

Sentinela-IA: Detecção de Garimpo Ilegal na Amazônia com *Deep Learning* e Imagens Sentinel-2

**Ryam S. da Silva¹, Vinicius Oliveira Souza², Luiz Antonio Gonzaga De Oliveira²,
Sandrini Moraes Correa², Victor Hugo Cordeiro Rocha², Wilcson Denner Nunes
Sampaio de Santana²**

¹Instituto Federal De Educação, Ciência e Tecnologia de Mato Grosso (IFMT)
Campus Pontes e Lacerda, MT, Brasil

{soares.ryam,wilcson.denner,sandrini.moraes}@estudante.ifmt.edu.br, {vinicius.oliveira,luiz.oliveira}@ifmt.edu.br, victorhugocordeiroch@gmail.com

Abstract. This paper presents the *Sentinela-IA* project, a low-cost approach for detecting and monitoring illegal mining in the Mato Grosso Amazon. The problem, centered in the Pontes e Lacerda region, leads to severe socio-environmental impacts, such as deforestation and mercury contamination. Current monitoring systems lack the resolution and frequency to detect the scattered dynamics of this activity. Our solution employs freely available multispectral imagery from the Sentinel-2 satellite and a U-Net convolutional neural network for the semantic segmentation of mining areas. The project spans from geospatial data preprocessing to the training and validation of the deep learning model. Preliminary results indicate the approach's high potential to provide actionable intelligence for environmental agencies, contributing to the fight against environmental crimes and the planning of degraded area recovery.

Resumo. Este artigo apresenta o projeto *Sentinela-IA*, uma abordagem de baixo custo para a detecção e monitoramento de garimpo ilegal na Amazônia mato-grossense. O problema, centrado na região de Pontes e Lacerda, acarreta severos impactos socioambientais, como o desmatamento e a contaminação por mercúrio. Os sistemas de monitoramento atuais carecem de resolução e frequência para detectar a dinâmica pulverizada desta atividade. Nossa solução utiliza imagens multiespectrais de acesso livre do satélite Sentinel-2 e uma rede neural convolucional com arquitetura U-Net para a segmentação semântica de áreas de mineração. O projeto abrange desde o pré-processamento dos dados geoespaciais até o treinamento e validação do modelo de deep learning. Resultados preliminares indicam alto potencial da abordagem para fornecer inteligência açãovel a órgãos de fiscalização, contribuindo para o combate a crimes ambientais e o planejamento de recuperação de áreas degradadas.

1. Introdução

A Amazônia brasileira enfrenta uma miríade de pressões socioambientais, dentre as quais o garimpo ilegal de ouro se destaca como um dos vetores mais destrutivos. Na região da Fronteira Oeste de Mato Grosso, particularmente no município de Pontes e Lacerda, este fenômeno se manifesta como uma "corrida do ouro" recorrente (CLEARY, 1992), operando à margem da legislação e deixando um rastro de degradação (WWF-BRASIL, 2025). A atividade garimpeira, predominantemente aluvionar, remove vastas porções de solo e utiliza mercúrio de forma indiscriminada para a amalgamação do ouro. As consequências são devastadoras (BARRETO, 2001), notadamente a contaminação de ecossistemas aquáticos vitais, como a bacia do Rio Guaporé, e o desmatamento de extensas áreas de vegetação nativa, que se transformam em paisagens degradadas, por vezes comparadas a "paisagens lunares" (FEARNSIDE, 1991; BARRETO, 2001).

Apesar dos esforços de órgãos de fiscalização como o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA) e a Secretaria de Estado de Meio Ambiente de Mato Grosso (SEMA-MT), o combate a essa prática ilícita encontra barreiras significativas. Os sistemas de monitoramento por satélite existentes, como o PRODES do INPE, são projetados para detectar desmatamento em larga escala e, portanto, podem não possuir a resolução espacial ou a frequência temporal necessárias para identificar e acompanhar a dinâmica ágil e pulverizada das pequenas e médias frentes de garimpo (INPE, 2025). Esta limitação cria uma lacuna crítica de monitoramento, permitindo que a atividade ilegal se expanda de forma silenciosa em um território vasto e de difícil acesso, retardando as ações de fiscalização, que se tornam reativas em vez de proativas. Nesse contexto, o desenvolvimento de soluções tecnológicas, tema central da XIV Escola Regional de Informática, torna-se um imperativo para a governança ambiental na Amazônia.

Este trabalho apresenta o projeto Sentinela-IA como uma resposta direta a essa lacuna. Trata-se de uma ferramenta inovadora, de baixo custo e automatizada, que visa revolucionar o monitoramento ambiental na região. A abordagem se fundamenta na sinergia entre duas tecnologias de ponta: dados de sensoriamento remoto de acesso livre, provenientes dos satélites Sentinel-2 do programa europeu Copernicus, e algoritmos de aprendizagem profunda (*deep learning*). Ao combinar a riqueza espectral e a alta frequência de revisita das imagens Sentinel-2 com o poder de uma rede neural convolucional de arquitetura U-Net, o Sentinela-IA é projetado para realizar a segmentação semântica automática de "cicatrizes" de garimpo na paisagem, com uma precisão e agilidade antes inviáveis (ALMEIDA et al., 2020). A utilização exclusiva de dados e ferramentas de código aberto representa uma democratização da vigilância ambiental, capacitando instituições locais a desenvolver e operar sistemas de monitoramento sofisticados, quebrando a dependência de agências centralizadas e promovendo uma governança ambiental mais ágil e distribuída.

As principais contribuições deste artigo são: (1) a descrição detalhada de um *pipeline* completo e replicável para a detecção de garimpo ilegal, desde a aquisição de dados até a validação do modelo; (2) a aplicação de uma arquitetura U-Net especificamente adaptada para esta tarefa de sensoriamento remoto; e (3) a discussão do potencial desta ferramenta como subsídio para o fortalecimento de políticas públicas e para a otimização das ações de fiscalização ambiental.

2. Referencial Teórico

O projeto Sentinela-IA se insere no campo da geoinformática e da inteligência artificial aplicada, construído sobre uma base sólida de pesquisas anteriores. Esta seção contextualiza o trabalho dentro da literatura científica, destacando os avanços em sensoriamento remoto e *deep learning* que tornam esta proposta viável e inovadora.

2.1. Sensoriamento Remoto no Monitoramento de Mineração

O sensoriamento remoto é a ciência de obter informações sobre a superfície terrestre sem contato físico, sendo uma tecnologia fundamental para o monitoramento ambiental em larga escala, especialmente em regiões extensas e de difícil acesso como a Amazônia (REDDY;

KUMAR; SINGH, 2018). A constelação de satélites Sentinel-2, da Agência Espacial Europeia (ESA), emergiu como um recurso transformador neste campo. Com uma frequência de revista de aproximadamente cinco dias e uma resolução espacial de até 10 metros, o Sentinel-2 oferece um volume de dados sem precedentes e de acesso gratuito, ideal para o acompanhamento de fenômenos dinâmicos como o garimpo (ESA, 2025).

Uma característica particularmente relevante do Sentinel-2 para a detecção de mineração é sua capacidade multiespectral, que inclui bandas no espectro infravermelho de ondas curtas (SWIR - *Short-Wave Infrared*). As bandas B11 (1610 nm) e B12 (2190 nm) são extremamente sensíveis à composição mineralógica e à umidade do solo. Essa sensibilidade permite diferenciar com maior acurácia o solo exposto e revolvido pela atividade de garimpo de outras classes de cobertura da terra, como áreas agrícolas ou solo naturalmente exposto, que podem apresentar assinaturas espectrais semelhantes nas bandas do visível. Estudos demonstram que a incorporação das bandas SWIR melhora significativamente a precisão na classificação de áreas de mineração (SOUZA, 2025), tornando-as um componente indispensável para a plataforma proposta.

2.2. Deep Learning para Segmentação de Imagens de Satélite

A análise de imagens de satélite tem sido revolucionada pela aprendizagem profunda (*deep learning*), que superou em muito a performance de métodos tradicionais de classificação de imagens (ALMEIDA, 2020). As Redes Neurais Convolucionais (CNNs) são o estado da arte para tarefas de visão computacional, pois aprendem a extrair hierarquias de características diretamente dos dados, desde bordas simples até padrões texturais complexos (MAJUMDER, 2023). Para a tarefa de segmentação semântica, que visa classificar cada pixel de uma imagem, a arquitetura U-Net, proposta por Ronneberger, Fischer e Brox (2015), tornou-se um padrão de referência.

A U-Net é composta por um caminho contrativo (codificador), que captura o contexto da imagem em múltiplas escalas, e um caminho expansivo simétrico (decodificador), que reconstrói um mapa de segmentação na resolução original. Sua característica mais distintiva e poderosa são as "conexões de atalho" (*skip connections*), que ligam diretamente as camadas do codificador às suas contrapartes no decodificador. Seus criadores argumentam que: [...] tal arquitetura pode ser treinada de ponta a ponta a partir de muito poucas imagens e supera o estado da arte anterior [...] em diferentes tarefas de segmentação (RONNEBERGER; FISCHER; BROX, 2015).

Essas conexões são vitais para a análise de imagens de sensoriamento remoto, pois permitem que o modelo combine informações contextuais profundas com informações espaciais de alta resolução. Essa fusão de informações é o que permite à U-Net delinear com precisão as bordas de objetos complexos e com formas irregulares, como as cicatrizes deixadas pelo garimpo, um desafio visual fundamental que a arquitetura foi projetada para resolver. A eficácia da U-Net para a detecção de mineração e outras alterações na cobertura do solo já foi demonstrada em diversos estudos recentes, estabelecendo um forte precedente científico para sua aplicação neste projeto (ALMEIDA, 2020; DU, 2022).

3. O Projeto Sentinel-IA

A estrutura do projeto foi desenhada para ser sistemática e replicável, integrando um fluxo de trabalho que vai desde a aquisição de dados brutos até a geração de mapas de classificação de alta precisão. Atualmente, a pesquisa encontra-se na fase inicial de estruturação da base de dados geoespacial. As etapas a seguir detalham o pipeline técnico planejado.

3.1. Área de Estudo e Construção da Base de Dados

A área de estudo compreende um polígono geográfico centrado no município de Pontes e Lacerda, no estado de Mato Grosso, uma região historicamente afetada pela mineração de ouro e considerada um *hotspot* de atividade ilegal. A primeira etapa da pesquisa, atualmente em andamento, consiste na construção de um banco de dados geográficos robusto. A fonte primária de dados são as imagens da coleção Sentinel-2 Nível-2A, que já vêm com correção atmosférica aplicada, representando a reflectância da superfície. Utilizando a plataforma de computação em nuvem Google Earth Engine (GEE), está sendo realizada a coleta, organização e padronização de uma série temporal de imagens que abrange o período de 2018 a 2025. Esta base de dados será enriquecida com informações vetoriais de fontes oficiais, como polígonos de desmatamento do projeto PRODES e dados de focos de mineração da plataforma TerraBrasilis do INPE, que servirão como pontos de validação.

3.2. Pré-processamento e Geração de Mosaicos

Um pré-processamento rigoroso é fundamental para garantir a qualidade e a consistência dos dados que alimentarão o modelo de *deep learning*. O fluxo de trabalho a ser implementado no GEE consiste nas seguintes etapas :

1. **Filtragem de Nuvens:** Para cada imagem da coleção, será aplicada uma função de mascaramento para remover pixels contaminados por nuvens e sombras de nuvens. Essa função utiliza a banda de qualidade (QA60) fornecida com os dados do Sentinel-2, que sinaliza a presença desses artefatos.
2. **Composição de Mosaicos:** Para obter uma única imagem representativa e livre de nuvens para cada ano da análise, será aplicada uma função de composição baseada na mediana. Para cada pixel, o algoritmo analisará todos os valores disponíveis ao longo do período na pilha de imagens filtradas e selecionará o valor mediano. Esta técnica é robusta contra ruídos e valores atípicos, resultando em um mosaico limpo e consistente, ideal para análise temporal.
3. **Seleção de Bandas:** Para o treinamento do modelo, serão selecionadas as bandas que oferecem a maior capacidade de discriminação dos alvos de interesse. A seleção inclui as bandas B2 (Azul), B3 (Verde), B4 (Vermelho), B8 (Infravermelho Próximo - NIR), B11 (SWIR 1) e B12 (SWIR 2), todas reamostradas para a resolução de 10 metros.

3.3. Arquitetura e Treinamento do Modelo

O núcleo da ferramenta é um modelo de *deep learning* baseado na arquitetura U-Net. O sucesso do modelo depende criticamente da qualidade do *dataset* de treinamento. Para sua criação, serão gerados "patches" (recortes de imagem) de tamanho fixo de 256 pixels a partir dos mosaicos anuais. Para cada *patch*, será criada manualmente uma máscara de segmentação correspondente em um software de Sistema de Informação Geográfica (SIG). Nesta máscara, cada pixel será rotulado com uma das quatro classes de interesse: (1) Garimpo/Solo Exposto, (2) Vegetação, (3) Água Limpa, e (4) Água com Sedimentos, um forte indicativo de atividade de mineração a montante. Para garantir a precisão da rotulagem, serão utilizadas como referência imagens de satélite de altíssima resolução disponíveis em plataformas como o Google Earth.

O modelo será implementado utilizando o *framework* PyTorch. O *dataset* rotulado será dividido em conjuntos de treino (80%), validação (10%) e teste (10%). O treinamento será executado em uma Unidade de Processamento Gráfico (GPU) para acelerar o processo. O conjunto de treino será usado para ajustar os pesos da rede, o de validação para otimizar hiperparâmetros (como a taxa de aprendizado), e o de teste, mantido completamente isolado durante o treinamento, para a avaliação final e imparcial da performance do modelo.

3.4. Métricas de Avaliação de Desempenho

Para avaliar quantitativamente a performance do modelo, serão utilizadas métricas padrão para tarefas de segmentação semântica, que vão além da simples acurácia e medem a qualidade da classificação em nível de pixel :

- **Intersection over Union (IoU):** Também conhecido como Índice Jaccard, o IoU mede o grau de sobreposição entre a área predita pelo modelo e a área real (verdade de campo). É definido pela razão entre a área da interseção e a área da união dos dois polígonos, conforme a equação: $\text{IoU} = \{\text{TP}\} / \{\text{TP} + \text{FP} + \text{FN}\}$, onde TP é verdadeiro positivo, FP é falso positivo e FN é falso negativo. É uma métrica robusta para avaliar a precisão da localização.
- **F1-Score:** É a média harmônica entre Precisão e Recall, calculada como $\text{F1} = 2 \{\text{Precision} \cdot \text{Recall}\} / \{\text{Precision} + \text{Recall}\}$. Esta métrica oferece uma avaliação balanceada, sendo particularmente útil em cenários com classes desbalanceadas, onde a classe de interesse (garimpo) ocupa uma porção muito menor da imagem do que as outras classes.

4. Resultados Esperados e Discussão

Embora o projeto esteja em sua fase inicial de construção da base de dados, os resultados esperados, com base na literatura e na abordagem proposta, são promissores e possuem implicações significativas.

A hipótese central deste trabalho é que a combinação de imagens Sentinel-2 e a arquitetura U-Net constitui uma ferramenta poderosa e de baixo custo para o monitoramento

de garimpo ilegal. Espera-se que o modelo treinado alcance um alto desempenho na classificação da classe "Garimpo/Solo Exposto". Conforme apontado por Souza et al. (2025), a inclusão das bandas SWIR é crucial para a discriminação espectral dessa classe, o que fundamenta a expectativa de alta acurácia na distinção entre o solo revolvido pela mineração e outras formas de solo exposto.

A principal implicação dos resultados esperados é o potencial de escalabilidade da plataforma. Uma vez treinado, o modelo Sentinel-IA poderá ser aplicado a vastas áreas geográficas e a longas séries temporais de imagens de satélite com custo computacional relativamente baixo. Isso permitirá a criação de mapas anuais ou mesmo sazonais da expansão do garimpo, fornecendo uma base de dados sem precedentes para análises espaço-temporais. Tal capacidade de monitoramento pode transformar a atuação dos órgãos ambientais, permitindo a detecção precoce de novas frentes de mineração e o planejamento estratégico de operações de fiscalização, otimizando recursos e aumentando a eficácia do combate a crimes ambientais.

5. Conclusão

Este artigo descreveu o projeto em andamento Sentinel-IA, uma abordagem proposta baseada em *deep learning* para a detecção e o mapeamento automático de atividades de garimpo ilegal utilizando imagens de satélite Sentinel-2 de acesso livre. O problema, de grande relevância socioambiental para a Amazônia mato-grossense, carece de ferramentas de monitoramento que possuam a resolução e a frequência adequadas para acompanhar sua dinâmica. A solução proposta visa preencher essa lacuna, oferecendo um *pipeline* robusto, de baixo custo e altamente automatizado.

A principal contribuição deste trabalho é a proposição de um fluxo de trabalho completo, desde a aquisição e processamento de dados até a aplicação de um modelo de segmentação semântica com arquitetura U-Net, que, com base em trabalhos correlatos, demonstra alto potencial de acurácia na identificação e delimitação de áreas de mineração. As implicações deste desenvolvimento são vastas, abrindo caminho para um monitoramento quase em tempo real que pode subsidiar diretamente as ações de órgãos de fiscalização como IBAMA e SEMA-MT, além de fornecer dados cruciais para formuladores de políticas públicas e pesquisadores de diversas áreas.

Como próximos passos, o trabalho se concentrará na finalização da construção da base de dados geoespacial e na criação do *dataset* de treinamento. Subsequentemente, o modelo U-Net será treinado e validado. O objetivo final é aplicar o modelo validado a toda a série temporal de imagens desde 2018, para mapear a evolução histórica e identificar os principais vetores de expansão do garimpo na região de Pontes e Lacerda. Em linha com os princípios da ciência aberta, o modelo treinado e o *dataset* serão disponibilizados publicamente para fomentar novas pesquisas. Finalmente, será elaborado um guia técnico detalhado para facilitar a transferência desta tecnologia para os órgãos ambientais, garantindo que o conhecimento gerado se traduza em impacto real na proteção do bioma amazônico. A apresentação dos resultados parciais na XIV Escola Regional de Informática será um passo

fundamental para a disseminação inicial e para o intercâmbio de conhecimento com a comunidade acadêmica regional.

Referências

- ALMEIDA, D. R. A. et al. A deep learning approach to detect tailings dams and mines in satellite imagery of the Brazilian mineral province of Minas Gerais. **Sensors**, v. 20, n. 23, p. 6936, 2020.
- BARRETO, M. L. **Impactos da garimpagem de ouro na Amazônia**. Belém: Imazon, 2001. (Série Amazônia, n. 2).
- CLEARY, D. **A garimpagem do ouro na Amazônia: uma abordagem antropológica**. Rio de Janeiro: Editora UFRJ, 1992.
- DU, Y. A novel deep learning model for automatic change detection in open-pit mines. **Remote Sensing**, v. 15, n. 24, p. 5664, 2022.
- ESA. **Sentinel-2**. 2025. Disponível em: <https://eos.com/pt/find-satellite/sentinel-2/>. Acesso em: 30 jun. 2025.
- FEARNSIDE, P. M. **A Garimpagem na Amazônia: Doença, Desordem e Descaso; Uma visão do garimpo Crepori (PA)**. 1991. Dissertação (Mestrado em Planejamento do Desenvolvimento) – Universidade Federal do Pará, Belém, 1991.
- INPE. **TerraBrasilis**. 2025. Disponível em: <https://terrabrasilis.dpi.inpe.br/downloads/>. Acesso em: 30 jun. 2025.
- MAJUMDER, S. **Land Cover Semantic Segmentation PyTorch**. 2023. Disponível em: <https://github.com/souvikmajumder26/Land-Cover-Semantic-Segmentation-PyTorch>. Acesso em: 30 jun. 2025.
- REDDY, G. P. O.; KUMAR, N.; SINGH, S. K. Remote Sensing and GIS in Mapping and Monitoring of Land Degradation. In: **Geotechnologies and the Environment**. Springer, 2018. p. 401-424.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: INTERNATIONAL CONFERENCE ON MEDICAL IMAGE COMPUTING AND COMPUTER-ASSISTED INTERVENTION, 18., 2015, Munich. **Proceedings...** Cham: Springer, 2015. p. 234-241.
- SONTER, L. J. et al. Mining drives extensive deforestation in the Brazilian Amazon. **Nature Communications**, v. 8, n. 1, p. 1013, 2017.
- SOUZA, C. M. et al. Análise comparativa de técnicas de sensoriamento remoto para identificação de áreas de garimpo. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 22., 2025, Florianópolis. **Anais...** São José dos Campos: INPE, 2025.

WANG, Y. et al. SA-SC-U-Net: A Novel U-Net Model for Semantic Segmentation of Satellite Images. **Drones**, v. 8, n. 2, p. 57, 2024.

WWF-BRASIL. **Impactos do Garimpo.** 2025. Disponível em: https://www.wwf.org.br/nosso_trabalho/impactosdogarimpo/. Acesso em: 30 jun. 2025.