

UNIVERSIDADE FEDERAL DO PAMPA

ANDRÉ FONTANA WEBER

**ANÁLISE DE IMAGENS DE SATÉLITE PARA DETECÇÃO DE LIXO:
DESAFIOS E POTENCIALIDADES PARA A GESTÃO AMBIENTAL
SUSTENTÁVEL**

**ITAQUI
2024**

ANDRÉ FONTANA WEBER

**ANÁLISE DE IMAGENS DE SATÉLITE PARA DETECÇÃO DE LIXO:
DESAFIOS E POTENCIALIDADES PARA A GESTÃO AMBIENTAL
SUSTENTÁVEL**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Cartográfica de Agrimensura da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Engenheiro Cartógrafo e Agrimensor.

Orientador: Cristiano Galafassi

**ITAQUI
2024**

Ficha catalográfica elaborada automaticamente com os dados fornecidos pelo(a) autor(a) através do Módulo de Biblioteca do Sistema GURI (Gestão Unificada de Recursos Institucionais).

A555a Fontana, André Weber

Análise de imagens de satélite para detecção de lixo: desafios e potencialidades para a gestão ambiental sustentável / André Fontana Weber. – 2024.

37 p.: il.

Orientador: Cristiano Galafassi

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Pampa, Engenharia Cartográfica e de Agrimensura, Campus Itaqui, 2024.

1. Meio Ambiente. 2. Sustentabilidade. 3. Pixel. 4. Imagens de Satélite. 5. Modelagem. I. Fontana, A. II. Título.

ANDRÉ FONTANA WEBER

**ANÁLISE DE IMAGENS DE SATÉLITE PARA DETECÇÃO DE LIXO:
DESAFIOS E POTENCIALIDADES PARA A GESTÃO AMBIENTAL
SUSTENTÁVEL**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Cartográfica e de Agrimensura da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Bacharel em (Engenharia Cartográfica e de Agrimensura).

Área de concentração: Engenharia.

Trabalho de Conclusão de Curso defendido e aprovado em: 12 de julho de 2024.

Banca examinadora:



Documento assinado digitalmente

CRISTIANO GALAFASSI

Data: 16/07/2024 08:07:23-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Cristiano Galafassi

Orientador

Universidade Federal do Pampa (Unipampa)



Documento assinado digitalmente

SIDNEI LUIS BOHN GASS

Data: 18/07/2024 14:31:34-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Sidnei Bom Gass

Universidade Federal do Pampa (Unipampa)



Documento assinado digitalmente

IGOR SILVEIRA ELESBAO

Data: 16/07/2024 12:31:35-0300

Verifique em <https://validar.iti.gov.br>

Prof. Igor Silveira Elesbae

Universidade Federal do Pampa (Unipampa)

**ITAQUI
2024**

Tudo quanto te vier à mão para fazer, faze-o conforme as tuas forças, porque no além, para onde tu vais, não há obra, nem projetos, nem conhecimento, nem sabedoria alguma.

Eclesiastes 9:10.

AGRADECIMENTOS

Ao Prof. Dr. Cristiano Galafassi, amigo, professor, orientador e coordenador de curso, pela amizade e apoio durante a vivência acadêmica, na Universidade Federal do Pampa.

Ao Prof. Dr. Sidnei Bohn Gass, orientador de estágio, o qual tive a oportunidade de estabelecer um bom vínculo de amizade, ainda no período do ensino remoto, devido à pandemia de covid-19. Por todas as orientações e incentivos dados no percurso de aulas e enquanto coordenador, sempre reservou um momento para tirar dúvidas.

Aos professores José Carlos Severo e Ildomar Schneider Tavares, pela amizade, companhia e prozas, nas viagens para Itaqui e retorno.

Aos professores Daiane Campara Soares e Gabriel dos Santos Kehler, pelo apoio na pesquisa acadêmica e incentivo à participação nos eventos do Salão Internacional de Ensino, Pesquisa e Extensão (SIEPE).

Ao núcleo de acessibilidade, pelo apoio dado, à Bruna Todeschini, minha eterna gratidão.

Meus familiares Roseli de Fátima Fontana, Aline Garcia Weber, Alice Garcia Weber, Pietro Weber Dedavid, Potter Weber Dedavid, Sérgio Artur Weber, Darlim Martins Fontana e João Luiz Barbosa pelo incentivo ao longo do percurso acadêmico.

Aos meus colegas Wederson Martins Varanis, Gustavo Simionato Câmpara, Iuri Vanderlei Vasconcellos, Paulo Alexandre de Borba Arioldi, Sandy Joia, Felipe Aguiar Lopes, Vinícius Ferrari Thums e Maiara Lopes, os quais de forma mais presente e fraterna me acompanharam nesse percurso acadêmico, partilhando experiências e aprendizados.

E, não menos importante, aos amigos Anderson Machado Cardoso, Rogério da Silva Viana, Andreone Cristiano Secconi Saueressig Rangel Moreira, Geraldo Generoso Ferreira, Aline Maciel dos Santos, Fernanda Borghi, Maurício Taschetto, Talita Aparecida Piber, Leandro Righi, Elias Bonoto, Sílvia Taschetto e Rafael Garcia Cardoso, pela amizade, incentivo e fraternidade durante essa trajetória de graduação.

Aos demais professores, amigos e pessoas que fizeram parte dessa trajetória, meus mais sinceros agradecimentos.

RESUMO

Duas imagens do satélite CBERS 4A, capturadas pela Câmera Multiespectral e Pancromática de Ampla Varredura (WPM), com resolução radiométrica de 8 bits, resolução espacial pancromática de 2m e multiespectral de 8m dos municípios de Edeia/GO e Indiara/GO, foram obtidas do Instituto Nacional de Pesquisas Espaciais (INPE) em abril de 2024, para detecção de áreas de descarte irregular de lixo, empregando técnicas de processamento digital no software QGIS e análises estatísticas. O objetivo principal foi identificar e caracterizar padrões de lixo no solo através de análise espectral das bandas azul, verde, vermelho e infravermelho próximo. A análise inicial revelou diferenças estatisticamente significativas entre os pixels de lixo e outros elementos da paisagem, como vegetação, estradas, solo exposto, residências e água. Os resultados do teste de variância e do Teste T indicaram que os pixels de lixo apresentam características espectrais distintas em relação à vegetação e água, mas há um risco moderado de confusão com estradas e solo exposto. Especificamente, os pixels de lixo foram mais facilmente distinguíveis nas bandas infravermelha próxima e vermelha, enquanto apresentaram maior similaridade com estradas e residências nas bandas azul e verde. Para avaliar o desempenho do modelo de detecção de lixo, foi utilizado o F β score, que considera tanto a precisão quanto o recall. Os resultados mostraram uma precisão geral baixa devido à dificuldade em distinguir pequenos depósitos de lixo e à limitação da resolução das imagens. A análise também destacou que a classificação correta de lixo na paisagem é desafiadora devido à similaridade espectral com outros objetos e à presença de ruídos atmosféricos e limitações dos sensores. A pesquisa demonstrou a viabilidade de utilizar inteligência artificial e aprendizado profundo para monitorar áreas de descarte irregular de resíduos sólidos, mas que são necessários ajustes significativos para melhorar a precisão e reduzir falsos positivos e negativos. Recomenda-se expandir o conjunto de dados e aperfeiçoar os modelos para permitir uma detecção mais precisa e confiável de lixo na paisagem, contribuindo assim para o desenvolvimento de práticas sustentáveis de gestão ambiental.

Palavras-chave: Meio Ambiente. Sustentabilidade. Pixel. Imagens de Satélite. Modelagem.

ABSTRACT

Two images from the CBERS 4A satellite, captured by the Wide Field Multispectral and Panchromatic Camera (WPM), with radiometric resolution of 8 bits, panchromatic spatial resolution of 2m, and multispectral spatial resolution of 8m of Edeia/GO and Indiará/GO municipalities, were obtained from the National Institute for Space Research (INPE) in April 2024 for detecting areas with irregular waste disposal, employing digital processing techniques in the QGIS software and statistical analyses. The main objective was to identify and characterize patterns of waste on the ground through spectral analysis of the blue, green, red, and near-infrared bands. Initial analysis revealed statistically significant differences between waste pixels and other landscape elements such as vegetation, roads, bare soil, residences, and water. Results from variance and T-test indicated that waste pixels exhibit distinct spectral characteristics compared to vegetation and water, but there is a moderate risk of confusion with roads and bare soil. Specifically, waste pixels were more distinguishable in the near-infrared and red bands, while showing greater similarity with roads and residences in the blue and green bands. To evaluate the waste detection model's performance, the $F\beta$ score, which considers both precision and recall, was used. Results showed overall low precision due to challenges in distinguishing small waste deposits and limitations in image resolution. The analysis also highlighted that accurate classification of waste in the landscape is challenging due to spectral similarity with other objects and the presence of atmospheric noise and sensor limitations. The research demonstrated the feasibility of using artificial intelligence and deep learning to monitor areas with irregular waste disposal, but significant adjustments are needed to improve accuracy and reduce false positives and negatives. Expanding the dataset and refining models are recommended to enable more precise and reliable waste detection in the landscape, thereby contributing to the development of sustainable environmental management practices.

Keywords: Environment. Sustainability. Pixel. Satellite Images. Modeling.

LISTA DE FIGURAS

Figura 1 - Mapa de localização da área de estudo.....	22
Figura 2 - Área de estudos no Município de Edeia Fonte: Elaborado Autor.....	23
Figura 3 - Área de estudos no Município de Edeia.....	24

LISTA DE TABELAS

Tabela 1 - Tabela de localização das áreas de estudo	25
Tabela 2 - Tabela da Anova com dados da análise da variância dos pixels	27
Tabela 3 - Análise da comparação entre os pixels de lixo e os demais critérios de classificação	28

LISTA DE SIGLAS E ABREVIATURAS

CNNs	Redes Neurais Convolucionais
DPI	Densidade de Pixels por Polegada
FN	False Negatives
FP	False Positives
GF-2	Gaofen-2 (satélite chinês)
IA	Inteligência Artificial
INPE	Instituto Nacional de Pesquisas Espaciais
KNN	K-Nearest Neighbors
Mask R-CNN	Mask Region-based Convolutional Neural Network
ML	Machine Learning (Aprendizado de Máquina)
n	tamanho da amostra
NDVI	Índice de Vegetação por Diferença Normalizada
OTB	Orfeo ToolBox
QGIS	Quantum Geographic Information System
R	Linguagem de Programação R
RGB	Red, Green, Blue
RNA	Rede Neural Artificial
s	Desvio padrão da amostra
SVM	Support Vector Machine
TN	True Negatives
TP	True Positives
VGG-16	Visual Geometry Group 16
X	Média amostral
YOLO	You Only Look Once
B	parâmetro de ajuste da precisão e do recall no cálculo do F-score.
μ_0	Média hipotética da população

LISTA DE APÊNDICES

Apêndice A - Quadro de pontos analisados	36
--	----

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Problema da pesquisa	14
1.2	Justificativa	14
1.3	Objetivos	15
1.4	Objetivo geral	15
1.5	Objetivos específicos	15
2	REFERENCIAL TEÓRICO	16
3	METODOLOGIA	22
4	RESULTADOS E DISCUSSÕES	27
5	CONCLUSÃO	31
	REFERÊNCIAS	33
	APÊNDICE	36

1 INTRODUÇÃO

A inteligência artificial (IA) tem recebido destaque nas pesquisas de monitoramento ambiental, oferecendo uma variedade de abordagens para lidar com desafios complexos relacionados à poluição do ar, água e solo, bem como gestão de resíduos sólidos. Com técnicas como redes neurais artificiais, algoritmos genéticos, machine learning e deep learning, a IA proporciona precisão, flexibilidade e capacidade de tomada de decisões em tempo real, permitindo a detecção precoce de fontes de poluição, otimização de processos de tratamento e identificação de áreas em risco, contribuindo assim para a promoção de práticas sustentáveis de conservação ambiental (WANI *et al.*, 2024).

A aplicação da IA tem se mostrado efetiva na análise e monitoramento ambiental com o emprego de imagens de sensoriamento remoto, conforme as pesquisas feitas por Titu *et al.* (2024), Zhou *et al.* (2023), Malik *et al.* (2022), Verma *et al.* (2022), Yang *et al.* (2022) e Gnann *et al.* (2022) para explorar diferentes abordagens para a classificação e identificação de resíduos na paisagem, a partir da análise de imagens raster para detecção de resíduos (NNAMOKO *et al.*, 2022; YANG *et al.*, 2022; MURTHY *et al.*, 2020). Esses estudos destacam a importância das imagens de satélite no processo de análise da paisagem, fornecendo os dados brutos necessários para os modelos de análise, que podem ser treinados para reconhecer e interpretar características relevantes do terreno (YANG *et al.*, 2022; MURTHY *et al.*, 2020).

Os pixels das imagens, ao passar pelas camadas do modelo, são analisados, segmentados, detectados, classificados e rotulados com base em uma variedade de parâmetros, incluindo cor, tamanho, absorção e reflectância da superfície observada. Além disso, são considerados padrões espectrais, resolução espacial, rugosidade, textura e geolocalização dos pixels para uma análise mais completa. A análise também pode incluir a avaliação temporal dos dados, permitindo o reconhecimento de mudanças e padrões ao longo do tempo. Portanto, isso possibilita a identificação de características do terreno, padrões e tendências com uma precisão estatística significativa (CLEWLEY *et al.*, 2014).

A principal vantagem do uso de métodos de aprendizado de máquina (*deep learning*), como redes neurais convolucionais (CNNs), em comparação com a análise de sensoriamento remoto convencional é a capacidade de extrair características

complexas e de alto nível das imagens, permitindo uma identificação mais precisa e eficaz de objetos de interesse, como resíduos de construção e demolição. Enquanto a análise convencional de sensoriamento remoto muitas vezes se baseia em índices ou técnicas de processamento de imagens que podem não capturar completamente as nuances dos objetos de interesse, algoritmos baseados em *deep learning* podem aprender automaticamente padrões e características intrínsecas dos dados, resultando em uma identificação mais confiável e robusta (YANG *et al.*, 2022).

1.1 Problema da pesquisa

SUN *et al.* (2023) evidenciou a dificuldade de obtenção de localizações de lixo na paisagem, de forma oportuna pelos órgãos governamentais locais e grupos ambientais, devido à necessidade de grande esforço humano e custos econômicos para coletar informações sobre esses locais. Treinar algoritmos eficientes para identificar as áreas de descarte irregular, por meio de imagens de satélite, é um dos problemas mais desafiadores e fundamentais para garantir a sustentabilidade ambiental, uma vez que o monitoramento a campo é insustentável pelo custo.

Em imagens de satélite, os focos de lixo na natureza podem ser representados por conjuntos distintos e pequenos de pixels, tornando difícil a identificação humana passando-se despercebidos, especialmente quando estão inseridos em uma cena complexa, como centros urbanos, praias, áreas sombreadas e vegetação densa. Para que o modelo possa fazer uma detecção eficiente, deve ser fornecido um conjunto de dados com uma ampla variedade de escalas e ângulos de visão do que deve ser considerado como foco de lixo na paisagem, uma tarefa especialmente difícil quando se trata de objetos pequenos.

A pesquisa se mobiliza em responder se o sistema desenvolvido possui aptidão para detecção de áreas de descarte irregular de resíduos sólidos a partir de imagens de satélite, visando seu potencial uso por entidades governamentais e partes interessadas na mitigação dos impactos ambientais causados pelo lixo na paisagem.

1.2 Justificativa

Projetos desenvolvidos com a finalidade de classificação de lixo, baseado em inteligência artificial, contribuem para melhorar a eficiência do monitoramento

ambiental, gestão de resíduos sólidos e geração de novas tecnologias e empregabilidade (YANG *et al.*, 2022). Esse projeto pretende que, ao analisar uma imagem de satélite, detectada a presença de lixo, o algoritmo possa retornar à localização espacial e a caracterização do objeto detectado com uma boa confiabilidade.

Essa abordagem está alinhada aos pilares do desenvolvimento sustentável das Nações Unidas, em particular aos objetivos de número 11, que visa reduzir o impacto ambiental negativo da gestão de resíduos municipais, e ao objetivo 12, que busca assegurar padrões de produção e consumo sustentáveis. Especificamente, contribui para a adoção de padrões mais sustentáveis de produção e consumo por meio do desenvolvimento de ferramentas para monitorar os impactos do desenvolvimento local (SCOTT *et al.*, 2017).

1.3 Objetivos

1.4 Objetivo geral

Avaliar um conjunto de pixels de imagens de satélite para preparação de dados visando identificar áreas de descarte de resíduos sólidos em modelos eficientes de inteligência artificial baseados em aprendizado profundo.

1.5 Objetivos específicos

1. Avaliar o comportamento dos pixels de lixo por meio do teste de comparação de médias para cada banda.
2. Comparar os pixels de lixo com os elementos lixo, vegetação, estradas, solo exposto, residência e água na paisagem por meio do Teste T.
3. Analisar os resultados obtidos e identificar possíveis melhorias nos modelos e nas técnicas empregadas, visando aprimorar a detecção e classificação de áreas de descarte irregular.

2 REFERENCIAL TEÓRICO

Estima-se que cada pessoa gere cerca de 2,22 kg de resíduos por dia, o que representa um grave e crescente problema ambiental, afetando o equilíbrio ambiental devido aos impactos causados pela deposição inadequada na natureza (MALIK *et al.*, 2022). Acredita-se que esse número possa chegar a 2,2 milhões de toneladas de lixo descartado até 2025 (SAMI *et al.*, 2020) e 3 bilhões de toneladas de resíduos ao ano até 2050 (MAJCHROWSKA *et al.*, 2022).

A proporção de lixo reciclável é de 13,5%, enquanto 33% são descartados na natureza, de forma inadequada (MAJCHROWSKA *et al.*, 2022). Esse descarte irresponsável causa poluição visual e impacta negativamente a biodiversidade (TITU *et al.*, 2024). Exemplos clássicos desses resíduos incluem latas, garrafas, copos descartáveis, pacotes de batatas fritas, alimentos, cadeiras, sofás, computadores, pneus, geladeiras (MALIK *et al.*, 2022), resíduos de construção e demolição (NA *et al.*, 2022), fios emaranhados e lixo de rua (TITU *et al.*, 2024).

A inteligência artificial, por meio do aprendizado de máquina, surge como uma aliada na mitigação desse problema ambiental (SAMI *et al.*, 2020). Essa tecnologia tem sido empregada na separação e identificação dos tipos de resíduos produzidos, utilizando métodos avançados de aprendizado profundo para auxiliar os profissionais técnicos e o poder público na adoção de medidas proativas (TITU *et al.*, 2024; MAJCHROWSKA *et al.*, 2022).

A identificação de focos de lixo é essencial para uma gestão eficiente e garantir a sustentabilidade ambiental (YANG *et al.*, 2022), porém, apresenta desafios significativos para os seres humanos, devido à heterogeneidade da paisagem e às limitações no monitoramento efetivo. Portanto, recorre-se ao monitoramento ambiental por meio de ferramentas computacionais.

Algumas estratégias para realizar as análises podem empregar arquiteturas de redes neurais convolucionais (CNNs), como Random Forest, Rede Neural Artificial (RNA), VGG-16, Árvore de Decisão, ResNet, SVN, KNN, AlexNet, YOLO e Mask R-CNN, a partir de técnicas de machine learning, como o uso de redes neurais convolucionais (CNNs), que integram sensores e possibilitam o reconhecimento automático e a geolocalização (NNAMOKO *et al.*, 2022). Essas técnicas utilizam

benchmarks¹ e rótulos de classificação, com base na proposta metodológica desenvolvida em um framework², podendo contar com o apoio de bibliotecas, como TensorFlow e PyTorch (YANG *et al.*, 2022).

As Redes Neurais Profundas, especificamente as Redes Neurais Convolucionais (CNNs), são projetadas para detectar padrões visuais em imagens. Elas utilizam camadas de convolução, onde cada neurônio se conecta a um conjunto limitado de neurônios da camada anterior por meio de filtros ou kernels. Esses filtros são matrizes que detectam características visuais específicas, como bordas, texturas e formas (ERSAVAS *et al.*, 2024).

As técnicas de Aprendizagem de máquina são formas eficazes para detecção e classificação de resíduos sólidos nas imagens, gerando máscaras para identificar os objetos identificados com alta precisão e rapidez de análise (MALIK *et al.*, 2022). Para treinar o modelo de CNN, é essencial contar com um conjunto representativo de imagens dos resíduos em questão (SAMI *et al.*, 2020). As imagens passam pelas camadas convolucionais e de pooling, seguidas por camadas densas para classificação (VERMA *et al.*, 2022).

Após a identificação dos resíduos em cada imagem, o modelo pode realizar uma etapa adicional de classificação ou análise com base em características específicas ou propriedades dos materiais identificados, levando em consideração o número de parâmetros de entrada e as camadas ocultas (MALIK *et al.*, 2022; NNAMOKO *et al.*, 2022; SAMI *et al.*, 2020).

A aplicação da detecção de objetos abrange áreas amplas, como imagens médicas, segurança, vigilância por vídeo, veículos autônomos, visão de robô e reconhecimento facial (MURTHY *et al.*, 2020). Para qualquer aplicação, os modelos

¹ Benchmarks: conjunto de dados, como imagens, por exemplo, padronizados com métricas específicas e servem para avaliação e comparação de modelos em abordagens específicas

² Framework: plataforma com funcionalidades e ferramentas para o desenvolvimento de aplicativos e sistemas, podendo comportar uma biblioteca de algoritmos, sendo os mais comuns TensorFlow, PyTorch e scikit-learn, para facilitar a escrita de códigos de treinamento para aprendizado de máquinas

avaliam sua precisão por meio de métricas como precisão, Recall³ e F1-score⁴, que levam em conta os verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN). Verdadeiros positivos (TP) são instâncias em que o modelo previu corretamente a classe positiva, enquanto verdadeiros negativos (TN) são instâncias em que o modelo previu corretamente a classe negativa. Falsos positivos (FP) representam instâncias em que o modelo prevê incorretamente a classe positiva quando a classe real era negativa, e falsos negativos (FN) referem-se a instâncias em que o modelo prevê incorretamente a classe negativa, quando a classe real era positiva (MAJCHROWSKA *et al.*, 2022; QIN *et al.*, 2022).

Essas análises são sensíveis ao número e à resolução do benchmark analisado (QIN *et al.*, 2022). Tanto o número quanto a resolução do conjunto de imagens influenciam no desenvolvimento do modelo, tamanho, precisão preditiva e perda de entropia cruzada. Uma resolução de imagem menor implica um modelo mais leve, com menos parâmetros e, portanto, menor complexidade computacional. No entanto, mesmo com uma resolução reduzida, um modelo bem projetado e treinado pode ser capaz de extrair características relevantes o suficiente para classificar com precisão os objetos de interesse (NNAMOKO *et al.*, 2022; MURTHY *et al.*, 2020).

Para evitar ambiguidades, é essencial compreender a diversidade do benchmark utilizado. Isso requer dados bem anotados para comparação, pois os conjuntos de dados disponíveis podem não cobrir todos os tipos de resíduos representados nas imagens ou fornecer um número suficiente de imagens, especialmente quando os materiais podem estar deformados ou confusos devido ao ambiente em relação aos padrões do benchmark.

Vários estudos abordam o desenvolvimento de modelos de classificação de resíduos, utilizando diferentes algoritmos e técnicas para melhorar a precisão e a eficácia. Sami *et al.* (2020) propuseram um modelo baseado em propriedades

³Recal: proporção de instâncias positivas corretamente identificadas pelo modelo em relação ao total de instâncias positivas presentes no conjunto de dados, cujo valor oscila entre 0, sem identificação e 1, positivos identificados.

Recall = Verdadeiros Positivos / (Falsos Negativos + Verdadeiros Positivos)

⁴F1-score: métrica de cálculo de precisão da média harmônica entre precisão e recall, cujo valor oscila entre 0, pior modelo e 1, melhor desempenho.

$F1 = 2 \times \text{Precisão} \times \text{Recal} / (\text{Precisão} + \text{Recal})$

materiais dos resíduos, treinando algoritmos como SVM, Árvore de Decisão, Floresta Aleatória e CNN, com destaque para a CNN devido ao seu melhor desempenho. Os pontos importantes deste estudo envolvem a atenção com o pré-processamento dos dados para garantir a uniformidade e exploraram diferentes técnicas de análise de imagem, como escala de cinza e variações RGB, para melhorar a precisão da classificação.

Majchrowska *et al.* (2022) desenvolveram frameworks para classificação de lixo, utilizando aprendizado profundo e técnicas de geolocalização, respectivamente. Yang (2022), Alsubaei *et al.* (2022), Alonso *et al.* (2021) e Kang *et al.* (2017) descrevem o uso de redes neurais convolucionais para classificação e reconhecimento de lixo, obtendo altas taxas de reconhecimento. Nnamoko *et al.* (2022) exploraram o tamanho do modelo de CNN para diferentes aplicativos, destacando a importância de encontrar um equilíbrio entre tamanho e precisão do modelo. Titu *et al.* (2024) e Hossain *et al.* (2021) empregaram o Google Street View e redes neurais de aprendizado profundo, framework CVAT e o modelo YOLOv5, para identificar e classificar poluição visual, utilizando uma variedade de modelos neurais e métricas de avaliação.

Os estudos de Na *et al.* (2022) e Dyba (2024) exploram técnicas avançadas de segmentação e classificação de resíduos em contextos específicos. Dyba (2024) comparou a eficácia de diferentes algoritmos em mapeamento geomorfológico, destacando a importância da semelhança entre as características da área e o benchmark de treinamento para a confiabilidade dos resultados. Na *et al.* (2022) desenvolveu um sistema automatizado para reciclagem de resíduos de construção e demolição, utilizando uma arquitetura de rede neural convolucional (CNN) com o algoritmo YOLACT. Embora tenha obtido resultados satisfatórios, observou-se uma queda de desempenho em conjuntos de dados com alterações na saturação, indicando a sensibilidade do modelo a certos tipos de variação.

Além das técnicas de classificação de lixo por sensores em plataformas, há também a análise ambiental, empregando técnicas de sensoriamento remoto, drones, câmeras embarcadas e imagens do Google Street View são amplamente exploradas em estudos como os de Titu *et al.* (2024), Gnann *et al.* (2022) e Malik *et al.* (2022), que buscam diferentes abordagens para lidar com a classificação e identificação de resíduos na paisagem. Os estudos propostos por esses autores ressaltam a necessidade de modelos precisos e eficazes para enfrentar os desafios associados

ao gerenciamento de resíduos sólidos, para evitar os problemas de *overfitting*, quando o modelo se adapta demais aos dados de treinamento e não generaliza bem para novos dados.

Verma *et al.* (2022) utilizaram imagens, com as mesmas dimensões, de drones para identificação de lixo na paisagem, avaliando parâmetros de confiabilidade por meio de precisão, recall, pontuação F1 e acurácia, com precisão de 94%. Yang *et al.* (2022) estudou a detecção de resíduos de construção civil e demolição em imagem de satélite utilizando a base em aprendizado profundo e os Dados Gaofen-2 (GF-2), com precisão local superior a 82%.

SUN *et al.* (2023) propôs o uso de redes neurais convolucionais profundas (CNNs) em imagens de satélite de alta resolução como uma abordagem eficaz, eficiente e de baixo custo para detectar lixões ilegais. Essa abordagem foi aplicada em 28 cidades ao redor do mundo, resultando na detecção de quase 1000 lixões que surgiram por volta de 2021, mostrando que a aplicação da metodologia reduziu o tempo de investigação em mais de 96,8% em comparação com o método manual.

Zhou *et al.* (2023) empregou imagens de satélite do Sentinel-2 para identificar as funções dos materiais plásticos em superfícies terrestres, treinando o modelo a partir de imagens de plásticos classificados com base nas informações RGB das imagens, observando que o uso de algoritmos de aprendizado profundo treinados em imagens Sentinel-2 tem potencial para identificar a função de materiais plásticos em superfícies terrestres.

No caso de plásticos, a IA utiliza a tecnologia de imagem hiperespectral para capturar o espectro de refletância, especialmente aqueles que são visíveis e refletem luz na faixa do infravermelho próximo, sendo possível detectar e distinguir tipos de plásticos e microplásticos presentes no meio ambiente com base em suas características espectrais, com ênfase nas especificidades dos plásticos pretos, que têm propriedades de absorção específicas, devido às suas propriedades de absorção do carbono preto, o método de classificação atual é menos eficiente na detecção de plástico preto, o que pode vir a ser solucionado com o emprego do infravermelho de comprimento de onda médio (TAMIN *et al.*, 2022).

Para facilitar a interpretação e previsão de eventos ambientais, ainda se podem citar o uso de ferramentas como o Google Earth Engine e softwares de Sistemas de Informações Geográficas, como ORFEO (OTB), fornecem recursos robustos para análise de imagens de satélite e geoprocessamento (TEDORESCU; VOICU, 2021;

CLEWLEY *et al.*, 2014). Além disso, essas plataformas permitem a inserção de códigos de programação em linguagens como R, Java e Python, podendo haver a interoperabilidade entre as linguagens, facilitando a personalização e integração de ferramentas de análise (CLEWLEY *et al.*, 2014).

Baseado nos resultados das pesquisas, o sucesso de um modelo eficaz está diretamente ligado ao treinamento adequado. Utilizando um framework de aprendizado fracamente supervisionado baseado em redes neurais convolucionais (CNNs), é possível extrair informações da paisagem sem a necessidade de rotulagem explícita de cada objeto sensível na imagem de sensoriamento remoto. Esse método permite que o modelo aprenda padrões e características relevantes durante o treinamento, possibilitando a identificação automática de objetos sensíveis em novas imagens, sem supervisão explícita em cada exemplo (DYBA, 2024; MURTHY *et al.*, 2020).

Sun *et al.* (2023) sugerem que o monitoramento de lixões deve considerar as características únicas dos lixões, como suas cores semelhantes ao ambiente circundante e suas características morfológicas que podem ser sutis, fato que justifica o treinamento se dar com um benchmark variado. Pode-se fazer a adoção de mecanismos de atenção para enfatizar as características críticas dos lixões e melhorar o desempenho do modelo na detecção desses objetos, estratégias de aumento de dados e balanceamento de categorias, e o uso de técnicas de validação cruzada.

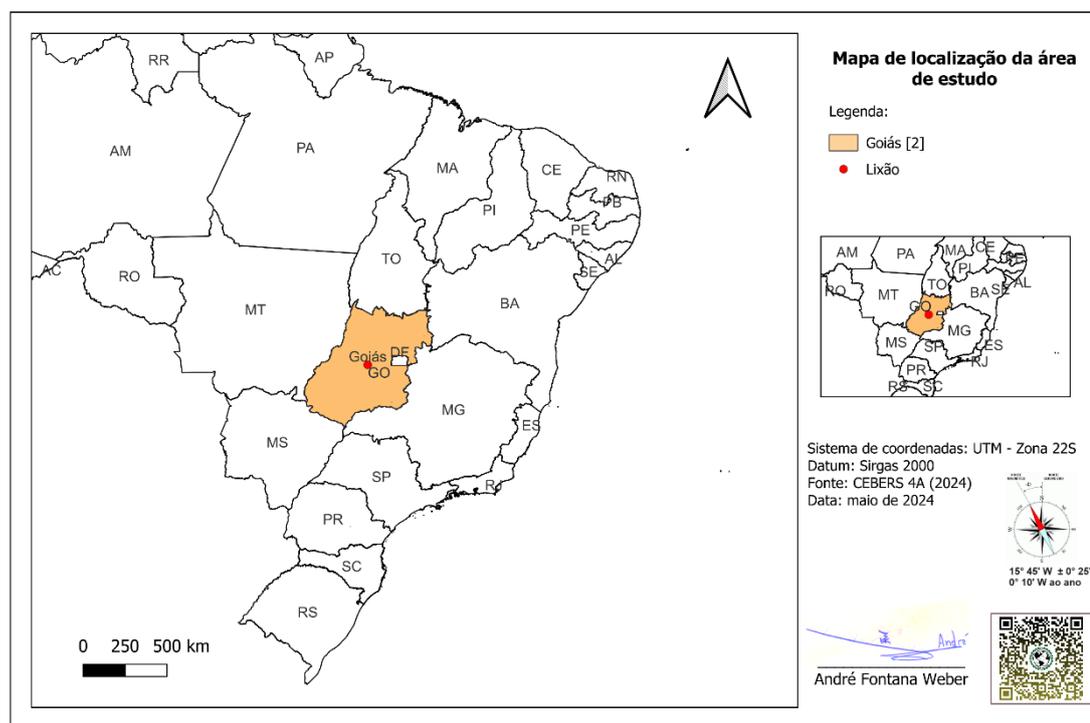
O monitoramento eficaz de lixo, em suas diferentes formas, na paisagem é fundamental para a preservação do meio ambiente e a promoção de práticas sustentáveis de gestão de resíduos. Diante dos avanços tecnológicos e das capacidades cada vez maiores da inteligência artificial, solidifica-se a possibilidade de se aplicar redes neurais convolucionais (CNN) como uma solução promissora para o monitoramento contínuo e preciso de lixões. Ao combinar dados de imagens de satélite com algoritmos de aprendizado profundo, pode-se desenvolver modelos robustos capazes de identificar e mapear lixões de forma rápida e eficiente em escala global. Essa abordagem contribui para políticas de gestão de resíduos e para a proteção do meio ambiente e a promoção de um futuro mais sustentável (Dyba, 2024; Sun *et al.*, 2023; Zhou *et al.*, 2023; Gnann *et al.*, 2022; Yang *et al.*, 2022).

3 METODOLOGIA

As imagens são provenientes do satélite CBERS 4A, Câmera Multiespectral e Pancromática de Ampla Varredura (WPM), com resolução radiométrica de 8 bits, resolução espacial pancromática de 2m e multiespectral de 8m, largura da faixa de 92km, na órbita do satélite e provêm do repositório de dados do Instituto Nacional de Pesquisas Espaciais (INPE), no mês de abril de 2024.

Empregou-se o processo de fusão pancromática e composição colorida no software livre QGIS, reprojatadas, conforme código EPSG. As bandas empregadas foram: Pancromática: 0,45 - 0,90 μm ; B1 (azul): 0,45 - 0,52 μm ; B2 (verde): 0,52 - 0,59 μm ; B3 (vermelho): 0,63 - 0,69 μm e B4 (infravermelho próximo): 0,77 - 0,89 μm , posteriormente ajustado o brilho, contraste e saturação.

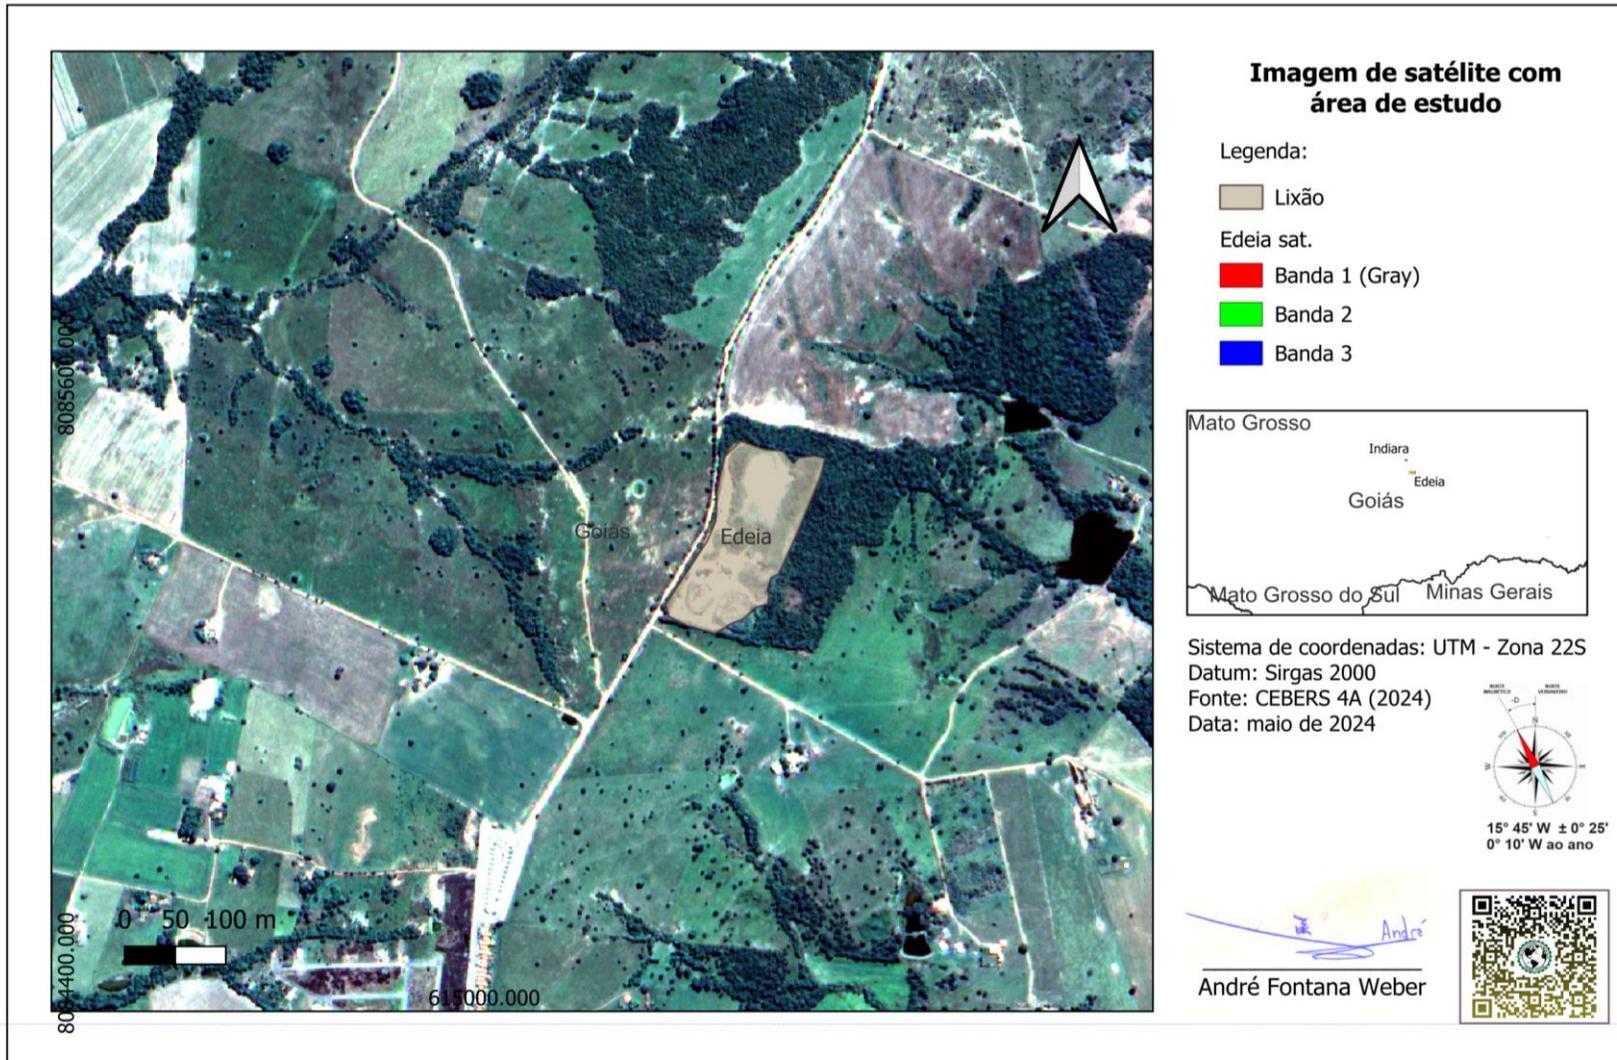
Figura 1 - Mapa de localização da área de estudo



Fonte: Elaborado Autor

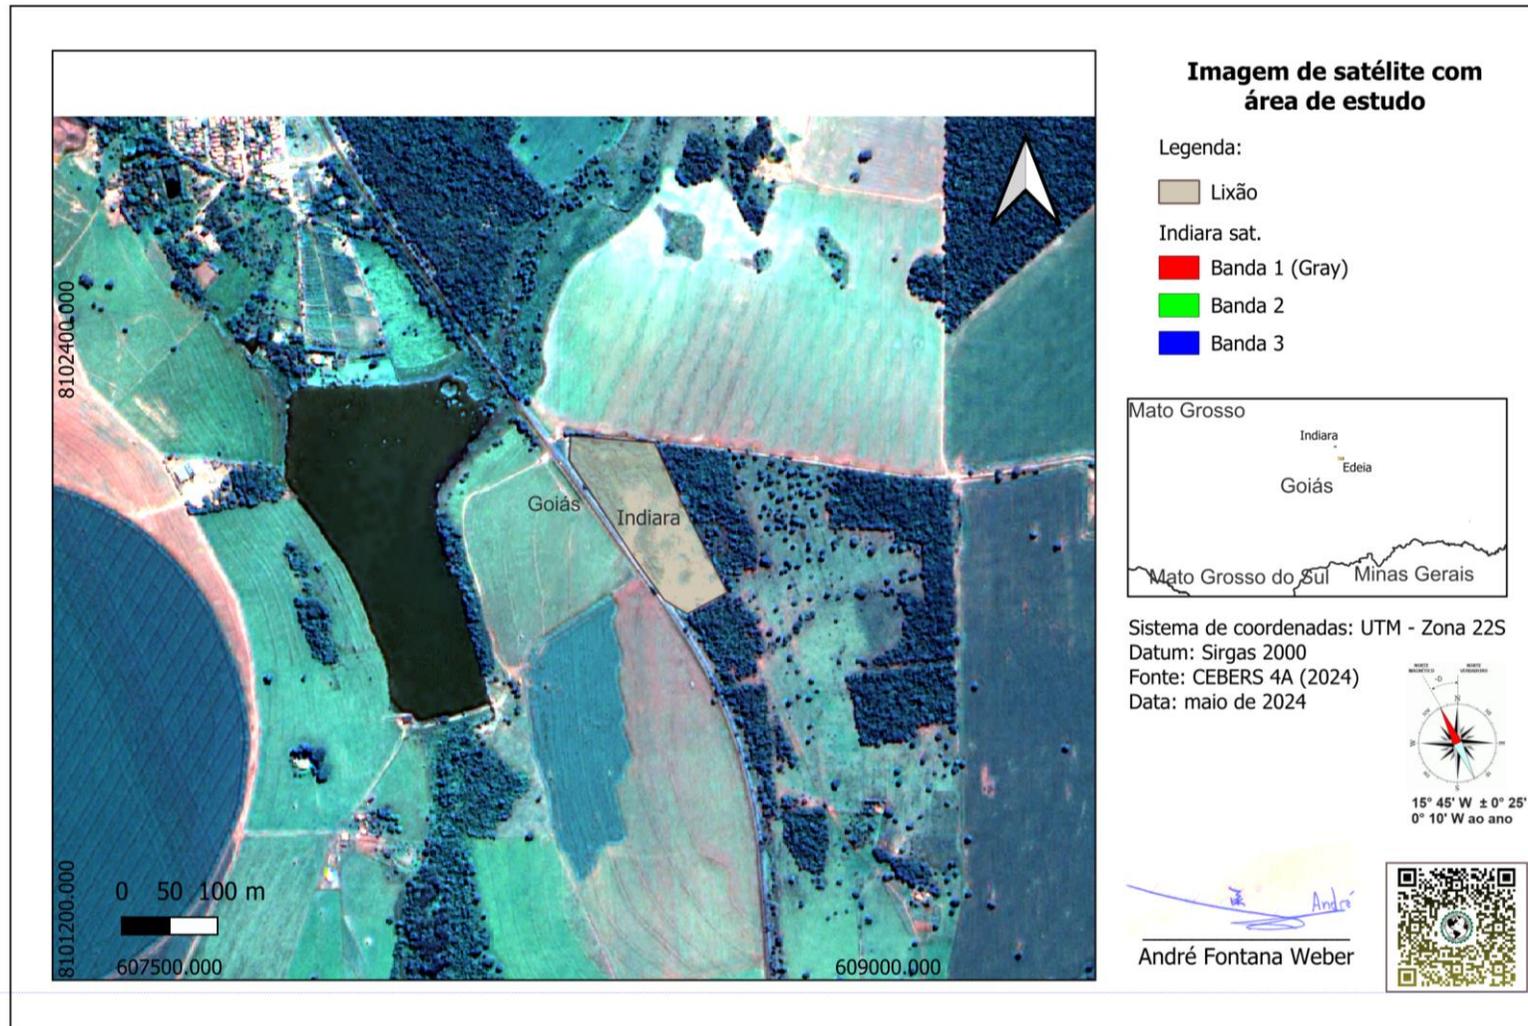
A Figura 1 traz o município de Edeia e a Figura 2 o município de Indiara. As duas áreas foram escolhidas para compor o conjunto de clusters, pertencem às regiões mencionadas, conforme mostrado na Tabela 1.

Figura 2 - Área de estudos no Município de Edeia



Fonte: Elaborado Autor

Figura 3 - Área de estudos no Município de Edeia



Fonte: Elaborado Autor

Tabela 1 - Tabela de localização das áreas de estudo

EPSG	Localização	Coordenada	Coordenada	Data	Figura
31983	Edeia/GO	17° 18' 52.4" S	49° 54' 46.2" W	29/04/2024	1
31983	Indiara/GO	17° 09' 50.3" S	49° 58' 48.1" W	29/04/2024	2

Fonte: Autor.

Para testar modelos de análise por meio de CNN, os recortes de imagens gerados deram ênfase às áreas próximas àquelas em que há o depósito de lixo na intenção de facilitar o treinamento e reconhecimento dessas áreas, conforme sugestão de Almeida e Tavares Junior (2011).

A classificação da imagem teve como objetivo extrair as seguintes características referentes à disposição de lixo no solo. Utilizou-se de uma composição no colorido natural, nas suas 4 bandas, nas cores azul, verde, vermelho e infravermelho, respectivamente, a qual possibilitou a identificação dos padrões de uso e ocupação do solo.

A análise do comportamento da banda infravermelha é útil para diferenciar materiais e vegetação, o que poderia melhorar a detecção de resíduos no solo. A composição em cores naturais facilita a interpretação visual dos padrões, o que é benéfico para a identificação de lixo.

A mineração de pixel das imagens visa descobrir padrões e relacionamentos em dados nas duas imagens para avaliação de características dos números digitais. No contexto da detecção de lixo, esse princípio é aplicado para identificar resíduos que podem não ser imediatamente visíveis ou diferenciáveis em imagens de satélite devido à complexidade e variabilidade do cenário.

Pode-se, assim, estudar a possibilidade de empregar as imagens em um método de segmentação treinável para extrair características significativas das áreas com lixo depositado. Esse processo visa identificar padrões do lixo nas imagens de satélite, nos quais o modelo se concentra e verificará a precisão da detecção.

A primeira análise de pixel no QGIS® versão 3.34, baseou-se na ferramenta para identificar feições nas áreas em que o lixo está evidente. O uso do QGIS® para análise preliminar de pixels é uma boa prática para obter uma compreensão inicial das características visuais do lixo. Tem a finalidade de ajudar a configurar parâmetros adequados para a segmentação e o treinamento do modelo.

Para a avaliação de variação do comportamento dos pixels de lixo foi aplicado o teste de comparação de médias no Excel (ANOVA) para cada banda. Para comparação entre os pixels de lixo com os elementos lixo, vegetação, estradas, solo exposto, residência e água na paisagem empregou-se o Teste T (equação 1). Os dados utilizados estão no Apêndice A.

$$t = \frac{(X - \mu)}{(s / \sqrt{n})} \quad [1]$$

Em que:

x média amostral

μ_0 média hipotética da população

s desvio padrão da amostra

n tamanho da amostra

Para avaliar o desempenho do modelo, além da acurácia, foi utilizada a métrica $F\beta$ score (equação 2). A métrica, que leva em conta a média harmônica dos valores de precisão e recall, é útil para avaliar o desempenho em conjuntos de dados desbalanceados. O $F\beta$ score é calculado conforme a Equação 2, onde o parâmetro β determina o peso do recall na pontuação combinada, permitindo ajustar a importância de cada medida:

$$F\beta = (1 + \beta^2) \cdot \frac{\text{precisão} \cdot \text{recall}}{(\beta^2 \cdot \text{precisão}) + \text{recall}} \quad [2]$$

Sendo:

Precisão a proporção de verdadeiros positivos entre os exemplos classificados como positivos.

Recall é a proporção de verdadeiros positivos entre todos os exemplos que realmente são positivos.

β o parâmetro que permite ajustar a importância relativa da precisão e do recall no cálculo do F-score.

A proposta pretende avaliar se o sistema possui aptidão para detectar lixo na paisagem, apresentando parâmetros confiáveis para ser utilizado por entidades governamentais e partes interessadas na localização de lixo a partir de imagens de satélite.

4 RESULTADOS E DISCUSSÕES

Foram avaliados vinte diferentes pontos aleatórios nas imagens de satélite e caracterizadas as tonalidades dos pixels nas suas quatro bandas, evidenciando uma variação em todas as bandas para as variáveis lixo, em relação aos demais elementos presentes na paisagem.

A Tabela 2 apresenta uma alta variância entre as bandas observadas (Apêndice C) para os pontos amostrados no software QGIS para os pixels de lixo evidenciados.

Tabela 2 - Tabela da Anova com dados da análise da variância dos pixels observados

<i>Fonte da variação</i>	<i>SQ</i>	<i>GL</i>	<i>MQ</i>	<i>F</i>	<i>valor-P</i>	<i>F crítico</i>
Entre grupos	298797,2	3	99599,07	59,11579	$7,97 \cdot 10^{-20}$	2,724944
Dentro dos grupos	128045,8	76	1684,813			
Total	426843	79				

Variâncias: Vermelho: 1524,05; Azul: 943,8184211; Verde: 1985,713158; Infravermelho: 2285,671053
 Coeficiente de variação: vermelho: 10,43%; azul: 9,41%; Verde: 10,81%; Infravermelho: 9,11%.
 Fonte: Autor.

A estatística F de 59,1159 mostra a razão entre a variabilidade dos grupos (classes) e a variabilidade dentro dos grupos. Considerando um valor elevado de F calculado, indica que a variabilidade entre as médias das classes é alta em relação à variabilidade dentro das classes, portanto há diferenças estatisticamente significativas entre as médias dos valores de pixels, para as quatro bandas analisadas.

Para analisar o comportamento do lixo na paisagem foi realizado o Teste T, comparado com os demais elementos da paisagem avaliados. A configuração do teste considerou verificar se há qualquer diferença significativa as bandas para os resíduos e os demais parâmetros a 5% de significância com um número diferente de amostras (20 para lixo e 10 para as outras categorias).

Os resultados do teste T indicam a significância das diferenças entre as médias dos valores de pixels para as quatro bandas analisadas (vermelho, verde, azul e UV infravermelho) entre lixo e os outros elementos da paisagem conforme a Tabela 3.

Tabela 3 - Análise da comparação entre os pixels de lixo e os demais critérios de classificação

Critério comparativo	Red	Green	Blue	UV
Vegetação	$1,45199.10^{-6}$	$3,21.10^{-6}$	$5,08.10^{-7}$	0,008512
Estrada	0,317346223	0,986006	0,482449	$8,82.10^{-05}$
Solo exposto	$6,34016.10^{-5}$	$8,95.10^{-6}$	0,00568	0,056766
Residência	0,995270154	0,715934	0,591007	0,914648
Água	2,22956E-09	$1,55.10^{-10}$	$3,61.10^{-9}$	$4,78.10^{-16}$

Fonte: Autor.

Na interpretação do Teste T, com base nos dados da Tabela, para a vegetação e água há diferenças significativas em todas as bandas, indicando que os pixels de lixo têm características distintas e não são facilmente confundidos com vegetação ou água. As estradas e solos expostos apresentaram diferenças significativas em algumas bandas, sugerindo que há um risco moderado de confusão com lixo. No caso de residência o teste mostrou que não há nenhuma diferença significativa em todas as bandas, sugerindo um alto risco de confusão com lixo.

Os resultados do teste T mostram que os pixels analisados para lixo têm características distintas em comparação com vegetação, solo exposto e água em todas as bandas, o que significa que essas classes são menos prováveis de serem confundidas com lixo. No entanto, os valores de p maiores para estrada e residências indicam que os pixels de lixo podem ser confundidos com esses elementos em algumas bandas, especialmente em vermelho, verde e azul. A banda do infravermelho próximo parece ser um pouco mais distintiva para separar lixo de estradas, mas não de vegetação ou solo exposto.

Com base nos resultados do teste, sugere-se que a modelagem de uma rede neural deve ser ajustada para levar em conta essas diferenças e melhorar a precisão na detecção de lixo. Em particular, deve-se focar na distinção de lixo versus estradas e residências, que parecem ser as classes mais propensas a confusão.

Trabalho similar foi realizado por De Moura Septímio (2023) com imagens de sensoriamento remoto capturadas pelo sensor WPM do satélite CBERS-4A, cobrindo partes dos municípios de Goiânia. Os testes aplicados foram o método de permutação da característica com três classificadores: k-Nearest Neighbors (k-NN), Support Vector Machines (SVM) e Multi-layer Perceptron (MLP). Dividindo o conjunto de dados foi dividido em treino e teste na proporção de 50%, com estratificação e embaralhamento. Três modelos foram criados com os classificadores mencionados,

otimizando hiperparâmetros para melhorar o desempenho, avaliados pelo F1 (F1 score), também evidenciando dificuldades, por meio de métodos numéricos, a partir da análise de textura, utilizando a matriz de coocorrência de níveis de cinza (GLCM), em detectar depósitos de lixo menores que a dimensão da janela de análise (22m x 22m), resultando em falsos negativos.

Tal como a visão humana depende de clareza e foco para discernir detalhes, as CNNs precisam de dados visuais claros e consistentes para performar bem (MUSTAPHA et al., 2024), o que não foi constatado no padrão espectral do conjunto de pontos. A similaridade entre o lixo e outros elementos paisagísticos se deu por detalhes como cores, texturas ou formas específicas que são comuns em diversos resíduos, resultando em respostas espectrais similares.

A baixa resolução da imagem, associada a suavização do modelo de heurística utilizada, indica a dificuldade em reconhecer os pixels, de tal forma a coletar e processar todas as evidências para tomar uma decisão tornando o processo impraticável. O algoritmo apresenta dificuldade em identificar o lixo, focando em características que são mais frequentemente associadas a outros objetos, ao tentar considerar todos os possíveis aspectos das imagens analisadas.

A estatística contribui com a interpretação sobre o comportamento do conjunto de dados, uma vez que as imagens de satélite frequentemente contêm ruídos devido à atmosfera, condições climáticas, e limitações dos sensores, os quais incidem na redução da qualidade espectral refletindo no número digital dos pixels. Esses ruídos dificultam a detecção precisa de objetos específicos. Quando a resolução é baixa, pode ocorrer a suavização dos detalhes, tornando mais difícil distinguir entre diferentes objetos, identificando de forma errada o lixo com outros materiais como construções. Imagens de alta resolução também podem conter ruídos e detalhes excessivos que podem confundir a rede (LOBATO et al., 2024).

As imagens utilizadas não apresentaram uma amostra diversificada de cada classe de pixel de lixo para identificar. Ocorrem variações nas condições atmosféricas, na iluminação, na escala e na composição das áreas de interesse. Portanto não foi possível encontrar um equilíbrio entre a precisão desejada dos dados para detecção dos pixels representativos de lixo, mediante a escolha de técnicas de otimização e, às vezes, adaptação do sistema para operar com múltiplos níveis de CNN para as imagens escolhidas.

Quanto à modelagem, as análises espectrais do número digital corroboraram para um score desfavorável na avaliação de desempenho do modelo, devido ao fato do conjunto de dados de pixels ser desbalanceado. Evidencia-se uma baixa precisão (falsos positivos) versus ao recall (falsos negativos), para identificação assertiva de classificação de lixo na paisagem. De forma objetiva, a acurácia do modelo não chegou a 20%.

Assim como o trabalho de De Moura Septímio (2023), este trabalho também sugere uma maior quantidade e variedade de amostras para verificar a acurácia e melhorar a robustez do método. Portanto, a implementação bem-sucedida da proposta não apenas depende da acurácia dos modelos de visão, mas também da capacidade de integrá-los eficientemente dentro das limitações práticas de hardware, garantindo que a solução seja viável tanto tecnicamente quanto economicamente para a aplicação real na detecção e monitoramento de lixo na paisagem.

Os resultados e as discussões baseiam-se na análise espectral de imagens de satélite para identificação de áreas de descarte de resíduos sólidos, destacando a variação nas características espectrais dos pixels de lixo em comparação com outros elementos da paisagem. Utilizando dados do satélite CBERS 4A, foram realizadas análises estatísticas como ANOVA e Teste T para avaliar diferenças significativas nas bandas vermelha, verde, azul e infravermelho próximo entre os pixels de lixo e classes como vegetação, estradas, solo exposto, residência e água. Os resultados mostram que, enquanto os pixels de lixo apresentam características distintas em relação a vegetação e água, há um risco moderado de confusão com estradas e residências, especialmente em determinadas bandas espectrais.

A pesquisa destaca a necessidade de ajustes nos modelos de rede neural para melhorar a precisão na detecção de lixo, enfatizando a importância de uma maior diversidade e quantidade de amostras para aumentar a robustez do método.

5 CONCLUSÃO

Ao avaliar um conjunto de pixels de imagens de satélite, para a preparação de dados, visando identificar áreas de descarte de resíduos sólidos, em modelos eficientes de inteligência artificial baseados em aprendizado profundo, constatou-se que a resolução espacial pancromática de 2 metros e a resolução multiespectral de 8 metros do CBERS4A são insuficientes em termos de tamanho de pixel para a detecção precisa de lixo. A resolução radiométrica de 8 bits, resolução espacial pancromática de 2m e multiespectral de 8m ocasionou a suavização de detalhes, aumentando a confusão entre diferentes objetos. Para melhorar a precisão da detecção, sugere-se o uso de satélites com maior resolução espacial ou imageamento por drones, que podem fornecer imagens com maior nível de detalhe e reduzir as ambiguidades na classificação de resíduos na paisagem.

A avaliação do comportamento dos pixels de lixo por meio do teste de comparação de médias para cada banda revelou variações significativas entre as classes. Logo, há uma variabilidade entre as médias das classes é alta em relação à variabilidade dentro das classes, mostrando diferenças estatisticamente significativas entre as médias dos valores de pixels para as quatro bandas analisadas. Isso sugere que os pixels de lixo possuem características distintas que podem ser utilizadas para melhorar a identificação de áreas de descarte de resíduos sólidos em modelos de inteligência artificial baseados em aprendizado profundo.

Os resultados do Teste T indicaram diferenças estatisticamente significativas nas bandas vermelha, verde, azul e infravermelho próximo para vegetação e água em comparação com lixo. Isso sugere que os pixels de lixo têm características distintas e não são facilmente confundidos com essas classes. Contudo, para estradas e solos expostos, houve diferenças significativas em algumas bandas, indicando um risco moderado de confusão com lixo. E, no caso de residências, não foram encontradas diferenças significativas em todas as bandas, sugerindo um alto risco de confusão com lixo.

Com base nos resultados obtidos e na análise das técnicas empregadas, conclui-se que a modelagem de redes neurais para a detecção de áreas de descarte irregular de resíduos sólidos precisa de ajustes significativos para melhorar a precisão e a classificação correta. Os dados evidenciaram dificuldades na distinção entre lixo e outras classes como estradas e residências, às quais apresentaram maior

propensão a confusão. A pesquisa demonstrou que, devido à baixa resolução espacial das imagens pancromáticas de 2 metros e multiespectrais de 8 metros, houve uma suavização de detalhes que aumentou a confusão entre diferentes objetos na paisagem, resultando em um desempenho insatisfatório do modelo, com uma acurácia inferior a 20%.

O trabalho demonstrou que é viável utilizar inteligência artificial e aprendizado profundo para detectar áreas de descarte irregular de resíduos sólidos em imagens de satélite. Porém, com os critérios empregados neste estudo, os modelos não mostraram desempenho satisfatório na classificação das áreas de lixo em relação a outros elementos da paisagem, evidenciando a necessidade de ajustes para aumentar a precisão em áreas menores, de modo a contribuir significativamente para o monitoramento ambiental e a gestão de resíduos sólidos, alinhando-se aos objetivos de desenvolvimento sustentável.

Sugere-se que a ampliação do conjunto de dados, incluindo uma maior variedade de amostras e testes com diferentes escalas e ângulos de visão para aprimorar a detecção de resíduos, bem como o emprego de outros satélites com maior resolução espacial WORLDVIEW-2 (50 cm), QUICKBIRD (60 cm), GEOEYE-1 (41 cm) e IKONOS-2 (1 m), com enfoque na melhoria da precisão e na minimização de falsos positivos e negativos. Outras possibilidades incluem sensores projetados para detectar e medir concentrações de gases na atmosfera, observadas as variações sazonais e climáticas, com ênfase maior na banda do infravermelho, para detecção da assinatura espectral desses gases.

REFERÊNCIAS

- ALONSO, Sergio Luis Nañez Alonso; FORRADELLAS, Ricardo Francisco Reier; MORELL, Oriol Pi; VAZQUEZ, Javier Jorge. Digitalization, Circular Economy, and Environmental Sustainability: The Application of Artificial Intelligence in the Efficient Self-Management of Waste. **Sustainability**, Basel, Switzerland, v. 13, 19p. Feb. 2021.
- ALSUBAEI, Faisal S.; AI-WESABI, Fahd N.; HILA, Anwer Mustafa. Deep Learning-Based Small Object Detection and Classification Model for Garbage Waste Management in Smart Cities and IoT Environment. **Smart Cities and IoT Environment**, Seattle, United States, v. 12, 18p. 2022.
- CLEWLEY, Daniel, BUNTING, Peter; SHEPHERD, James; GILLINGHAM, Sam; FLOOD, Neil; DYMOND, John; LUCAS, Richard; ARMSTON, John; MOGHADDAM, Mahta. "A Python-Based Open-Source System for Geographic Object-Based Image Analysis (GEOBIA) Utilizing Raster Attribute Tables." **Remote Sensing**, Basel, Switzerland, v. 6, n.7, 25p. Jun. 2014.
- DE MOURA SEPTÍMIO, Horácio. **Deteção de Depósitos de Lixo Utilizando Sensoriamento Remoto: Métodos e Resultados**. Goiânia, Tribunal de Contas dos Municípios do Estado de Goiás, 12p. 2023.
- DYBA, Krzysztof. Explanation of the influence of geomorphometric variables on the landform classification based on selected areas in Poland. **Scientific Reports**, London, England, v. 14, n. 1, 13p. dec. 2024.
- ERSAVAS, Tansel; SMITH, Martin A.; MATTICK, John S. Novel applications of Convolutional Neural Networks in the age of Transformers. **Scientific Reports**, London v. 14, 11p. may. 2024.
- GNANN, Nina; BASCHEK, Björn; TERNES, Thomas A. Close-range remote sensing-based detection and identification of macroplastics on water assisted by artificial intelligence: A review. **Water Research**, The Netherlands, Holland, v. 222, 15p. 2022.
- HOSSAIN, Yearat; NIJHUM, Ifran Rahman; SADI, Abu Adnan; SHAD, Tazin Morshed; RAHMAN, Rashedur M. Visual Pollution Detection Using Google Street View and YOLO. **IEEE Access: The Multidisciplinary Open Access Journal**, New York, United States, v. 1, p. 433-440, Dec. 2021.
- JIN, Shoufeng; YANG, Zixuan; KRÓLCZYKG, Grzegorz; LIU, Xinying; GARDONI, Paolo; LI, Zhixiong. Garbage detection and classification using a new deep learning-based machine vision system as a tool for sustainable waste recycling. **Waste Management**, Canada, v. 162, n. 1, p. 123-130, May. 2023.
- KANG, Zhuang; YANG, JIE; LI, Guilan ZHANG, Zeyi. An Automatic Garbage Classification System Based on Deep Learning. **IEEE Access: The Multidisciplinary Open Access Journal**, New York, United States, v. 20, 11p. 2017.
- LI, Jie, J.; SHENG, Y. Chen, L. Ke, N.; YAO, Z. Miao, X. ZENG, L. Hu, WANG, Q. A web-based learning environment of remote sensing experimental class with Python. In: **International Archives of the Photogrammetry**, Remote Sensing and Spatial Information Sciences, France, v. XLIII-B5-2020, p. 57-61, 2020.

LI, Zhenhui; ZHOU, Fan; WANG, Zhiyuan; XU, Xovee; LIU, Leyuan; YIN, Guangqiang. Measuring and classifying IP usage scenarios: a continuous neural trees approach. **Scientific Reports**, London, England, v. 14. n. 1, 10p. Dec. 2024.

LOBATO, I; FRIEDRICH, T. VAN AERT, S. Deep convolutional neural networks to restore single-shot electron microscopy images. **NPJ Comput Mater**, London, n. 10, v. 10, 19p. Jan. 2024.

MALIK, Meena; SHARMA, Sachin; UDDIN, Mueen; CHEN, Chin-Ling; WU, Chih-Ming; SONI, Punit; CHAUDHARY, Shikha. Waste Classification for Sustainable Development Using Image Recognition with Deep Learning Neural Network Models. **Sustainability**, Basel, Switzerland, v. 14, 18p. Jun. 2022.

MAJCHROWSKA, Sylwia; MIKOŁAJCZYK, Agnieszka; FERLIN, Maria; KLAWIKOWSKA, Zuzanna; MARTA A. PLANTYKOW, KWASIGROCH, Arkadiusz; MAJEK, Karol. Deep learning-based waste detection in natural and urban environments. **Waste Management**, Canada, v. 138, p. 274-284, 2022.

MURTHY, Chinthakindi Balaram; HASHMI, Mohammad Farukh; BOCKDE, Neeraj Dhanraj; GEEM, Zong Woo. Investigations of Object Detection in Images/Videos Using Various Deep Learning Techniques and Embedded Platforms - A Comprehensive Review. **Applied Sciences**, Switzerland, v. 10, 46p. May. 2020.

MUSTAPHA, Mubarak Taiwo; OZSAHIN, Ilker; OZSAHIN, Dilber Uzun. Chapter 2 - Convolution neural network and deep learning, p. 21-50. In: SELVARAJ, Jubie; PRABHA, Thangavelu; KUMAR, T. Durai Ananda; PALANIAPPAN, Senthilkumar. **Artificial intelligence and image processing in medical imaging developments in biomedical engineering and bioelectronics**. Academic Press, Norwich, 419p. 2024.

NA, Seunguk; HEO, Seokjae, HAN, Sehee; SHIN, Yoonsoo; LEE, Myeunghun. Development of an Artificial Intelligence Model to Recognise Construction Waste by Applying Image Data Augmentation and Transfer Learning. **Buildings**, Basel, Switzerland, v. 12, n. 175, 18p. 2022.

NNAMOKO, Nonso; BARROWCLOUGH, Joseph PROCTER, Jack. Solid Waste Image Classification Using Deep Convolutional Neural Network. **Infrastructure**, v. 7, n. 42, 18p. 2022.

PRASAI, Ritika; SCHWERTNER, T. Wayne; MAINALI, Kumar; MATHEWSON, Heather; KAFLEY, Hemanta; THAPA, Swosthi; ADHIKARI, Dinesh; MEDLEY, Paul; DRAKE, Jason. Application of Google earth engine python API and NAIP imagery for land use and land cover classification: A case study in Florida, USA. *Ecological Informatics*. **Elsevier**, Amsterdam, Holand, v. 66, 7p. Dec. 2021.

QIN, Jiongming; WANG, Cong; RAN, Xu; YANG, Shaohua; CHEN, Bin. A robust framework combined saliency detection and image recognition for garbage classification. **Waste Management**, Canada, v. 140, p. 193-203, 2022.

SAMI, Khan Nasik; AMIN, Zian Md Afique; HASSAN, Raini. Waste Management Using Machine Learning and Deep Learning Algorithms. **International Journal on Perceptive and Cognitive Computing**, Kuala Lumpur, Malaysia, v. 6, n. 2. Dec. 2020.

SCOTT, Andrew C.; BOHL, David K.; HEDDEN, Steve; MOYER, Jonathan D.; HUGHES, Barry B. **Sustainable development goals report: Brazil 2030**. United Nations Development Programme Bureau for Policy Programme Support, 82p. Dez. 2030.

SUN, Xian; DONGSHUO, Yin; QIN, Fei; YU, Hongfeng; LU, Wanxuan; YAO, Fanglong; He, Qibin; HUANG, Xingliang; YAN, Zhiyuan; WANG, Peijin; DENG, Chubo; LIU, Nayu; YANG, Yiran; LIANG, Wie; WANG, Ruiping; WANG, Cheng; YOKOYA, Naoto; HÄNSCH, Ronny; FU, Kun. Revealing influencing factors on global waste distribution via deep learning based dumpsite detection from satellite imagery. **Nature Communications**, London, United Kingdom v. 14, n. 1, Dec. 2023.

TAMIN, Owen; MOUNG, Ervin Gubin; DARGHAM, Jamal Ahmad; YAHYA, Farashazillah; OMATU, Sigeru. A review of hyperspectral imaging-based plastic waste detection state-of-the-arts. **International Journal of Electrical and Computer Engineering (IJECE)**, Bantul, Indonesia, v. 13, n. 3, p. 3407-3419, June. 2023.

TITU, Md Fahim Shahoriar; CHOWDHURY, Abdul Aziz; HAQUE, S. M. Rezwanaul; KHAN, Riasat. Deep-Learning-Based Real-Time Visual Pollution Detection in Urban and Textile Environments. **Sci**, Basel, Switzerland, v. 6, n. 1, 2024.

VERMA, Vishal; GUPTA, Deepali; GUPTA, Sheifali; UPPAL, Mudita; ANAND, Divya; ORTEGA-MANSILLA, Arturo; ALHARITHI, Fahd S.; ALMOTIRI, Jasem; GOYAL, Nitin. A Deep Learning-Based Intelligent Garbage Detection System Using an Unmanned Aerial Vehicle. **Symmetry**, Basel, Switzerland, v. 14, 15p. May. 2022.

WANI, Atif Khurshid; RAHAYU, Farida; AMOR, Ilham Bem; QUADIR, Munleef; MURIANINGRUM, Mala; PARNIDI, Parnidi; AYUB, Anjuman; SUPRIYADI, Supriyadi; SAKIROH, Sakiroh; SAEFUDIN, Saefudin; KUMAR, Abhinav; LATIFAH, Evy. **Environmental resilience through artificial intelligence: innovations in monitoring and management**. **Environmental Science and Pollution Research**, Heidelberg, Germany, v. 31, p. 18379–18395, 2024.

YANG, Kun; ZHANG, Chaoqun; LUO, Ting; HU, Lei. Automatic identification method of construction and demolition waste based on deep learning and GAOFEN-2 DATA. In: **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLIII-B3-2022 XXIV ISPRS Congress (2022 edition), Nice, France, p. 1293-1299, 6–11 June 2022.

YANG, Zhongxue; BAO, Yiqin; LIU, Yuan; ZHAO, Qiang; ZHENG, Hao; BAO, YuLu. Research on deep learning garbage classification systems based on fusion of image classification and object detection classification. **Mathematical Biosciences and Engineering**, Springfield, United States, v. 20, v. 3, p. 4741-4759. 2023.

ZHENG, Junjun; XU, Mingyuan; CAI, Ming; WANG, Zhichao; YANG, Mingmiao. Modeling Group Behavior to Study Innovation Diffusion Based on Cognition and Network: An Analysis for Garbage Classification System in Shanghai, China. **International Journal of Environmental Research and Public Health**, Basel, Switzerland, v. 11; n. 18, 16p.

ZHOU, Shanyu; MOU, Lichao; HUA, Yuansheng; ZHANG, Lixian; KAUFMANN, Hermann; ZHU, Xiao Xiang. Can we use deep learning models to identify the functionality of plastics from space? **International Journal of Applied Earth Observation and Geoinformation**, Netherlands, Amsterdam, v. 123, 9p. 2023.

APÊNDICE

Apêndice A - Quadro de pontos analisados

Ponto	Característica	Município	Latitude	Longitude	Banda 1	Banda 2	Banda 3	Banda 4
1	Lixo	Edeia	615549,8	8085400,6	327	302	381	451
2	Lixo	Edeia	615477	8085299,7	282	270	389	446
3	Lixo	Edeia	615445,6	8085255,1	258	281	387	479
4	Lixo	Edeia	615503,5	8085231,1	275	275	437	493
5	Lixo	Edeia	615481,1	8085227,8	235	218	300	335
6	Lixo	Edeia	615464,6	8085217,9	190	190	245	311
7	Lixo	Edeia	615491,8	8085143	260	239	343	390
8	Lixo	Edeia	615503,5	8085132,7	250	227	304	399
9	Lixo	Edeia	615495,2	8085118,7	276	256	319	425
10	Lixo	Edeia	615400,1	8085118,7	244	244	323	393
11	Lixo	Indiara	608474,5	8102052,5	303	279	312	385
12	Lixo	Indiara	608471,2	8102019,4	301	257	310	436
13	Lixo	Indiara	608300,9	8102217	249	235	323	397
14	Lixo	Indiara	608245,5	8102177,3	288	278	312	453
15	Lixo	Indiara	608582	8101968,9	355	298	368	439
16	Lixo	Indiara	608544	8101916,9	269	252	363	423
17	Lixo	Indiara	608225,7	8102081,4	269	263	354	411
18	Lixo	Indiara	608576,2	8101871,4	277	245	292	350
19	Lixo	Indiara	608625,9	8101873,9	318	301	377	445
20	Lixo	Indiara	608612,6	8101920,6	345	307	378	474
21	Vegetação	Indiara	615762,6	8085070,5	192	191	143	590
22	Vegetação	Indiara	615400	8085589,7	183	160	143	402
23	Vegetação	Edeia	609916,1	8101696,3	180	159	109	541
24	Vegetação	Edeia	609918,6	8101630,1	210	152	112	433
25	Vegetação	Edeia	609521,7	8101833,5	197	194	137	613
26	Vegetação	Indiara	607259,5	8101481,7	183	149	101	675
27	Vegetação	Indiara	607652,6	8101049,3	191	168	145	428
28	Vegetação	Edeia	619929,9	8086097,9	182	142	101	483
29	Vegetação	Edeia	618858,4	8086695	188	172	124	504
30	Vegetação	Indiara	613908	8086567	276	257	316	459
31	Estrada	Edeia	607246,7	8002528,9	256	243	262	460
32	Estrada	Edeia	607837	8102786,8	246	249	356	545
33	Estrada	Edeia	617171,7	8085309,2	302	348	374	661
34	Estrada	Edeia	617909,2	8085275,2	257	244	287	596
35	Estrada	Edeia	619053,1	8084175,8	271	261	304	527
36	Estrada	Indiara	607827,2	8101380,7	230	203	232	579
37	Estrada	Indiara	608220,1	8102119,4	235	218	239	485
38	Estrada	Indiara	607121,7	8102813,5	311	348	462	656
39	Estrada	Indiara	608773,5	8102817,5	249	241	304	558
40	Estrada	Indiara	610700,6	8101777,8	213	189	206	472
41	Solo exposto	Edeia	619996	8086674,4	209	194	265	424

Apêndice A - Quadro de pontos analisados - Continuação

Ponto	Característica	Município	Latitude	Longitude	Banda 1	Banda 2	Banda 3	Banda 4
42	Solo exposto	Edeia	620033,9	8085761,5	228	200	262	370
43	Solo exposto	Edeia	616605,37	8085933	225	201	253	398
44	Solo exposto	Edeia	615871,4	8085918,1	202	174	206	314
45	Solo exposto	Indiara	609473,2	8102056	211	185	282	378
46	Solo exposto	Indiara	608486,7	8101893,3	187	160	211	326
47	Solo exposto	Indiara	608899,1	8102143,1	185	165	251	395
48	Solo exposto	Indiara	609109,5	8102704,1	192	179	261	339
49	Solo exposto	Indiara	607260,2	8102833	197	175	275	348
50	Solo exposto	Edeia	608601	8102193,2	253	241	321	490
51	Residência	Indiara	612404,8	8085641	594	524	528	718
52	Residência	Edeia	607730,8	8102747,1	269	265	324	382
53	Residência	Indiara	613270,2	8083371,2	335	320	395	515
54	Residência	Indiara	613504,2	8083316,6	233	215	306	419
55	Residência	Indiara	607709,1	8102855,7	208	170	231	415
56	Residência	Indiara	607594,3	8102806,7	181	156	256	286
57	Residência	Edeia	613495,2	8083322,7	179	147	204	258
58	Residência	Edeia	614941,1	8083656,6	191	164	227	334
59	Residência	Edeia	6174428,5	8084480,8	229	207	300	405
60	Residência	Edeia	617061,5	8087031,2	213	424	472	466
61	Água	Indiara	613457,9	8083564,6	130	108	74	80
62	Água	Edeia	612437,1	8086395	159	131	121	85
63	Água	Edeia	614638	8086306	142	111	92	80
64	Água	Edeia	614088,1	8086787,5	131	103	68	85
65	Água	Indiara	609920,2	8101231,1	151	123	99	88
66	Água	Indiara	608041,5	8101931,5	150	125	95	73
67	Água	Indiara	607870	8102291	151	130	106	73
68	Água	Indiara	607877,7	8102143,3	154	129	101	77
69	Água	Edeia	619061,1	8084096,7	149	114	80	73
70	Água	Edeia	616157,1	8085199,3	128	99	84	68