



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Análise da Evolução Temporal de Garimpo Ilegal Sobre a Terra Indígena Kayapó

Matheus Dias de Aviz¹, Leonardo Correa Cordeiro², Mayara Cobacho Ortega Caldeira³,

¹ Msc. em Geologia e Geoquímica, I, Universidade Federal do Pará, Rua Augusto Corrêa, nº 01, CEP 66075-000, Belém, Pará. (11) 93358-0234. matheus.aviz@ig.ufpa.br (autor correspondente), <https://orcid.org/0000-0002-8543-4283>. ² Msc. em Ciências Ambientais, Universidade Federal do Pará, Rua Augusto Corrêa, nº 01, CEP 66075-000, Belém, Pará. (91) 98300-3035, leocordeiro7991@gmail.com, <https://orcid.org/0000-0001-9620-4005>. ³ Docente, Instituto Ciberespacial, Universidade Federal Rural da Amazônia, Estrada principal da Ufra, nº 2150, CEP 66.077-830, Belém, Pará. (18) 99147-0412. mayara.cobacho@ufra.edu.br, <https://orcid.org/0000-0002-2427-9363>.

Artigo recebido em 12/09/2024 e aceito em 29/01/2025

RESUMO

Ferramentas de sensoriamento remoto são essenciais para monitorar a expansão de garimpos em Terras Indígenas (TI), muitas vezes sendo a única forma de fiscalização ambiental, especialmente em áreas remotas. Apesar de estudos sobre a proteção de TI estarem bem documentados, a relação entre a expansão do garimpo e as políticas governamentais é pouco explorada. Nesse contexto, o sensoriamento remoto permite mapear essas regiões e mensurar os impactos em diferentes escalas. Este estudo teve como objetivo avaliar a expansão do garimpo ilegal em cinco áreas da TI Kayapó entre 2014 e 2023, utilizando a plataforma Google Earth Engine e imagens do satélite Landsat-8. O algoritmo Random Forest foi empregado para classificar quatro classes: garimpo, água, vegetação e desflorestamento. Os resultados indicaram uma redução nas classes água (24,57%) e vegetação (4,89%), com um aumento significativo nas classes garimpo (380%) e desflorestamento (149%). O garimpo mostrou forte correlação com o desflorestamento ($p < 0,05$; 0,94) e vegetação ($p < 0,05$; -0,95). O estudo revelou que a expansão do garimpo na TI Kayapó cresceu durante o período analisado, influenciada por eventos político-sociais, como mudanças governamentais e a pandemia de 2019. Além disso, a resolução espacial das imagens favoreceu a precisão da classificação. Por fim, o uso do classificador Random Forest com imagens Landsat-8 se mostrou eficaz na identificação da expansão do garimpo na TI Kayapó.

Analysis of the Temporal Evolution of Illegal Mining on the Kayapó Indigenous Land

ABSTRACT

Remote sensing tools are essential for monitoring the expansion of mining in Indigenous Lands (TI), often being the only form of environmental monitoring, especially in remote areas. Although studies on the protection of TIs are well documented, the relationship between the expansion of mining and government policies is little explored. In this context, remote sensing makes it possible to map these regions and measure the impacts at different scales. This study aimed to assess the expansion of illegal mining in five areas of the Kayapó Indigenous Land between 2014 and 2023, using the Google Earth Engine platform and images from the Landsat-8 satellite. The Random Forest algorithm was used to classify four classes: mining, water, vegetation and deforestation. The results indicated a reduction in the water (24.57%) and vegetation (4.89%) classes, with a significant increase in the mining (380%) and deforestation (149%) classes. Mining showed a strong correlation with deforestation ($p < 0.05$; 0.94) and vegetation ($p < 0.05$; -0.95). The study revealed that the expansion of mining in the Kayapó Indigenous Land grew during the period analyzed, influenced by political and social events, such as government changes and the 2019 pandemic. In addition, the spatial resolution of the images favored classification accuracy. Finally, the use of the Random Forest classifier with Landsat-8 images proved to be effective in identifying the expansion of mining in the Kayapó Indigenous Land.

Introdução

As florestas amazônicas desempenham um papel essencial na manutenção do equilíbrio ambiental global, funcionando como um importante regulador climático, além de serem um dos maiores reservatórios de biodiversidade do planeta. Essas florestas também representam a base

da subsistência e da identidade cultural de diversas populações indígenas, que dependem diretamente de seus recursos para garantir sua sobrevivência e perpetuação cultural (Mataveli et al., 2022). Contudo, o avanço de atividades antrópicas, como o desmatamento e o garimpo ilegal, tem

comprometido essas funções ecológicas e sociais, colocando em risco não apenas os ecossistemas, mas também a integridade territorial e cultural das comunidades indígenas (Perez et al., 2022).

O garimpo ilegal, em particular, constitui uma das ameaças mais críticas às Terras Indígenas (TIs) na Amazônia. Essa atividade promove a degradação ambiental por meio do desmatamento e da contaminação de corpos d'água, além de desencadear impactos sociais severos, como conflitos armados e a introdução de doenças em comunidades isoladas (Rorato et al., 2022; Caldas et al., 2023). Além disso, o garimpo ilegal acarreta a desestruturação econômica dessas comunidades, muitas vezes deixando um rastro de pobreza e vulnerabilidade social. A expansão dessa prática ocorre muitas vezes em função de lacunas na fiscalização ambiental, da fragilidade nas políticas públicas de proteção e da insuficiência de mecanismos de governança que garantam a efetiva proteção dessas áreas protegidas (Siqueira-Gay et al., 2020).

No contexto amazônico, o monitoramento dessas atividades representa um grande desafio, dada a vastidão e a dificuldade de acesso a muitas áreas. Nesse sentido, o sensoriamento remoto tem se consolidado como uma ferramenta indispensável para a análise espacial e temporal dessas dinâmicas. Estudos recentes destacam sua eficácia na detecção de áreas de exploração ilegal de recursos naturais, oferecendo suporte técnico para o planejamento de ações de mitigação e combate ao garimpo (Balaniuk et al., 2020; Fassoni-Andrade e Paiva, 2019). Ainda assim, as análises existentes geralmente se concentram em aspectos isolados, como o impacto ambiental imediato ou a quantificação do desmatamento, sem explorar de forma ampla as dinâmicas de governança e as influências políticas subjacentes a essas expansões.

Nesse contexto, o sensoriamento remoto é utilizado como uma ferramenta que permite o monitoramento de grandes áreas de forma multitemporal e assim identificar as principais Terras Indígenas (TIs) que são desmatadas (Linares et al., 2024). Durante o período de 2013 a 2021, a taxa de desmatamento em TIs foi de aproximadamente 900 km²/ano, com a TI Kayapó apresentando 3 km²/ano para o mesmo período (Silva Júnior et al., 2023). Impactos como esses ressaltam a importância de um aspecto crítico em relação à expansão do garimpo ilegal e às políticas de governança para frear esse cenário.

É notório que as comunidades indígenas desempenham um papel essencial na conservação

da biodiversidade e na manutenção dos serviços ecossistêmicos. Contudo, essas populações têm enfrentado crescentes pressões externas, que vão desde invasões territoriais até a exploração ilegal de recursos naturais. A construção do cenário no qual as TIs possuem grandes impactos das atividades minerárias deveria ter como base os pilares social, econômico e ambiental, a fim de garantir que os povos locais e os recursos naturais sofressem o menor grau de impacto nesses três pilares (Alvarenga, 2023).

Diante disto, os agentes do Estado, como a União e a Agência Nacional de Mineração (ANM), possuem o dever de assegurar que as atividades em TIs atendam aos requisitos básicos do desenvolvimento sustentável e atuem dentro da legalidade (Alvarenga, 2023; Mendes e Martins, 2022). Entretanto, a implementação efetiva dessas diretrizes esbarra em desafios práticos, como a ausência de fiscalização eficiente e a falta de uma coordenação interinstitucional para enfrentar essas ameaças. O descaso com esses povos, principalmente no requisito em políticas públicas e legislações capazes de assegurar seus direitos, contribui para o que é mencionado por Mendes e Martins (2022) como necropolítica, cujas ações governamentais no decorrer dos anos mais contribuíram para a efetivação das atividades nessas regiões do que para assegurar os direitos desses povos.

Além das implicações ambientais e sociais, é importante destacar os impactos econômicos negativos que o garimpo ilegal traz, tanto para as comunidades locais quanto para o país como um todo. A evasão fiscal e a desestruturação das economias locais são apenas algumas das consequências que demandam atenção governamental e acadêmica. A alternância de poder no Governo Federal, com diferentes perspectivas sobre a proteção ambiental, frequentemente reflete suas prioridades por meio de mudanças na aplicação de políticas públicas, fiscalização e combate às atividades ilegais em TIs. Essa relação entre governança ambiental e expansão de atividades ilegais em áreas protegidas ainda carece de estudos aprofundados que integrem dados espaciais e temporais para avaliar a evolução do problema sob diferentes contextos políticos (Amaral e Lopez, 2023).

Diante desse cenário, surge questões como, as dinâmicas de governança e as fragilidades institucionais influenciam a expansão do garimpo ilegal em Terras Indígenas na Amazônia, e de que forma tecnologias como o sensoriamento remoto podem mitigar esses impactos. A busca por

respostas a essa problemática é essencial para subsidiar políticas públicas e estratégias de manejo mais eficazes, voltadas à proteção das Terras Indígenas e ao enfrentamento das ameaças socioambientais associadas ao garimpo ilegal.

Além disso, é essencial investigar como as resoluções espaciais e temporais dos estudos de sensoriamento remoto impactam a classificação e o monitoramento do garimpo ilegal nessas áreas.

A hipótese central do artigo é que as taxas de desmatamento coincidem com períodos de escassez de políticas públicas voltadas para a proteção das Terras Indígenas (TIs). Para verificar essa hipótese, o objetivo do estudo foi caracterizar e analisar a expansão das áreas de garimpo ilegal em cinco regiões da TI Kayapó, na Amazônia, entre 2014 e 2023, utilizando técnicas de sensoriamento remoto.

O estudo utiliza essas técnicas para discutir a relação entre as flutuações nas atividades garimpeiras e as mudanças nas políticas públicas de proteção ambiental sob diferentes administrações. Os resultados obtidos permitiram quantificar e localizar áreas críticas de exploração mineral, além de contribuir para o debate sobre governança ambiental e a proteção das TIs. Ao

fornecer uma análise integrada, o estudo visa apoiar iniciativas que promovam estratégias mais eficazes de combate ao garimpo ilegal e de proteção das comunidades indígenas afetadas.

Material e métodos

Localização e Caracterização da Área Experimental

A TI Kayapó está localizada no sudeste do estado do Pará, sendo que sua área recobre quatro municípios, como pode ser visto na Figura 1. Sendo 50,47% da área total corresponde ao município de São Félix do Xingu, seguido de Ourilândia do Norte (37,18%), Cumaru do Norte (11,85%) e Bannach (0,50%) (Figura 1). Esta TI abrange aproximadamente 3.284 mil hectares e possui um perímetro de 1.029 km. Abriga dois povos indígenas, denominado de isolados do Rio Fresco e Mebêngôkre (Kayapó), com uma população total de 6.365 habitantes, conforme dados do (IBGE, 2023). Além disso, a TI Kayapó foi oficialmente reconhecida pelo Decreto nº 316 em 30 de outubro de 1991 (DECRETO No 316, DE 29 DE OUTUBRO DE 1991., 1991).




Figura 1. Mapa de localização da TI Kayapó. Representa a localização das cinco áreas de garimpo investigadas neste trabalho (A) e a localização aproximada da TI Kayapó no Brasil (B).

As fitofisionomias que a compõe são dos tipos contato savana-floresta ombrófila (20,49%), floresta ombrófila aberta (45,65%), floresta ombrófila densa (21,93%) e savana (11,93%). Esta TI tem clima tropical úmido (IBGE, 2002) estando localizada na bacia hidrográfica do rio Xingu e no bioma Amazônia. A pedologia local é caracterizada por Argissolo vermelho-amarelo, Neossolo lítico, Nitossolo vermelho e Latossolo vermelho-amarelo (EMBRAPA, 2021). Os minérios mais explorados na região são manganês, ouro e cobre principalmente próximo aos rios. Além disso, nesta região de acordo com o Sistema de informação Geográficas de Mineração (SIGMINE) (ANM, 2024) existem processos ativos: 19 processos de Cobre, 15 de Ouro, 9 de Cassiterita, 3 de Fosfato, 2 de Manganês e 1 de Ferro e Níquel.

Contudo, essa TI tem sofrido um intenso desmatamento nos anos de 2021 a 2023, com áreas de vegetação nativa sendo convertidas em áreas de garimpo e desmatamento. Em 2021, a taxa de desmatamento foi de 13.038 km², sendo uma das mais altas desde 2008. Em 2022, esse número caiu

para 11.594 km². No período de agosto de 2022 a julho de 2023, a taxa consolidada de desmatamento foi de 9.064 km², representando uma queda de 21,8% em relação ao período anterior, conforme a base de dados vetoriais do Projeto de Estimativa de Desmatamento na Amazônia (INPE, 2023). Por este motivo, foram selecionadas cinco áreas de garimpo na TI de Kayapó (conforme a Figura 1), para estudo da evolução do garimpo desde 2014.

Descrição metodológica

A metodologia foi dividida em quatro grandes tópicos (Figura 2). O primeiro apresenta a aquisição dos dados sendo descrito suas fontes, bem como a tratamento dos dados antes de serem trabalhados no Google Earth Engine (GEE); o segundo tópico consiste no processamento das imagens na plataforma GEE; o terceiro e quarto passos concernem no uso do geoprocessamento para definir as classes e calcular as áreas, culminando na análise estatística utilizando o software Past




Figura 2. Infográfico da metodologia aplicada para classificação das áreas de garimpo

Em resumo, referente ao código em *JavaScrip* para o GEE, imagens de satélite Landsat-8 foi utilizada para classificar a Terra Indígena Kayapó (TI-Kayapó) em diferentes classes de uso da terra, como garimpo, rios, vegetação e solo exposto. As imagens foram filtradas por data e cobertura de nuvens, então essas imagens do Landsat-8 passaram por uma composição mediana para reduzir a interferência de nuvens. Foi realizado mesmo procedimento para imagens da constelação Sentinel-2, estas usadas como validação, visto a maior resolução espacial (10 m).

A classificação foi realizada com o algoritmo Random Forest, utilizando amostras de treinamento (70%) e validação (30%). A acurácia do modelo foi avaliada por métricas como acurácia global, do produtor e do consumidor, além do índice Kappa e RMSE, para comparar as classificações de diferentes satélites.

O cálculo da área de cada classe foi feito a partir das imagens classificadas, fornecendo estimativas precisas da distribuição do uso da terra. Por fim, os resultados da classificação e as imagens foram exportados para o Google Drive para análises posteriores no Qgis e no PAST.

Aquisição e Pré-Processamento de dados

Para a análise temporal, de 2014 a 2023, foram utilizadas as coleções de imagens, disponíveis na plataforma GEE, do satélite Landsat-8 (LANDSAT/LC08/C02/T1_L2), sensor OLI, com resolução de 30 metros, revisita de 16 dias, nível 2, tier 1 disponíveis na plataforma GEE. A utilização de imagens do satélite Landsat-8 ocorreu por conta da maior disponibilidade de imagens, contudo destacamos a alta presença de nuvens nas imagens o que foi amenizada no GEE. Estudos de Yang *et al.* (2022) e Doblas *et al.* (2022) destacam a ferramenta GEE, uma plataforma

digital com processamento de dados geoespaciais em nuvem e que fornece acesso a dados multitemporais públicos e gratuitos.

Vale ressaltar que essas imagens apresentam reflectância de superfície. As bandas utilizadas foram as do vermelho (0,636 - 0,673 μm), verde (0,533 - 0,590 μm) e azul (0,452 - 0,512 μm), na composição 4RG3B2. Além disso, foi adquirido o *shapefile* do território da terra indígena Kayapó do site da Fundação Nacional dos Povos Indígenas (FUNAI, 2024). Foram adquiridos dados de áreas atuais com atividades garimpeiras a fim de comparação com a classificação realizada. Essa aquisição foi realizada através da classificação prévia de imagens Sentinel-2 MSI, nível 2A (COPERNICUS/S2_SR_HARMONIZED) do ano de 2024 em todo o território da terra indígena Kayapó com buffer de 100 m. Essa delimitação ocorreu no próprio GEE.

Processamento digital de imagens

Após a identificação das áreas com garimpos na TI, foram delimitadas cinco áreas de garimpo (Figura 1) com um *buffer* externo de 100 metros à TI Kayapó. Esse *buffer* foi implementado para prevenir erros de tipologia. Essas áreas foram inseridas no GEE, onde foram coletadas 30 amostras aleatórias, bem distribuídas em cada uma das quatro classes (Figura 3): Garimpo, Água, Vegetação e Áreas Desflorestadas (naturais ou antrópicas). A coleta foi realizada através de polígonos que cobrem mais de um pixel. É importante ressaltar que na região existem dois tipos de rios, um com a água com alto e outro com baixo teor de sedimento, de modo que foram coletadas amostras representativas de ambos os tipos de rios.

Objeto	Imagem	Textura	Descrição
Garimpo		Lisa e leitosa de alta reflectância	Áreas com alta reflectância, com alta heterogeneidade de superfície, confundindo com solo exposto e água. Incidência de vegetação densa e esparsa.
Água		Leitosa para rios com alta turbidez e lisa e esmeralda para rios com menor turbidez	Dois tipos de resposta espectral, rios com alto teor de sedimentos em suspensão, que se confundem com garimpo e rios com baixo teor de sedimentos. Caracterizado por canais de até 200 m.
Vegetação		Rugosa	Compostas por áreas homogêneas e com baixa confusão, localizadas em todas as 5 áreas e bem extensas.
Desflorestado		Superfícies geométricas	Compostas por áreas naturais e antropizadas. As naturais são localizadas em áreas de alto relevo e dentro da TI e as antrópicas em regiões fora da TI, representadas por solo exposto, pastos e áreas agrícolas.

Figura 3. Chaves de interpretação das quatro classes selecionadas para classificação: Garimpo, Água, Vegetação e desflorestado.

Após a coleta ocorreu a classificação das imagens Landsat-8, e para isso, foi empregado o classificador *Random Forest* - RF (*Classification and Regression Trees*), proposto por Breiman (2001). Esse classificador é conhecido por construir modelos de árvores de decisão tanto para classificação quanto para regressão. O algoritmo *Random Forest* funciona como um conjunto de árvores de decisão (ensemble), onde múltiplas árvores são treinadas com diferentes subconjuntos aleatórios de dados e variáveis. Cada árvore individual gera uma previsão, e a *Random Forest* combina os resultados dessas árvores para fazer uma previsão final, seja pela média das predições (para regressão) ou pela maioria dos votos (para classificação). A aleatoriedade nas amostras de dados e nas variáveis usadas em cada árvore aumenta a robustez do modelo, tornando-o menos suscetível ao *overfitting*. Esse método é particularmente eficaz em lidar com grandes volumes de dados e detectar relações complexas entre variáveis, proporcionando um modelo preciso e estável (Breiman, 2001).

Neste trabalho, o RF foi ajustado com 100 árvores de decisão e divisão de amostras de 70% para treinamento e 30% para validação. Foram utilizadas para classificação na composição 4R3G2B. Também foi realizada a classificação de imagens correspondentes a cada ano de imagens Sentinel-2, para a realização de validação cruzada com a classificação das imagens Landsat-8.

Conforme apontam Yang et al. (2022) e Zhou et al. (2021), a plataforma GEE e o uso de classificadores supervisionados como RF possuem desempenho otimizados, permitindo classificar com bom desempenho computacional em grandes áreas e em diversas classes. Precisão e otimização são requisitos fundamentais para a aplicação dos métodos de classificação em diferentes escalas temporais e espaciais. Ferramentas eficientes como essas são essenciais, por exemplo, na identificação da extração ilegal de ouro na Amazônia, que apresentou um aumento médio significativo de 7,9% ao ano, com a região amazônica concentrando 90% da área de garimpo do território nacional (Oviedo & Senra, 2023).

No processamento de imagens foi aplicado um filtro limite espacial, para que a classificação ocorresse apenas nas cinco áreas de interesse. Além disso, foi aplicado filtro de nuvens, sombras e cirros para a obtenção de imagens com até 5% de cobertura desses alvos. Por fim, foi realizada uma composição de imagens a partir do operador mediana, o qual realiza a mediana dos pixels das imagens filtradas e gera um compósito de imagens sem nuvens. A imagem gerada foi na composição 4RG3B2. Finalmente, foi realizado cálculo das áreas das classes em Km². Esta etapa, foi realizada no GEE, já que nele as áreas de cada classe por ano são obtidas através da relação entre área de um pixel e quantidade de pixels em cada classe.

Elaboração cartográfica

Após a classificação, as imagens e os produtos de classificação e suas respectivas imagens (R4G3B2) foram exportados para o ambiente de Sistema de Informação Geográfica (SIG), QGIS versão 3.28.4-Firenze, para a confecção de produtos cartográficos.

Análise Estatística

Os dados foram tabulados em uma planilha eletrônica no *software Excel*, posteriormente analisados nos *softwares* PAST e GEE para serem apresentados em forma de figuras, gráficos e tabelas. Foi utilizado o teste Shapiro-Wilk para verificar a normalidade dos dados com nível de confiança de 95% e $p > 0,05$, posteriormente aplicado a correlação de *Spearman* entre as classes para as variáveis não-paramétricas.

No coeficiente de correlação de *Spearman* verificou-se a variação das correlações entre -1 a +1, a fim de verificar o valor maior e mais das correlações entre as classes objeto do estudo. As correlações foram classificadas entre forte, moderada e fraca para os intervalos entre 0,7 e 0,9 (correlação forte) tanto positiva quanto negativa; 0,5 a 0,7 (correlação moderada) tanto positiva quanto negativa e de 0,3 a 0,5 (correlação fraca) tanto positiva quanto negativa (Dias & Magode, 2023).

A avaliação de precisão e erro foi realizada no GEE, a partir das variáveis apresentadas por Strauss et al. (2022), sendo elas: da matriz de confusão, índice Kappa, acurácia global - AG (Equação 1), acurácia do consumidor - AC (Equação 2) e produtor - AP (Equação 3). Além disso, também foi calculado erros de comissão - EC (Equação 4) e Omissão - EO (Equação 5), e o Erro da raiz média quadrática - RMSE (*Root Mean Square Error* - Equação 6). A Matriz de confusão foi calculada para o conjunto de validação da classificação Landsat 8; Índice Kappa foi calculado para medir a concordância entre os dados de treinamento (70%) e dados de referência (30%) e; o RMSE foi calculado entre a concordância de classificação entre imagens Landsat-8 e Sentinel-2.

$$AG = \frac{\sum_{i=1}^n \delta_i}{N} \quad (1)$$

$$AC = \frac{n_{ii}}{\sum_{j=1}^n n_{ji}} \quad (2)$$

$$AP = \frac{n_{ii}}{\sum_{j=1}^n n_{ij}} \quad (3)$$

$$EC = 1 - AC_i = 1 - \frac{n_{ii}}{\sum_{j=1}^n n_{ji}} \quad (4)$$

$$EO = 1 - AP_i = 1 - \frac{n_{ii}}{\sum_{j=1}^n n_{ij}} \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

A AG representa a proporção total de classificações corretas (δ_i) em relação ao número total de amostras (N). A AC mede a proporção de classificações corretas (n_{ii}) para uma classe específica em relação ao total de amostras classificadas como pertencentes a essa classe ($\sum n_{ji}$). A AP (sensibilidade/*recall*) mede a proporção de classificações corretas de uma classe específica (n_{ii}) em relação ao total de amostras de referência para essa classe ($\sum n_{ij}$). O EC indica a proporção de amostras que foram classificadas incorretamente como pertencentes a uma classe específica em relação ao total de amostras classificadas nessa classe ($1 - AC_i$). O EO indica a proporção de amostras que deveriam ter sido classificadas em uma classe específica, mas não foram, em relação ao total de amostras de referência para essa classe ($1 - AP_i$) (Congalton e Green, 2008). Finalmente, o RMSE é uma medida estatística utilizada para avaliar a diferença entre os valores previstos por um modelo ($\hat{y}_i$) e os valores observados (reais) (y_i). Ele representa a magnitude média do erro de previsão de um modelo, e é calculado como a raiz quadrada da média dos quadrados dos erros (Chai & Draxler, 2014).

Resultados

Nessa seção, são apresentadas as avaliações das classificações realizadas nas cinco áreas de garimpo na TI Kayapó, incluindo as avaliações de métricas de acurácia e uma breve análise da expansão das manchas de garimpo. A determinação da expansão das áreas de garimpo na terra indígena Kayapó foi conduzida através da classificação de imagens do satélite Landsat-8 OLI, para o período de 10 anos (2014-2023). A classificação foi realizada utilizando o classificador *Random Forest*, que se mostrou eficaz na distinção das classes analisadas.

Avaliação da classificação da TI Kayapó

A Figura 4 apresenta as imagens (4RG3B2) e os respectivos produtos de classificação, sendo possível notar a substituição da vegetação natural por garimpos a céu aberto de 2014 até 2023 das áreas 1, 2 e 3.




Figura 4. Classificação das áreas por classe na TI Kayapó – 2014 a 2023.

A Figura 4 revela que as maiores áreas de garimpo estão na área 3. Observa-se que esta região já era caracterizada por grandes manchas de garimpo desde 2014, possivelmente já existentes antes de 2014. Observa-se também incremento da expansão de área de garimpo na área 3 até 2023. Na área 1, observa-se pequenas áreas de garimpo em 2014, e ocorreu alto incremento de áreas até 2023, apresentando uma alta taxa de expansão de garimpo nessa região. Finalmente, na área 2, em 2014, havia uma pequena área de garimpo na borda da TI Kayapó, entretanto, com o passar dos anos nota-se a existência de áreas de garimpo em regiões no interior da TI. Além disso, é possível notar predominantemente, que a exploração garimpeira na TI Kayapó, está estritamente situada nas margens dos rios. E ainda existe entre 2014 e 2023

altas taxas de incremento de áreas de garimpo nas três áreas descritas na Figura 4.

A Figura 5 mostra a substituição da vegetação natural por garimpos a céu aberto de 2014 até 2023 das áreas 4 e 5. A área 4, de 2014 a 2017, não apresenta áreas de garimpo, alguns pixels podem ter sido classificados como garimpo erroneamente. A partir de 2018 essa região apresenta áreas significativas de garimpo, exibindo novas áreas de exploração na porção mais interior da TI Kayapó. A área 5 apresentava perímetros com garimpo desde 2014 e se mantinha estável até 2016 e em 2017 iniciou processo de aceleração de crescimento das manchas de garimpo. Então, apresentou maiores expansões de garimpo a partir de 2018, estabilizando na pandemia com posterior alta taxa de crescimento (14,13%) a partir de 2021.




Figura 5. Classificação das áreas por classe na TI Kayapó – 2019 a 2023.

Métricas e avaliações de acurácia.

Com base nas amostras aleatórias de validação coletadas, os resultados indicam acurácia

global média de 96,44% ± 0,71% e índice Kappa médio de 0,9087 ± 23,92.10⁻³. A Tabela 1 apresenta acurácia global, índice kappa e RMSE para todos os anos.

Ano	Acurácia Global (%)	Índice Kappa	RMSE
2014	97,85	0,9198	-
2015	95,98	0,8553	0,4596
2016	95,55	0,8870	0,5933
2017	95,51	0,8871	0,5156
2018	95,84	0,9063	0,4910
2019	96,65	0,9252	0,3194
2020	96,76	0,9266	0,3103
2021	96,71	0,9234	0,3468
2022	97,16	0,9361	0,3461
2023	96,40	0,9190	0,3788

Tabela 1. Precisão e erro das classificações

As precisões gerais indicaram que as classificações realizadas tiveram correta

2077

identificação com os dados de referência (amostras aleatórias). Os valores para índice Kappa obtidos neste estudo foram satisfatórios apresentando alta precisão assim como visto em Martins et al. (2023) cujo índice kappa variou de 90,92 a 94,89% e em Negreiro et al. (2024) cuja variação kappa foi 88 a 93%. A confusão na classificação foi predominante entre as classes garimpo, água e desflorestado, devido a heterogeneidade espacial e consequentemente a resposta espectral dos garimpos em seus muitos estágios terem resposta semelhantes a tais classes, conforme destaca Almeida (2019). Isso resultou em pixels de garimpo classificados em água devido a coloração da água, em detrimento aos altos terrores de sólidos suspensos na coluna d'água. E ainda, pixels de garimpo classificados como desflorestado devido as áreas de garimpos abandonadas, ou seja, não estão mais ativas no momento do imageamento, e possivelmente com baixa umidade o que favorece a confusão entre essas classes.

Comportamento semelhante foi observado por Almeida (2019) no Garimpo São Raimundo em Itaituba, cujo classificador indicou áreas de garimpo como solo exposto e/ou corpo hídrico mostrando que as áreas de garimpo podem apresentar distintas fases.

Apesar dos excelentes indicadores de acuracidade, as classes garimpo e água

apresentaram os maiores erros de omissão médio sendo 18,57% e 11,19%, respectivamente. A confusão de classificação entre essas classes pode ser explicada por alta taxa de sedimentos exportados aos corpos d'água provenientes das lavras garimpeiras, aumentando a refletância da água e assim confundindo com garimpo, o que somado a resolução espacial da imagem corrobora com a mistura de pixels principalmente nas margens.

Avaliação da expansão do garimpo na TI

A análise das áreas em km² das classes estudadas revela informações cruciais sobre a expansão do garimpo na Terra Indígena (TI) Kayapó, conforme ilustrado na Figura 6. A classe Água (Figura 6a) apresentou as maiores variações de área nos últimos 10 anos, enfrentando desafios na classificação devido a altos erros de omissão e sedimentação de garimpos nos rios (Gardner et al., 2021). A classe Desflorestamento (Figura 6b) mostrou um aumento significativo, passando de 49,80 km² em 2014 para aproximadamente 124,16 km², refletindo um período de diminuição das florestas e expansão das áreas desmatadas (Fernandes, 2022).




Figura 6. Quantificação das áreas por classe na TI Kayapó.

As manchas de Garimpo (Figura 6c) ocupavam inicialmente cerca de 20,6 km² em 2014,

alcançando aproximadamente 99,5 km² em 2023. Esse aumento, embora tenha sido substancial entre 2016 e 2021, reduziu entre 2021 e 2023,

possivelmente devido a mudanças nas políticas governamentais e impactos da pandemia (Wanderley et al., 2020). A classe Vegetação (Figura 6d) apresentou uma leve perda de cobertura florestal, correlacionada com o aumento das áreas desflorestadas e mudanças nas condições

ambientais (Sartori & Coelho, 2023). De modo a verificar a relação entre as classes analisadas, como perda de cobertura vegetal e aumento de garimpo, por exemplo, foi feita a correlação de *Spearman* entre as classes, como pode ser visto na Figura 7.




Figura 7. Correlação de Spearman entre as classes utilizadas na TI Kayapó

O Garimpo apresentou forte e direta correlação ($p < 0,05$; 0,94) com o Desflorestamento, enquanto com a Vegetação apresentou correlação forte e inversa ($p < 0,05$; -0,95). Isso indica que a atividade garimpeira nas áreas analisadas influencia diretamente na perda de cobertura florestal com a conversão de florestas para exploração ilegal de minérios (Marinho & Ribeiro, 2023). O Desflorestamento assim como o Garimpo, contribui para o desmatamento convertendo áreas verdes para solo exposto. A classe desflorestamento abrange atividades agropecuárias desenvolvidas na região que assim como o garimpo, atua impactando em áreas próximas à terra indígena (Silva Junior et al., 2020).

A classe de Vegetação apresentou correlação forte e inversa com o Desflorestamento ($p < 0,05$; -0,99) e Garimpo ($p < 0,05$; -0,95). Assim a alta correlação entre ambas as classes, indicam os impactos antrópicos sobre a terra indígena, como a exploração mineral e atividades agropecuárias. As áreas de água, representados pelos rios, apresentaram fraca correlação com as demais classes indicando que essas não exercem grande influência em suas áreas. É importante frisar que

mesmo as correlações terem sido baixas, as atividades de Garimpo e o Desflorestamento desenvolveram-se seguindo os corpos hídricos, principalmente o Garimpo, o que pode ter contribuído para alguns trechos no decorrer dos anos os corpos hídricos terem seus cursos impactados. Nota-se a evolução das atividades garimpeiras nos cursos dos rios, como pode ser vista essa tendência na imagem da classificação (Figura 4 e 5).

A resolução das imagens utilizadas também contribui para as correlações encontradas, visto que nem sempre o percurso do rio era uniforme, com alguns trechos os pixels de água serem semelhantes aos de Garimpo. Com a classe água sua correlação foi baixa ($p < 0,05$; -0,41). Os resultados de correlação corroboram com a classificação encontrada, principalmente entre a proporção nas classes vegetação e desflorestada, além das inconsistências para a classe água.

Discussão

Neste estudo, investigou a variação espacial através de análise temporal de imagens Landsat-8 em cinco áreas com garimpo na região

da TI Kayapó. As imagens Landsat-8 foram classificadas em quatro classes: Garimpo, Água, Vegetação e Desflorestado. A análise da classificação das áreas de garimpo revelou um aumento significativo da superfície ocupada dentro da TI Kayapó, com taxas de crescimento dos garimpos de 383% entre 2014 (20,57 km²) e 2023 (99,46 km²). Observa-se que nos intervalos de 2014 a 2016 houve pouco aumento das áreas de garimpo, enquanto entre 2016 e 2019 ocorreu aumento exponencial. Já no período entre os anos de 2019 e 2020, anos referente a pandemia, ocorreu aumento mais retraído. E nos períodos de 2021 e 2023, o crescimento voltou a ser exponencial. Nota-se, que esses padrões indicam uma forte correlação entre a expansão do garimpo e os eventos socioeconômicos e políticos ocorridos no período.

A expansão significativa do garimpo ilegal durante os últimos anos está em conformidade com os achados de estudos como o de Soares-Filho et al. (2020), que destacam o impacto da instabilidade política e do enfraquecimento das políticas públicas de preservação ambiental nas taxas de desmatamento e exploração mineral em áreas protegidas da Amazônia. A forte correlação entre mudanças nas políticas públicas e o aumento de atividades ilegais também é discutida por Fearnside (2021), que observa que a falta de fiscalização e os incentivos indiretos ao garimpo geram um ambiente propício para a expansão das atividades ilegais.

Em relação as demais classes, as relacionadas à supressão vegetal apresentaram um aumento em suas áreas, enquanto a classe vegetação apresentou declínio. A determinação da área da classe água foi desafiadora devido à alta confusão com a classe de garimpo. Isso se deve, em parte, à resolução média das imagens, que não permitiu distinguir adequadamente os canais dos rios devido à sua largura, além da similaridade na resposta espectral entre essas duas classes. Essa indefinição é explicada através do alto erro de omissão nessa classe. Por fim, esses resultados fornecem *insights* valiosos sobre a dinâmica do incremento das áreas de garimpo na TI Kayapó e

têm implicações importantes para a definição de estratégias de planejamento e monitoramento nesta região especialmente no que diz respeito ao aumento das atividades de garimpo e à supressão vegetal.

Implicações da heterogeneidade espacial dos garimpos na classificação

A heterogeneidade espacial dos garimpos apresenta um conjunto complexo de desafios para sua detecção eficaz, visto a alta variação de textura da superfície nesses ambientes (Giang et al., 2020). Essa heterogeneidade espacial, pode ser caracterizada por variações físicas, operacionais e ambientais, e assim, apresenta desafios significativos para a classificação e monitoramento adequado dessas áreas (Balaniuk et al., 2020). Diante dessa complexidade espacial, o monitoramento da expansão garimpeira é dito como estimativas de suas áreas, ou seja, o erro de omissão das classificações realizadas é moderado, tornando os resultados em estimativas e não em valores absolutos. O reflexo dos erros nas classes utilizadas, são esbarrados pela média resolução espacial das imagens utilizadas (Landsat-8, 30 m) (Adepoju & Adelabu, 2020).

Em razão da complexidade instaurada nas áreas de garimpo, consequência da sua heterogeneidade, os principais fenômenos que criam essa complexidade são a desnudação, manejo e acumulação do solo (Hosseinijanizadeh et al., 2023). Esses processos do garimpo geram consequências como: supressão vegetal, exposição do solo, áreas abandonadas de garimpo, ocasionando rebrota de vegetação e as criações de poças de mineração (Wang et al., 2023), essas formações ocorrem devido às operações de extração mineral, onde grandes quantidades de solo são removidas, criando depressões que se enchem de água (Chen et al., 2017). A Figura 7 apresenta os diferentes tipos de cobertura em uma área da TI Kayapó.



Figura 8. Garimpo ilegal na TI Kayapó
Fonte: ASCOM Polícia Federal do Brasil

Nesse contexto, diferentes técnicas como mineração aluvial ou de poço aberto, resultam em padrões de uso do solo distintos, exigindo abordagens de classificação adaptativas (Chen et al., 2017). A partir dessas diferentes técnicas de manejo empregadas no garimpo, a superfície se torna heterogênea (Figura 7), com isso os diferentes alvos trazem as imagens diferentes repostas espectrais, no sentido de um pixel de 30 por 30 m fazer a integralização da resposta de diferentes alvos. Essa heterogeneidade torna o mapeamento das áreas dificultoso, isso pode ser observado nos resultados de RMSE, os quais quando comparados aos produtos de classificação com imagens de maior resolução, o RSME tem valores elevados.

Entretanto, apesar da grande variedade de resposta espectral do garimpo, constatou-se um comportamento linear de crescimento das áreas de garimpo (Figura 6c), a qual apresenta crescimento de 2014 a 2023 (Scussel et al., 2024). Diante disso, inferimos que o garimpo, devido a sua resposta espectral ser bem distinta das classes circundantes, teve melhor identificação, principalmente nas áreas de lavras garimpeiras ativas. As lavras ativas são áreas com intensa atividade garimpeira que usam a água como principal agente de desagregação dos sedimentos a serem minerados, dessa forma o próprio recurso hídrico também é impactado (Leal et al., 2023).

Impactos socioambientais

Além dos impactos ambientais destacados pelo garimpo, a população indígena tem sua saúde afetada por conta de doenças relacionadas às atividades garimpeiras (Caldas et al., 2023). Estudos como de Pereira et al. (2021) e Caldas et al. (2023) destacam a concentração da malária em áreas de garimpo, considerando TI como as mais vulneráveis por conta do difícil acesso e pela localização que muitas vezes é distante de centros urbanos, onde ocorreria tratamento para essa doença.

Os impactos não ficam restritos apenas na superfície, mas alteram as características dos solos contribuindo para a inserção de metais pesados nos mesmos. Elementos como Cádmio (Cd), Arsênio (As) e Chumbo (Pb) são exemplos de metais pesados que ficam concentrados na superfície do solo e após o término da atividade garimpeira podem posteriormente contaminar espécies de vegetais em áreas próximas (Santos et al., 2016).

Implicações da resolução espacial na classificação dos garimpos.

Os testes realizados a priori aos resultados apresentados, nas imagens Sentinel-2 (10 m de resolução espacial), apresentaram maior confusão de classificação. Diante disso, podemos comparar os resultados de classificação das imagens Landsat-8 (30 m de resolução espacial) com as da Sentinel-2, sendo observado que a classificação Landsat-8

obteve os melhores resultados. É pensado que o aumento da resolução espacial, implicará em uma melhora na classificação, entretanto, a resposta espectral dos alvos é mais heterogênea devido ao aumento da resolução espacial (Kwak & Park, 2019).

O aumento da resolução espacial nas classificações de garimpo deve ser observado visto a sua paisagem ser heterogênea e apresentar dificuldades para sua classificação em termos de complexidade do desenvolvimento de conjuntos de dados de treinamento e validação (Pereira et al., 2024). Então, pode-se afirmar que devido à alta heterogeneidade espacial dos garimpos e sua diversificada resposta espectral dos alvos desse ambiente, o uso de sensores com alta resolução espacial deve ser utilizada para melhores resultados mais detalhados, porém com técnicas de classificação mais avançadas. Nesse sentido a média resolução é uma saída para classificação mais eficientes e simples (Radeloff et al., 2024).

Por tanto, para análises de expansão de áreas de garimpos, o uso de sensores de média resolução espacial são eficazes nessa determinação. Apesar da classificação não serem computadas com exatidão e precisão suficiente, pois garimpos são paisagens heterogêneas, já que é um desafio usando apenas imagens de satélite (Chen et al., 2021). Então, sensores de médias resolução espacial são uma boa ferramenta de estimativa de áreas nessas aplicações.

Com base nisso, além das amostras coletadas, o pré-processamento das imagens e os classificadores desempenham um papel crucial na melhor identificação da heterogeneidade dos pixels, permitindo assim a identificação das áreas de garimpo na TI (Doblas et al., 2022). Em municípios paraenses com presença de mineração, foram utilizadas imagens de drone para a validação da classificação das imagens de satélite, corroborando com os resultados do presente estudo, cujas áreas de garimpo apresentaram padrão não uniforme sendo caracterizadas por aglomerados de sedimentos e bancos de areia que modificam a paisagem local (Balieiro et al., 2015).

Implicações governamentais na expansão das áreas de garimpo na TI Kayapó.

As questões de legislação ambientais nos 10 anos analisados, foram flutuantes no sentido de enfraquecimento e fortalecimento do protecionismo ambiental. A partir de 2019, na troca de governo houve aumento de desflorestamento e ápice em 2021, conforme mostrado na Figura 5c e

na discussão apresentada do capítulo 4.3, em concordância com as análises de Silva Junior et al. (2020). Esses autores mostram que a taxa de desmatamento foi 5% maior em 2019 comparado ao ano anterior, assim pode-se inferir que a motivação de crescimento foi a percepção de enfraquecimento de proteção ambiental causado pelo governo corrente (Araújo & Campos, 2022). Logo, a atuação do Estado é fundamental para legitimar a atuação de garimpeiros e empresas mineradoras o que em alguns casos contribui para o reforço da desigualdade na região (Sousa & Mathis, 2023).

Notórias as conclusões de Leal et al. (2023), que destacam a relação entre os dados de monitoramento e as políticas governamentais que favorecem a intensificação de atividades ilegais em áreas da Amazônia.

A implementação de novos monitoramentos e a promoção de sistemas efetivos de controle de atividades ilegais podem ser fundamentais na reversão desses cenários. Concomitantemente, é importante fortalecer a fiscalização e as políticas públicas de preservação, além de incentivar a adoção de tecnologias de monitoramento em tempo real, como o uso de drones e sensores remotos, a fim de reduzir os impactos causados por essas atividades ilegais.

Anteriormente a esse evento de maior taxa de desflorestamento em TIs, 2014 registrou um dos menores anos de taxas de desmatamento registrado pelo Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (PRODES) (Silva Junior et al., 2020). Esse sistema detecta diminuição do desmatamento desde 2005 em TIs, e nos traz *insights* valiosos para o entendimento do aumento do desmatamento e consequentemente áreas de exploração de garimpo. O desmatamento em TIs na Amazônia está predominantemente relacionado a atividade garimpeira. Esses dados nos mostram o comprometimento em frear o desmatamento de forma geral atrelado ao fortalecimento de proteção ambiental (Rorato et al., 2022).

Após ao fim da gestão do governo comprometido ao protecionismo ambiental, em 2016 com a troca do governo, houve o retorno do crescimento do desmatamento em TIs até 2018. Isso é evidenciado e influenciado pelo descompromisso de pautas ambientais do governo

eleito em 2017, isto incentivou o aumento do desmatamento e de atividades de garimpo em TIs (Fernandes, 2022). E o registro do maior incremento em 2019, com a nova troca de gestão federal, o que ficou conhecido como o “*neoextrativismo*” ultraliberal marginal, o desmatamento foi elevado a níveis que não eram vistos desde o ano de 2008 (Moffette et al., 2021). As correntes de pensamentos diferentes em relação a proteção ambiental, estão relacionadas diretamente a expansão das áreas de garimpo e colocam em risco os direitos de comunidades indígenas (Villén-Pérez et al., 2020), estas por sua vez relacionadas ao desmatamento em TIs na Amazônia.

Conclusão

Este estudo analisou a expansão do garimpo ilegal em cinco áreas da Terra Indígena Kayapó no período de 2014 a 2023, utilizando técnicas de sensoriamento remoto para compreender a influência das políticas públicas e da dinâmica de governança na integridade dessas áreas.

Este estudo constata a expansão das áreas de garimpo na TI Kayapó. O uso do algoritmo Random Forest e das imagens Landsat-8 foi fundamental para identificar e mapear essas mudanças, com desempenho satisfatório, apesar de limitações como a resolução espacial das imagens e a falta de dados de campo para validação.

A análise temporal e espacial revelou um aumento em todas as regiões de garimpo detectadas em 2014 e nenhuma redução. A partir de 2018, houve aparecimento de novas áreas de garimpo, o que foi atribuído às novas medidas ambientais estabelecidas pelo governo em questão, ou até mesmo a liberdade imposta de forma não arbitrária e sim atribuídas aos próprios garimpeiros.

No mais, as questões de resolução espacial das imagens e coletas de amostras devem ser observadas no que diz respeito ao objetivo a se alcançar. Somado a isso, o cuidado com coleta de amostras para classificação deve ser proporcional a resolução espacial. Diante da heterogeneidade espacial dos garimpos, a classificação por sua vez gera estimativas que devem ser cuidadosamente observadas para, para evitar vieses na estimativa das áreas afetadas. Indicam-se alternativas de algoritmos de classificação, que conseguem lidar melhor com essa heterogeneidade, além de uso de imagens de resolução.

Finalmente, sugere-se uso de novas ferramentas de classificação, como a

supervisionada de máquina e técnicas baseadas em Geobias, para comparar e ter estimativas de áreas de garimpo mais assertivas e ultrapassando os problemas causados pela heterogeneidade dos garimpos. Outra problemática é a de uso de técnicas de pesquisa não empíricas para a relação dos aumentos do garimpo com implicações governamentais. Além disso, a validação com dados de campo e bases oficiais é necessária para obter métricas mais precisas, bem como as classificações. Nesse estudo a falta de bases para manchas de garimpo e recursos para coleta de dados em campo foi uma limitação, que pode causar vieses de supra ou sub mensuração das áreas de garimpo.

Este trabalho contribui significativamente para a compreensão das interações entre a expansão do garimpo ilegal, as mudanças na governança e os impactos ambientais na TI Kayapó. Os achados reforçam a importância de estratégias integradas que combinem fiscalização em campo com técnicas avançadas de sensoriamento remoto, além de políticas públicas que priorizem a proteção ambiental e as comunidades indígenas. Espera-se que as evidências apresentadas sirvam como subsídio para a formulação de ações mais eficazes no combate ao garimpo ilegal e na preservação das TIs.

Referências

- Adepoju, K. A., & Adelabu, S. A., 2020. Improving accuracy of Landsat-8 OLI classification using image composite and multisource data with Google Earth Engine. *Remote Sensing Letters* 11(2), 107–116.
- Agência Nacional de Mineração - ANM., 2024. Sistema de informações geográficas da mineração - SIGMINE. Disponível: <https://geo.anm.gov.br/portal/apps/webappviewer/index.html?id=6a8f5ccc4b6a4c2bba79759aa952d908>. Acesso: 12 set. 2024.
- Alvarenga, C. (2023). O garimpo ilegal na Amazônia e os impactos socioambientais enfrentados pelos povos originários. *Revista de Direitos Humanos e Efetividade*, 9(2). <https://doi.org/10.26668/IndexLawJournals/2526-0022/2023.v9i2.10001>
- Amaral, A. D. S., & Lopez, C. L., 2023. O triste sonho do Eldorado contemporâneo: o impacto do garimpo ilegal na Terra Indígena Kayapó – PA. *Revista Mutirão. Folhetim de Geografias Agrárias do Sul* 4(2), 17–39.

- <https://doi.org/10.51359/2675-3472.2023.258846>.
- Araújo, B., & Campos, F. S. S., 2022. Populismo Autoritário e Meio Ambiente no Brasil. *Media & Jornalismo* 22(40), 141–159. https://doi.org/10.14195/2183-5462_40_7.
- Balaniuk, R., Isupova, O., & Reece, S., 2020. Mining and Tailings Dam Detection in Satellite Imagery Using Deep Learning. *Sensors* 20(23), 6936. <https://doi.org/10.3390/S20236936>.
- Balieiro, P. C. P., Garcia, E., Santos, L. B., & Mallmann, G. M., 2015. Uso de imagens de alta resolução espacial na detecção de áreas de mineração na Amazônia brasileira. *Revista Brasileira de Geografia Física* 6397–6404.
- Brasil Escola. Garimpo no Brasil. Disponível: <https://brasilecola.uol.com.br/geografia/garimpo-brasil.htm>. Acesso: 12 set. 2024.
- Breiman, L., 2001. Random forests. *Machine Learning* 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Caldas, R. J. C., Nogueira, L. M. V., Rodrigues, I. L. A., Andrade, E. G. R. de, Costa, C. M. L., & Trindade, L. de N. M., 2023. Incidência de malária entre indígenas associada à presença de garimpos. *Revista Gaúcha de Enfermagem* 44. <https://doi.org/10.1590/1983-1447.2023.20220098>.
- Chai, T., & Draxler, R. R., 2014. Root mean square error (RMSE) or mean absolute error (MAE)? *Geoscientific Model Development* 7(3), 1247–1250. <https://doi.org/10.5194/GMD-7-1247-2014>.
- Chen, Y.; Peng, Z.; Ye, Y.; Jiang, X.; Lu, D.; Chen, E. Exploring a uniform procedure to map Eucalyptus plantations based on fused medium–high spatial resolution satellite images. *International Journal of Applied Earth Observation and Geoinformation*, vol. 103, p. 102462, 1 Dec. 2021. <https://doi.org/10.1016/J.JAG.2021.102462>.
- Chen, W., Li, X., He, H., & Wang, L., 2017. A Review of Fine-Scale Land Use and Land Cover Classification in Open-Pit Mining Areas by Remote Sensing Techniques. *Remote Sensing* 10(1), 15. <https://doi.org/10.3390/RS10010015>.
- Congalton, R. G., & Green, K., 2008. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices (2a ed.). CRC Press. <https://doi.org/10.1201/9781420055139>.
- Doblas, J., Reis, M. S., Belluzzo, A. P., Quadros, C. B., Moraes, D. R. V., Almeida, C. A., et al., 2022. DETER-R: An Operational Near-Real Time Tropical Forest Disturbance Warning System Based on Sentinel-1 Time Series Analysis. *Remote Sensing* 14(15), 3658. <https://doi.org/10.3390/RS14153658>.
- EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária, 2021. Latossolos Amarelos - Portal Embrapa. Disponível: <https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/solos-tropicais/sibcs/chave-do-sibcs/latossolos/latossolos-amarelos>. Acesso: 12 set. 2024.
- Fassoni-Andrade, A. C., & Paiva, R. C. D. de., 2019. Mapping spatial-temporal sediment dynamics of river-floodplains in the Amazon. *Remote Sensing of Environment* 221, 94–107. <https://doi.org/10.1016/J.RSE.2018.10.038>.
- Fernandes, R. M. S., 2022. A política mineral do governo Bolsonaro para a Amazônia Legal: Um balanço a partir dos processos minerários ativos. *AMBIENTES: Revista de Geografia e Ecologia Política* 4(2), 149–172. <https://doi.org/10.48075/AMB.V4I2.29781>.
- Gardner, J. R., Yang, X., Topp, S. N., Ross, M. R. V., Altenau, E. H., & Pavelsky, T. M., 2021. The Color of Rivers. *Geophysical Research Letters* 48(1), e2020GL088946. <https://doi.org/10.1029/2020GL088946>.
- Giang, T. L., Dang, K. B., Le, Q. T., Nguyen, V. G., Tong, S. S., & Pham, V. M., 2020. U-net convolutional networks for mining land cover classification based on high-resolution UAV imagery. *IEEE Access* 8, 186257–186273. <https://doi.org/10.1109/ACCESS.2020.3030112>.
- Hosseinjanizadeh, M., Khorasanipour, M., and Honarmand, M., 2023, Mapping mining waste and identification of acid mine drainage within an active mining area through sub-pixel analysis on OLI and Sentinel-2. *Earth Science Informatics*, v. 16, p. 3449–3467, doi:10.1007/S12145-023-01083-8/TABLES/4.
- Kimijima, S., Sakakibara, M., and Nagai, M., 2021, Detection of Artisanal and Small-Scale Gold Mining Activities and Their Transformation Using Earth Observation, Nighttime Light, and Precipitation Data: *International Journal of Environmental Research and Public Health* 2021, Vol. 18, Page 10954, v. 18, p. 10954, doi:10.3390/IJERPH182010954.
- Kwak, G. H., & Park, N. W., 2019. Impact of Texture Information on Crop Classification with Machine Learning and UAV Images. *Applied Sciences* 9(4), 643. <https://doi.org/10.3390/APP9040643>.
- Linares, S., André, M., Commings, J., Joubert, P., & Gond, V. (2024, November). The observatory of

- mining activities in French Guiana: 20 years of remote sensing applied to mining deforestation. In *XXI SIMPÓSIO INTERNACIONAL SELPER*. <https://hal.science/hal-04794636>
- Magodo, Z. J., & Dias, V. C. (2023). Contributo da polícia de proteção dos recursos naturais e meio ambiente no combate às actividades ilegais no Parque Nacional de Chimanimani. *ALBA-ISFIC Research and Science Journal*, 1(1), 52-64. <https://www.alba.ac.mz/index.php/alba/article/view/11>
- Marinho, R. R., & Ribeiro, D. F., 2023. Impactos do garimpo de ouro na bacia do Rio Amanã (AM-PA). *Revista Verde Grande: Geografia e Interdisciplinaridade* 5(02), 349–369. <https://doi.org/10.46551/RVG2675239520232349369>.
- Martins, A. M. M., Lourenço, P. M. S., da Silva, D. V. S., & Cruz, C. B. M. (2023). Mapeamento do uso e cobertura do solo do município de Saboeiro (CE) através de processamento na nuvem no GEE. <https://doi.org/10.51308/continentes.v1i22.410>
- Mataveli, G., Chaves, M., Guerrero, J., Escobar-Silva, E. V., Conceição, K., & de Oliveira, G. (2022). Mining is a growing threat within indigenous lands of the Brazilian Amazon. *Remote Sensing*, 14(16), 4092. <https://doi.org/10.3390/rs14164092>
- Mendes, J. F., & Martins, P. S. V. (2022). Entre genocídio e necropolítica: a luta pela vida dos povos indígenas e a mineração na Amazônia frente à pandemia da COVID-19.
- Menton, M., Milanez, F., Souza, J. M. de A., & Cruz, F. S. M., 2021. The COVID-19 pandemic intensified resource conflicts and indigenous resistance in Brazil. *World Development* 138, 105222. <https://doi.org/10.1016/J.WORLDDEV.2020.105222>.
- Moffette, F., Alix-Garcia, J., Shea, K., and Pickens, A.H., 2021, The impact of near-real-time deforestation alerts across the tropics: *Nature Climate Change* 2021 11:2, v. 11, p. 172–178, doi:10.1038/s41558-020-00956-w.
- Negreiro, L. L., da Silva, E. F., Calvi, M. F., Serra, A. B., de Moura Santos, A. H., dos Santos Silva, S. B., & Ferreira, F. S. (2024). Avaliação de mudanças de uso e cobertura da terra em território indígena na Amazônia brasileira. *Scientia Naturalis*, 6(1). <https://doi.org/10.29327/269504.6.1-10>
- Pereira, D. H. C., Gomes, R. A. T., Carvalho Júnior, O. A. De; Guimarães, R. F. Identificação de Garimpos de Ouro Embarcados por meio de Algoritmos de Classificação em Imagens Sentinel-2. *Sociedade & Natureza*, vol. 36, no. 1, p. e69409, 15 Apr. 2024. DOI 10.14393/SN-V36-2024-69409.
- Radeloff, V. C., Roy, D. P., Wulder, M. A., et al. "Need and vision for global medium-resolution Landsat and Sentinel-2 data products", *Remote Sensing of Environment*, v. 300, p. 113918, 1 jan. 2024. DOI: 10.1016/J.RSE.2023.113918.
- Rorato, A. C., Escada, M. I. S., Camara, G., et al., 2022. Environmental vulnerability assessment of Brazilian Amazon Indigenous Lands. *Environmental Science & Policy* 129, 19–36. <https://doi.org/10.1016/J.ENVSCI.2021.12.005>
- Santos, S. Dos, Pereira Pierangeli, M. A., et al., 2016. Teores de As, Cd e Pb em solos e sedimentos de áreas de garimpo de ouro. *Revista Brasileira de Geografia Física* 9(6), 1805–1814. <https://doi.org/10.26848/RBGF.V9.6.P1805-1814>.
- Scussel, C., de Lima, S.C., Mendes, A.L. de M., Santander, M.B., Ferreira, A.T. da S., Zocche, J.J., Grohmann, C.H., and Quintanilha, J.A., 2024, Dinâmica espaço-temporal na cobertura e uso da terra em uma bacia hidrográfica no sul do Brasil: análise baseada em sensoriamento remoto e big data: *Revista de Geociências do Nordeste*, v. 10, p. 124–137, doi:10.21680/2447-3359.2024V10N1ID34886.
- Silva Junior, C. H. L., et al., 2020. The Brazilian Amazon deforestation rate in 2020 is the greatest of the decade. *Nature Ecology & Evolution* 5(2), 144–145. <https://doi.org/10.1038/s41559-020-01368-x>.
- Siqueira-Gay, J., Soares-Filho, B., et al., 2020. Proposed Legislation to Mine Brazil's Indigenous Lands Will Threaten Amazon Forests. *One Earth* 3(3), 356–362. <https://doi.org/10.1016/J.ONEEAR.2020.08.008>.
- Silva-Junior, C. H., Silva, F. B., Arisi, B. M., Mataveli, G., Pessôa, A. C., Carvalho, N. S., ... & Melo, M. (2023). Brazilian Amazon indigenous territories under deforestation pressure. *Scientific Reports*, 13(1), 5851. <https://www.nature.com/articles/s41598-023-32746-7>
- Villén-Pérez, S., Anaya-Valenzuela, L., da Cruz, D. C., & Fearnside, P. M. (2022). Mining threatens isolated indigenous peoples in the Brazilian Amazon. *Global Environmental Change*, 72, 102398.

<https://doi.org/10.1016/j.gloenvcha.2021.102398>

Wanderley, L. J., Gonçalves, R. J. de A. F., & Milanez, B., 2020. O interesse é no minério: o neoextrativismo ultraliberal marginal. *Revista da ANPEGE* 16(29), 555–599. <https://doi.org/10.5418/RA2020.V16I29.12457>.

Wang, B., Li, P., & Zhu, X., 2023. Quantification of Vegetation Phenological Disturbance Characteristics in Open-Pit Coal Mines. *Remote Sensing* 15(1), 258. <https://doi.org/10.3390/RS15010258>.

Yang, L., Driscoll, J., Sarigai, S., Wu, Q., Chen, H., & Lippitt, C. D., 2022. Google Earth Engine and Artificial Intelligence (AI): A Comprehensive Review. *Remote Sensing* 14(14), 3253. <https://doi.org/10.3390/RS14143253>.

Zhou, L., Luo, T., Du, M., Chen, Q., Liu, Y., Zhu, Y., He, C., Wang, S., & Yang, K., 2021. Machine Learning Comparison and Parameter Setting Methods for the Detection of Dump Sites for Construction and Demolition Waste Using the Google Earth Engine. *Remote Sensing* 13(4), 787. <https://doi.org/10.3390/RS13040787>.