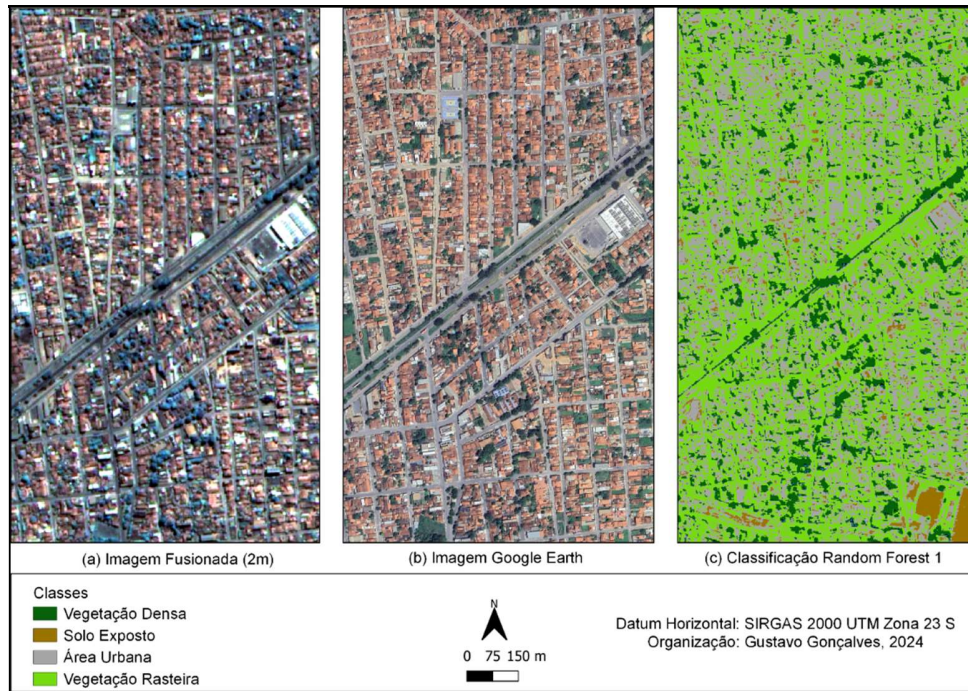


Figura 4 – Exemplo de classificação de imagem ilustrando confusão dos pixels de vegetação com área urbana.  
Fonte: Autores (2024).



Figura 5 – Análise do telhado cerâmico.  
Fonte: Autores (2024).

A Figura 6 apresenta a classificação pelo algoritmo RF, onde é observado uma boa concordância visual entre a imagem classificada e a imagem de alta resolução espacial do *Google Earth* (Figura 7). O resultado desta classificação indicou um predomínio da classe vegetação (18,54 km<sup>2</sup>), seguido da classe área urbana (17,79 km<sup>2</sup>), solo exposto (6,41 km<sup>2</sup>) e água (0,44 km<sup>2</sup>).

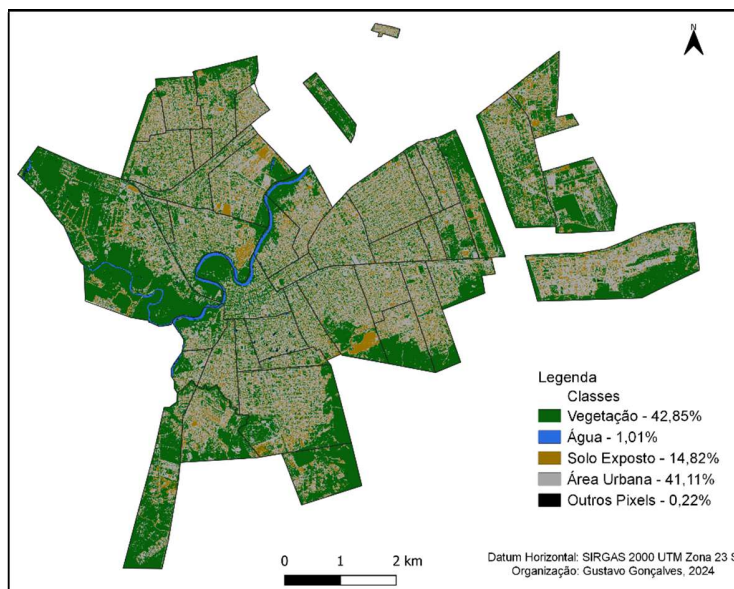


Figura 6 – Classificação do uso e ocupação do solo de Barreiras com imagem CBERS 4A.

Fonte: Autores (2024).



Figura 7 – Imagem do Google Earth da cidade de Barreiras.

Fonte: Autores (2024).



A classificação realizada foi avaliada com base na matriz de confusão, acurácia global, acurácia por classe (acurácia do produtor e usuário) e índice Kappa. Os resultados das métricas de exatidão são apresentados nas Tabelas 1 e 2. O mapa de uso e cobertura do solo para o perímetro urbano de Barreiras revelou uma acurácia global alta, 91,79%. A classe área urbana foi a que apresentou maior confusão de *pixels* com as demais classes, assim como esperado. Do total de 74.963 *pixels* para a linha da matriz, apenas 48.466 *pixels* foram classificados corretamente como área urbana, concebendo 64,65% de acerto. No caso da classe solo exposto, 20.533 *pixels* dessa classe foi considerada pelo produtor como área urbana, o que representa 27,39% da quantidade total da linha e confirma a confusão com os elementos urbanos. A classe vegetação se destacou com a maior quantidade de *pixels* classificados (305.169), obtendo o maior percentual de *pixels* classificados corretamente pelo produtor, (300.560), representando 98,49% de acerto. Nessa classe a maior confusão ocorreu com área urbana, onde 4.041 *pixels* foram classificados incorretamente.

Tabela 1 – Matriz de confusão para as classes mapeadas em Barreiras, BA.

Classes	Vegetação	Água	Solo exposto	Área Urbana	Outros	Total
Vegetação	300560	27	0	5905	41	306533
Água	149	13627	0	36	347	14159
Solo exposto	247	0	8868	20533	0	29648
Área Urbana	4041	0	1519	48466	0	54026
Outros	172	235	0	22	646	1075
Total	305169	13889	10387	74963	1034	405442

Fonte: Autores (2024).

Tabela 2 – Acurácia da classificação do uso e ocupação do solo de Barreiras, BA.

Classes	Vegetação	Água	Solo exposto	Área urbana	Outros
Acurácia do Usuário %	98,05	96,24	29,91	89,71	60,09
Acurácia do Produtor %	98,49	98,11	85,38	64,65	62,48
Acurácia Global %	91,79				
Índice Kappa por Classes	0,92	0,96	0,28	0,87	0,60
Kapa Global	0,79				

Fonte: Autores (2024).

A acurácia por classe, representada na Tabela 2, apresentou os maiores valores de acurácia do usuário na classe vegetação (98,05 %), água (96,24 %) e área urbana (89,71 %), enquanto as acurácias mais baixas foram encontradas para a classe outros (60,09 %) e solo exposto (29,91 %). De forma similar, as classes vegetação e água também revelaram valores altos de acurácia do produtor, sendo (98,49 %) e (98,11 %), respectivamente.

Nesta análise, a classe área urbana (64,65 %) e outros (62,48 %) foram as que apresentaram os piores resultados. A maior confusão de *pixels* ocorreu na classe solo exposto com área urbana (Tabela 1), onde há vegetação rasteira com presença de solo, observada em alguns bairros da cidade ainda pouco habitados, normalmente em lotes ainda sem construção. É confirmado a confusão entre a água e as sombras de edificações verticais (outros - *pixels* excluídos). A classificação apresentou resultados satisfatórios de acordo com o índice Kappa, alcançando o valor global de 0,79. Isoladamente, a classe água foi a que apresentou maior valor de índice Kappa (0,96) e a classe solo exposto o menor valor (0,28).

A matriz de confusão confirma o que já foi mencionado, a área urbana devido a sua diversidade de materiais, apresentam *pixels* impuros na resolução espacial de 2 m e, esses atribuem a uma mesma classe os demais *pixels* com assinatura espectral semelhante. A distribuição espacial da área total impermeável foi de 41,11% (Figura 8), sendo os bairros do perímetro urbano com os percentuais mais expressivos: Morada da Lua (6,41%), Morada Nobre (5,67%) e Santa Luzia (4,47%).



Figura 8 – Percentual de área impermeável total e não permeável representadas nos polígonos dos bairros de Barreiras, BA.

Fonte: Autores (2024).

A Figura 9 mostra o percentual (%) e área (km<sup>2</sup>) de impermeabilização do perímetro urbano de Barreiras em relação a área de cada bairro. Os bairros Jardins, Morada Nobre e Cidade Nova, localizado na porção noroeste e à nordete do perímetro urbano, apresentaram os maiores valores de área e percentual de impermeabilização. Enquanto os bairros Jardim, Juscelino Kubitschek, Vila dos Funcionários e Copacabana localizados na porção centro-norte do perímetro urbano da cidade, revelaram os menores valores de impermeabilização.




Figura 9 – Percentual (%) e área (km²) de impermeabilização do perímetro urbano de Barreiras em relação a área de cada bairro.

Fonte: Autores (2024).

Alguns bairros pouco habitados na cidade de Barreiras ficaram com grande porcentagem de impermeabilização devido sua grande extensão, e por haver predomínio de vegetação rasteira. O bairro Jardins (Figura 10) representa o exemplo,

essencontra-se no topo da classificação, conforme apresentado na Figura 9, apresentando a maior concentração de adensamento urbano, comparado com os demais bairros. Além disso, é possível visualizar grande áreas abertas compostas de vegetação e solo exposto.

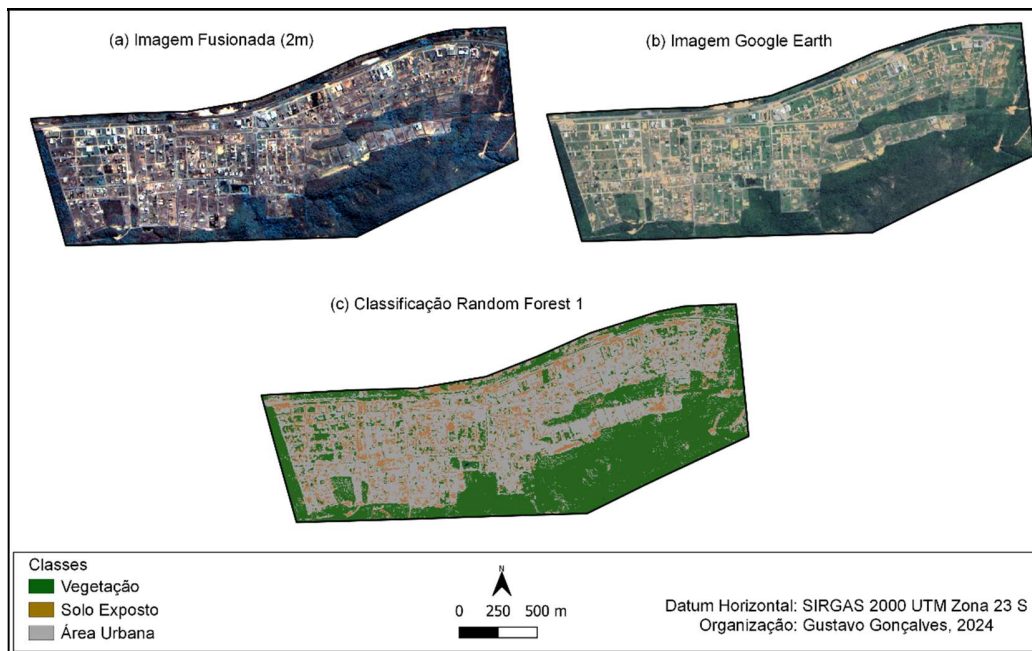


Figura 10 – Análise comparativa entre a imagem fusionada, do Google Earth e classificada para o bairro Jardins em Barreiras, BA.

Fonte: Autores (2024).

Similarmente, outros bairros com grandes confusões entre classes, mas que revelaram alto percentual de impermeabilização, incluem o de Cidade Nova (Figura 11), apresentando algumas confusões de *pixels*, predominantes com solo exposto e área urbana ao norte do bairro. É possível visualizar também confusão de vegetação rasteira e área urbana nas rotatórias do bairro e, nos canteiros da via principal que atravessa o bairro diagonalmente.

Os bairros Morada Nobre (Figura 12), Morada da Lua (Figura 13) e Santa Luzia (Figura 14) mostraram os melhores resultados na classificação, enquanto o bairro Jardins (Figura 10) e Cidade Nova (Figura 11), destacaram-se com grande confusão nas classes. O bairro Morada da Lua, apresentou índice de impermeabilização de 6,41% do total, concordando visualmente com a imagem fusionada do CBERS – 4A e com a imagem de alta resolução do *Google Earth*, onde grande parte deste bairro é composto por área construída. O bairro Santa Luzia possui a menor extensão espacial comparado com os demais outros bairros mencionados, entretanto, é o mais populoso da cidade (PREFEITURA DE BARREIRAS, 2019). Este bairro predomina em sua superfície vias e moradias, representando 4,47% em relação ao percentual de todo perímetro urbano.

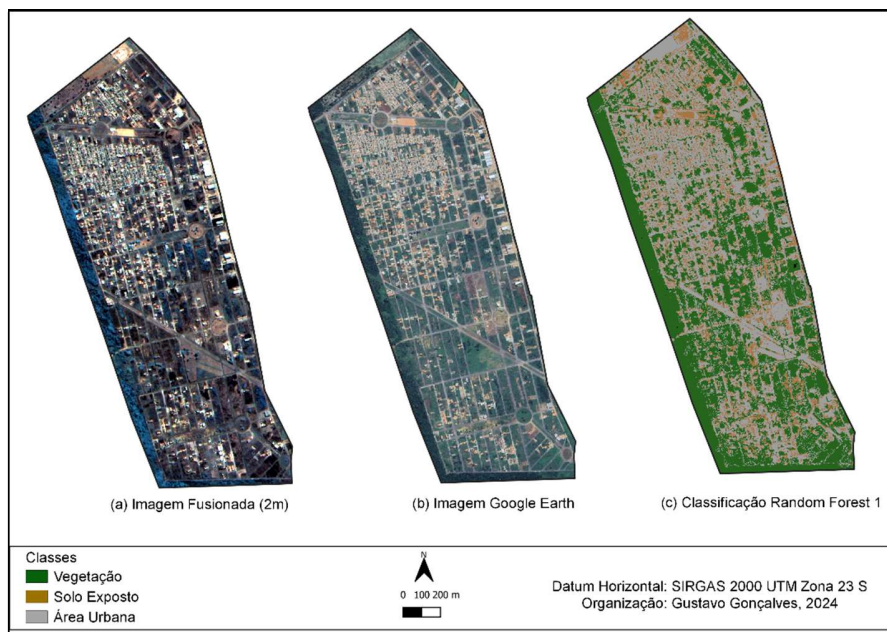


Figura 11 – Análise comparativa entre a imagem fusionada, imagem do Google Earth e imagem classificada do bairro Cidade Nova em Barreiras, BA.

Fonte: Autores (2024).

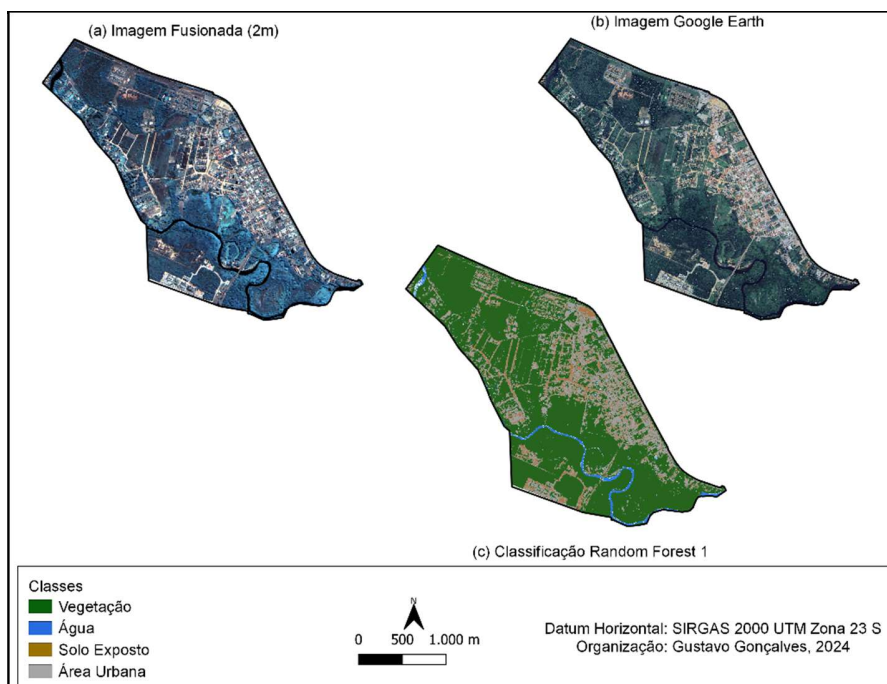


Figura 12 – Análise comparativa entre a imagem fusionada, classificada e do Google Earth para o bairro Morada Nobre em Barreiras, BA.

Fonte: Autores (2024).

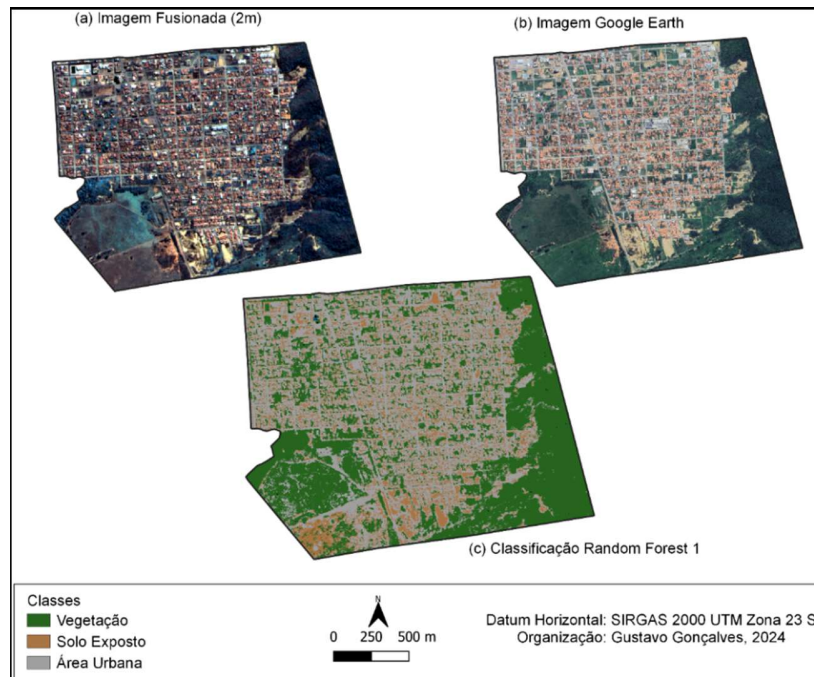


Figura 13 – Análise comparativa entre a imagem fusionada, classificada e Google Earth do bairro Morada da Lua em Barreiras, BA.  
Fonte: Autores (2024).

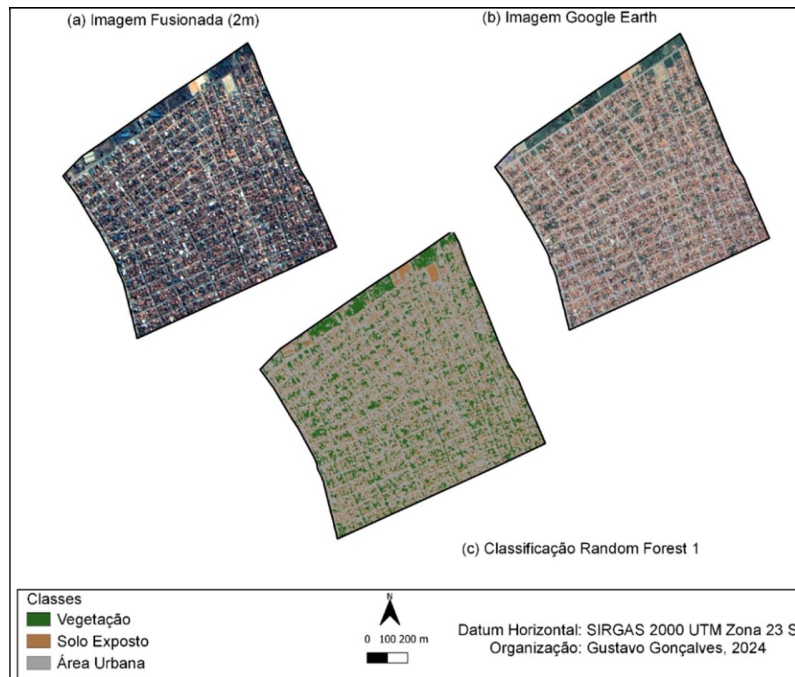


Figura 14 – Análise comparativa entre a imagem fusionada, classificada e do Google Earth para o bairro Santa Luzia em Barreiras, BA.  
Fonte: Autores (2024).

Em relação às confusões de *pixels* encontradas entre áreas impermeáveis e vegetação rasteira, assim como solo exposto com cobertura de telhado cerâmico, elas são justificadas pela semelhança de assinatura espectral dos materiais envolvidos na classificação. No caso da vegetação rasteira, confundida com tonalidade acinzentada na imagem fusionada, é possível que este resultado tenha sido gerado de forma natural. Podendo a vegetação estar seca ou talvez pela possibilidade desse tipo de vegetação ter nascido em um solo orgânico. Desta forma, a tonalidade próximo do preto, entretanto, não se descarta que a angulação do sol no momento em que a imagem foi obtida pelo satélite tenha influenciado no sombreamento dessa vegetação, se por exemplo, comparada com a imagem do *Google Earth*.

A diferença do comportamento espectral dos diferentes tipos de materiais presentes na cobertura do solo urbano faz com que a classificação apresente semelhança na análise espectral da área impermeável na resolução espacial de 2m, utilizada neste estudo. Desta forma, os diferentes tipos de materiais (asfalto, concreto, fibrocimento, telha cerâmica e de zinco) podem superestimar ou subestimar algumas áreas classificadas.

Dong *et al.* (2021) utilizaram o (RF) para extrair as superfícies impermeáveis em Pequim para estudar as mudanças espaço-temporal de superfícies impermeáveis a partir de imagens de satélite Landsat. A avaliação da precisão do trabalho mostrou que a estratégia de classificação, combinando características espectrais e texturais baseadas em RF, tem um desempenho ideal nas áreas urbanas complexas, com o coeficiente Kappa sendo 0,85. Os resultados obtidos pelos pesquisadores supracitados corroboram com os adquiridos neste trabalho no qual foi obtido um índice Kappa de 0,79 e uma acurácia global de 91,79%. Wu; Pan (2023), analisaram superfícies impermeáveis na área urbana de Nachang, China, através de imagens do CBERS-4A, Landsat 8 e Sentinel-1. Os autores utilizaram o algoritmo RF, e obtiveram resultados de acurácia global entre 88,3% e 92,55%. Estudos prévios, com aplicações semelhantes de análise espaço-temporal de superfícies impermeáveis em áreas urbanas, apresentaram resultados semelhantes aos obtidos nessa pesquisa, incluindo Hirye *et al.* (2015), Sun *et al.* (2017), Chang *et al.* (2020), Sobieraj; Fernández; Metelski (2022).

#### 4. Considerações finais

Essa pesquisa evidenciou o potencial das imagens CBERS-4A fusionada com a banda de alta resolução espacial (2m), e o algoritmo RF (envolvendo seleção aleatória de recursos e seleção aleatória de amostras) no mapeamento de superfícies impermeáveis em áreas urbanas. Os resultados permitiram quantificar o percentual e área (km<sup>2</sup>) de impermeabilização, contemplando todo perímetro urbano de Barreiras e relacionar com a área de cada bairro. Essas informações preenchem uma lacuna existente nos dados de planejamento urbano da cidade.

A classificação apresentou métricas de exatidão aceitáveis, elucidando acurácia global e índice Kappa com resultados satisfatórios. As classes água e solo exposto analisadas individualmente, destacaram o maior e menor valor de acurácia, respectivamente. A resposta dessas métricas, foram relevantes na concordância visual encontrada, entre a imagem classificada e a imagem do *Google Earth*. A estatística de acurácia do usuário e acurácia do produtor utilizadas, possibilitaram identificar nas classes os erros de omissão e comissão. Nesse sentido, constatou-se nos bairros onde há o maior adensamento construtivo de áreas impermeáveis, as menores confusões de *pixels* nas classes.

A heterogeneidade dos alvos presentes na superfície do perímetro urbano, foi presumível de ser diferenciada na alta resolução da imagem, entretanto, resultaram em respostas semelhantes na classificação. Desta forma, constatou-se que, os diferentes tipos de materiais (asfalto, concreto, fibrocimento, telha cerâmica e de zinco) podem superestimar ou subestimar algumas áreas classificadas.

Os resultados encontrados podem elucidar as bases técnico-científicas no estado da arte para futuras pesquisas sobre mapeamento do uso e ocupação do solo de superfícies impermeáveis em áreas urbanas a partir de técnicas de sensoriamento remoto/aprendizado de máquina e imagens de alta resolução espacial.

#### Referências

- Amini S., Saber, M. Rabiei-Dastjerdi, H., Homayouni, S. Urban Land Use and Land Cover Change Analysis Using Random Forest Classification of Landsat Time Series. *Remote Sensing*, 14, 11, 2654, 2022. <https://doi.org/10.3390/rs14112654>.
- Belgiu, M., Drăgu, L. Random Forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sensing*, 114, 24–31, 2016.

- Cai, B., Shao, Z., Fang, S., Huang, X., Tang, Y., Zheng, M., Zhang, H. The Evolution of Urban Agglomerations in China and How It Deviates from Zipf's Law. *Geo-spatial Information Science*, 27, 1, pp. 38–48, 2022. <https://doi.org/10.1080/10095020.2022.2083527>.
- Chang, S., Wang, Z.; Mao, D., Guan, K.; Jia, M., Chen, C. Mapping the Essential Urban Land Use in Changchun by Applying Random Forest and Multi-Source Geospatial Data. *Remote Sensing*, 12, 15, 2488, 2020 <https://doi.org/10.3390/rs12152488>.
- Dong, X., Meng, Z., Wang, Y., Zhang, Y., Sun, H., Wang, Q. Monitoring Spatiotemporal Changes of Impervious Surfaces in Beijing City Using Random Forest Algorithm and Textural Features. *Remote Sensing*, 13, 153, 2021. <https://doi.org/10.3390/rs13010153>.
- Hirye, M. C. de M., Alves, D., Kux, H. Mapeamento da cobertura da terra na cidade de Altamira (PA) em 2000 e 2010, com a utilização do modelo linear de mistura espectral de imagens do sensor TM. *Revista Brasileira de Cartografia*, 67, 1, 157–168, 2015. DOI: <https://doi.org/10.14393/rbcv67n1-44731>.
- IBGE. Instituto Brasileiro de Geografia e Estatística. *Censo Demográfico 2022*. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/22827-censo-demografico-2022.html?edicao=35938&t=resultados/>. Acesso em: 1/05/2023.
- IBGE. Instituto Brasileiro de Geografia e Estatística. *População Rural e Urbana*. Disponível em: <https://educa.ibge.gov.br/%20jovens/conheca-o-brasil/populacao/18313-populacao-rural-e-urbana.html> . Acesso em: 08/06/2023.
- INPE. Instituto Nacional de Pesquisas Espaciais. Câmeras Imageadoras CBERS 04A. Disponível em: <http://www.cbears.inpe.br/sobre/cameras/cbers04a.php>. Acesso em: 22/04/2023.
- Kotarba, A.Z., Aleksandrowicz, S. Impervious surface detection with nighttime photography from the International Space Station. *Remote Sensing of Environment*, 176, 295–307, 2016. <https://doi.org/10.1016/j.rse.2016.02.009>.
- Kuang, W., Hou, Y., Dou, Y., Lu, D., Yang, S. Mapping Global Urban Impervious Surface and Green Space Fractions Using Google Earth Engine. *Remote Sensing* 13, 4187, 2021. <https://doi.org/10.3390/rs13204187>
- Li, W., Wu, C., & Zang, S. Modeling urban land use conversion of Daqing City, China: a comparative analysis of “top-down” and “bottom-up” approaches. *Stochastic Environmental Research and Risk Assessment*, 28, 4, 817–828, 2014. <http://dx.doi.org/10.1007/s00477-012-0671-0>.
- Li, Wenliang. Mapping Urban Impervious Surfaces by Using Spectral Mixture Analysis and Spectral Indices. *Remote Sensing*, 12, 1, 94, 2020. <https://doi.org/10.3390/rs12010094>.
- Lillesand, T., Kiefer, R.W. *Remote Sensing and Image Interpretation*. 3.ed. New York: John Wiley & Sons, 1994, 768p.
- Liu, Z., Yang, J., Huang, X. Landsat-Derived Impervious Surface Area Expansion in the Arctic from 1985 to 2021. *Sci. Total Environ.* 905, 166966, 2023. <https://doi.org/10.1016/j.scitotenv.2023.166966>.
- Mahyoub, S., Rhinane, H., Mansour, M., Fadil, A., Okaishi, W.A. Impervious Surface Prediction in Marrakech City Using Artificial Neural Network. *International Journal of Advanced Computer Science and Applications IJACSA.*, 13, 185–189, 2022. <https://doi.org/10.1016/j.scitotenv.2023.166966>.
- Markert, K.N., Markert, A.M., Mayer, T., Nauman, C., Haag, A., Poortinga, A., Bhandari, B.; Thwal, N.S., Kunlamai, T., Chishtie, F., et al. Comparing sentinel-1 surface water mapping algorithms and radiometric terrain correction processing in southeast asia utilizing google earth engine. *Remote Sensing*. 12, 2469, 2020. <https://doi.org/10.3390/rs12152469>.



- Naikoo, M. W., Rihan, M., Ishtiaque, M., Shahfahad. Analyses of land use land cover (LULC) change and built-up expansion in the suburb of a metropolitan city: Spatio temporal analysis of Delhi NCR using landsat datasets. *Journal of Urban Management*, 9, 3, 347–359, 2020. <https://doi.org/10.1016/j.jum.2020.05.004>.
- Njoku, E. A., Tenenbaum, D. E. Aquantitative assessment of the relationship between land use/land cover (LULC), topographic elevation and land surface temperature (LST) in Ilorin, Nigeria. *Remote Sensing Applications: Society and Environment*, 27, 100780, 2022. <https://doi.org/10.1016/j.rsase.2022.100780>.
- Olivatto, T. F., Inguaggiato, F. F., Stanganini, F. N. Urban mapping and impacts assessment in a Brazilian irregular settlement using UAV-based imaging. *Remote Sensing Applications: Society and Environment*, 29, 100911, 2023. <https://doi.org/10.1016/j.rsase.2022.100911>.
- Parekh, J.R., Poortinga, A., Bhandari, B., Mayer, T., Saah, D. Chishtie, F. Automatic Detection of Impervious Surfaces from Remotely Sensed Data Using Deep Learning. *Remote Sensing*, 13, 16, 3166, 2021. <https://doi.org/10.3390/rs13163166>
- PREFEITURA DE BARREIRAS. *Relatório Plano Diretor – Planejamento Participativo*: Barreiras, 2019.
- Richards, J. A. *Remote Sensing Digital Image Analyses: an introduction*. 2. ed. Berlin: Springer-Verlag, 1993, 340p.
- Saah, D., Tenneson, K., Matin, M., Uddin, K., Cutter, P., Poortinga, A., Nguyen, Q. H., Patterson, M., Johnson, G., Markert, K., et al. Land cover mapping in data scarce environments: Challenges and opportunities. *Frontiers in Environmental Science*, 7, 150, 2019. <https://doi.org/10.3389/fenvs.2019.00150>.
- Shao, Z.; Cheng, T.; Fu, H.; Li, D.; Huang, X. Emerging Issues in Mapping Urban Impervious Surfaces Using High-Resolution Remote Sensing Images. *Remote Sensing*, 15, 2562, 2023. <https://doi.org/10.3390/rs1510256>.
- Sobieraj, J.; Fernández, M.; Metelski, D. A. Comparison of Different Machine Learning Algorithms in the Classification of Impervious Surfaces: Case Study of the Housing Estate Fort Bema in Warsaw (Poland). *Buildings*, 12, 12, 2115, 2022. <https://doi.org/10.3390/buildings12122115>.
- Su, S., Tian, J., Dong, X., Tian, Q., Wang, N., Xi, Y. An Impervious Surface Spectral Index on Multispectral Imagery Using Visible and Near-Infrared Bands. *Remote Sensing*, 14, 14, 3391, 2022. <https://doi.org/10.3390/rs14143391>.
- Sun, Z., Wang, C., Guo, H., Shang, R. A Modified Normalized Difference Impervious Surface Index (MNDISI) for Automatic Urban Mapping from Landsat Imagery. *Remote Sensing*, 9, 9, 942, 2017; <https://doi.org/10.3390/rs9090942>.
- Tucci, C.E.M. (2008). Águas urbanas. *Estudos avançados*, 22, 63, 97–112.
- UNO. United Nations Organization. (2018). *World Urbanization Prospects: The 2018 Revision*. UN Department of Economic and Social Affairs: New York, NY, USA, 2018.
- Wang, J.; Wu, Z.; Wu, C.; Cao, Z.; Fan, W.; Tarolli, P. Improving Impervious Surface Estimation: An Integrated Method of Classification and Regression Trees (CART) and Linear Spectral Mixture Analysis (LSMA) Based on Error Analysis. *Gisci. Remote Sensing*, 55, 4, 583–603, 2018. <https://doi.org/10.1080/15481603.2017.1417690>.
- Wang, Y., Huang, Q., Zhao, A., Lv, H., Zhuang, S. Semantic Network-Based Impervious Surface Extraction Method for Rural Urban Fringe from High Spatial Resolution Remote Sensing Images. *IEEE J. Sel. Top. Applied Earth Observations and Remote Sensing*, 14, 4980–4998, 2021. <http://dx.doi.org/10.1109/JSTARS.2021.3078483>.
- Wu, Y. Pan, J. Detecting Changes in Impervious Surfaces Using Multi-Sensor Satellite Imagery and Machine Learning Methodology in a Metropolitan Area. *Remote Sensing*, 15, 22, 5387, 2023. <https://doi.org/10.3390/rs15225387>.
- Zhang, L, Yugang Tian, Y., Liu, Q. A Novel Urban Composition Index Based on Water-Impervious Surface-Pervious Surface (W-I-P) Model for Urban Compositions Mapping Using Landsat Imagery. *Remote Sens.* 13, 1, 3, 2021. <https://dx.doi.org/10.3390/rs13010003>.

---

Zheng, Z., Yang, B., Liu, S.; Xia, J. Zhang, X. Extraction of Impervious Surface with Landsat Based on Machine Learning in Chengdu Urban, China. *Remote Sensing Applications: Society and Environment*, 30, 100974, 2023. <https://doi.org/10.1016/j.rsase.2023.100974>.

Zhu, Z., Qiu, S.; Ye, S. Remote Sensing of Land Change: A Multifaceted Perspective. *Remote Sensing of Environment* 282, 1, 113266, 2022. <https://doi.org/10.1016/j.rse.2022.113266>.