

Detecção de Erosão em Infraestruturas Elétricas por meio de AI e Imagens de Satélite

Tema: Gestão Ativos e Manutenção

Autores: Jhon Majin Erazo

Co-Autores: Carlos Antonio Alves, Jorge Benitez Caceres, Jose Duenas Salazar, Paulo Martinez Piratelo, Santiago Piovesan, Mateus Andre Favretto, Flavio Oliveira Barbosa, Paulo Violada, Wesley dos Santos Marinho, Carlos Nascimento, Lucas Souza, Antonio Donadon

Empresa: Instituto SENAI de Inovação em Sistemas Embarcados FIESC - SENAI/SC

Resumo

A erosão do solo é um dos principais riscos naturais globais, com impactos significativos em diversos setores econômicos, especialmente no setor elétrico. Os custos elevados associados à manutenção de infraestruturas afetadas pela erosão representam um grande desafio econômico. Para minimizar essas perdas, é crucial identificar e monitorar a erosão em larga escala, espacial e temporal. Este artigo apresenta resultados do estudo que integrou o modelo USLE, utilizado para gerar mapas de erodibilidade, com a detecção de erosão por meio do modelo Mask R-CNN, empregando imagens de satélites. A USLE foi aplicada para criar mapas de suscetibilidade à erosão, considerando fatores como topografia, precipitação, uso do solo e cobertura vegetal, enquanto o modelo Mask R-CNN foi utilizado para segmentar instâncias de áreas afetadas por erosão. A combinação dessas duas abordagens oferece uma solução robusta, escalável e eficiente, com potencial para aplicações tanto industriais quanto ambientais, permitindo a priorização de intervenções e a mitigação de riscos.

1. Introdução

A erosão do solo é um dos mais graves desafios ambientais da atualidade, com impactos profundos sobre a segurança alimentar, a sustentabilidade dos ecossistemas e a economia global. Os prejuízos econômicos decorrentes da erosão são substanciais, por exemplo, no setor elétrico, a erosão representa uma grave ameaça à infraestrutura de energia elétrica.

As linhas aéreas desempenham um papel crucial no fornecimento de energia elétrica, mas sua infraestrutura está frequentemente exposta a riscos ambientais, como a erosão do solo. Esses riscos podem comprometer a estabilidade das torres de transmissão, podendo levar a falhas estruturais, interrupções no fornecimento de energia e elevados custos de manutenção.

Apesar da relevância do problema, poucos estudos têm abordado de forma abrangente a identificação de áreas de erosão e solo exposto em grande escala, especialmente para o setor elétrico ou com periodicidade relevante utilizando modelos DL (do inglês, Deep Learning), e aqueles que o fazem, apenas apresentam uma solução mas não existe uma aplicação real da mesma (Gafurov & Yermolaev, 2020; Gafurov, 2022; Nogueira et al., 2020).

O sensoriamento remoto, por meio de imagens de satélite, oferece uma solução escalável para monitorar grandes áreas e obter dados periódicos sobre as mudanças na superfície terrestre. Combinando essa tecnologia com inteligência artificial (IA), especificamente Redes Neurais Convolucionais (CNNs), é possível automatizar e otimizar a detecção de áreas afetadas pela erosão. Por outro lado, de forma complementar, a Equação Universal de Perdas do Solo (USLE) permite a geração de mapas detalhados de suscetibilidade à erosão, integrando fatores como precipitação, uso do solo, vegetação e topografia.

Nesse contexto, a integração da predição do modelo Mask R-CNN baseado em CNNs e a informação gerada por mapas de erodibilidade com o modelo USLE representa uma abordagem inovadora e vantajosa para identificar e mitigar esses riscos de forma eficiente. Além de segmentar com precisão as áreas já afetadas, uma plataforma computacional foi desenvolvida para gerar mapas de suscetibilidade que permitem intervenções preventivas, com custos de reparos inferiores do que intervenções corretivas em emergência. Essa integração não apenas otimiza o monitoramento, mas também oferece um suporte valioso para o planejamento urbano, a proteção ambiental e a priorização de investimentos em infraestrutura em diversos setores da economia.

2. Desenvolvimento

Esta seção descreve os materiais e métodos utilizados na elaboração deste projeto de P&D Aneel Cemig e SENAI-SC. Primeiramente, apresenta-se o modelo de segmentação Mask R-CNN, baseado em CNNs, empregado para a detecção de áreas de erosão, juntamente com o conjunto de dados utilizado e os resultados obtidos. Em seguida, detalha-se a metodologia aplicada para a construção do mapa de erodibilidade utilizando o modelo USLE. Por fim, é apresentada uma análise comparativa entre os resultados obtidos pelo modelo Mask R-CNN e o mapa de erodibilidade gerado com base no USLE, permitindo avaliar a eficácia e complementaridade de ambas abordagens.

1. Arquitetura Mask R-CNN

Com base em estudos prévios e no estado da arte, a Mask R-CNN demonstrou capacidades avançadas de segmentação de objetos em diversos contextos, destacando-se pela habilidade de considerar características como formas, tamanhos diversos e texturas de maneira eficiente e precisa.

A Mask R-CNN é uma arquitetura desenvolvida para tarefas de detecção de objetos e segmentação de instâncias em diferentes contextos, sendo eficaz em aplicações que demandam alta precisão na segmentação de pequenos objetos. Normalmente, a Mask R-CNN utiliza um backbone ResNet para extrair características das imagens digitais de entrada em diversos níveis de abstração. Essa abordagem hierárquica permite ao modelo capturar diferentes padrões complexos e contextuais. O modelo utiliza uma Region Proposal Network (RPN) para identificar regiões de interesse na imagem que provavelmente contêm objetos.

O processo completo da Mask R-CNN gera duas saídas principais: 1) Detecção de objetos: inclui a classificação dos objetos e a localização por meio de bounding box. 2) Segmentação de instâncias: produz máscaras binárias para cada objeto detectado, representando com alta precisão seus contornos.

A Figura 1 apresenta a arquitetura da Mask R-CNN, mostrando o fluxo de processamento que se inicia com a entrada da imagem, representada como um tensor, e culmina nas duas saídas de detecção e segmentação. Essa combinação de funcionalidades em uma única arquitetura proporciona maior robustez e versatilidade, consolidando a Mask R-CNN como uma solução amplamente adotada em tarefas avançadas de visão computacional.




Figura 1 - *Arquitetura da Mask R-CNN.*

1.1 Dados para treinamento dos modelos baseados em CNNs

Para este projeto, foi utilizado um conjunto de imagens satelitais, ou tiles, fornecidos pela plataforma PlanetScope (BaseMaps). As imagens foram coletadas em diversas regiões do estado de Minas Gerais, Brasil, previamente identificadas como áreas com alta probabilidade de conter erosão e solo exposto. As imagens apresentam características distintas, abrangendo regiões com diferentes geometrias e contextos, incluindo vegetação alta e baixa, lavouras, áreas residenciais e estradas de terra.

Cada imagem satelital possui dimensões de 4096×4096 pixels e contém 4 bandas espectrais: R, G, B e NIR, todas adquiridas com uma resolução espacial de 5 metros/pixel. Foram utilizadas 28 imagens satelitais no total, que passaram por um processo de pré-tratamento envolvendo algoritmos de recorte e normalização. Inicialmente, as imagens foram cortadas em patches menores com dimensões de 512×512 pixels. Em seguida, as bandas espectrais foram normalizadas no intervalo de 0 a 255. Como resultado, foi construído um conjunto de dados composto por 1385 patches, cada um contendo 4 componentes espectrais organizadas em matrizes de dimensões $[512 \times 512 \times 4]$.

Foi realizado um processo de anotação manual por um especialista, que inspecionou cada uma das imagens para identificar e marcar as regiões com presença de erosão. A Figura 2 apresenta um exemplo de alguns dos rótulos gerados, nos quais as classes erosão (representada pela cor branca) e background (representado pela cor preta).




Figura 2 - Exemplo dos rótulos criados para detecção de erosão. (a) Imagem RGB; (b) Máscara binária.

1.2 Treinamento do modelo Mask R-CNN

Como foi mencionado anteriormente, neste projeto se utiliza um modelo de segmentação baseado em CNNs para detectar erosões próximas a torres de transmissão de energia elétrica.

Nesta etapa, foram utilizadas as bibliotecas TensorFlow e PyTorch para a implementação e o treinamento do modelo Mask R-CNN. Para otimizar o aprendizado dos modelos no novo contexto de identificação de erosão, foi empregada a técnica de transfer learning. Nesse processo, os pesos pré-treinados no ImageNet foram utilizados como ponto de partida para o treinamento, permitindo uma melhor adaptação dos modelos às características específicas do conjunto de dados de referência. Além disso, foi aplicado um conjunto de técnicas de aumento de dados para enriquecer a variabilidade do conjunto de treinamento. Entre as estratégias empregadas, destacam-se: inversão vertical, inversão horizontal, variações de escala e alterações de brilho (SHORTEN; KHOSHGOFTAAR, 2019).

O modelo Mask R-CNN foi treinado com a seguinte configuração: o conjunto de dados foi dividido em três partes principais, sendo 70% (964 imagens) destinadas ao treinamento, 20% (241 imagens) para validação e 10% (180 imagens) para teste.

Para evitar problemas de overfitting, foi aplicada a técnica de early stopping, que interrompe o treinamento automaticamente quando o desempenho do modelo na validação começa a se deteriorar. Além disso, foi utilizada uma taxa de aprendizado de 0.0005, combinada com o otimizador Adam (PRECHT, 1998).

O modelo Mask R-CNN se caracteriza por apresentar duas saídas: a detecção de objetos que delimita um retângulo ao redor da região com erosão e a segmentação de instâncias que cria uma máscara individual

por cada região com erosão. Nesse sentido, a Figura 3 apresenta três exemplos de detecção de erosão em diferentes imagens de teste. Observa-se que o modelo é capaz de gerar máscaras precisas para cada região de erosão, independentemente da época em que a imagem satelital foi capturada, seja no inverno ou no verão.



Figura 3 - Predição de erosão em diferentes imagens de teste pelo modelo Mask R-CNN.

Os resultados obtidos pelo modelo no conjunto de dados de teste (180 imagens) estão apresentados na Tabela 1. A Mask R-CNN alcançou um valor de 42% na métrica Intersection over Union (IoU), indicando uma baixa sobreposição entre a máscara predita e a máscara de referência (ground truth). Essa limitação pode ser atribuída à presença de regiões menores de erosão nas imagens de teste, que o modelo não conseguiu identificar adequadamente. Esses resultados também se refletem nas métricas de Precisão e F1-Score, que obtiveram valores de 62% e 61%, respectivamente, sugerindo um número elevado de falsos positivos e falsos negativos na predição.

Por outro lado, a acurácia atingiu um valor de 92%, demonstrando uma boa concordância geral entre os pixels preditos pelo modelo e os pixels de referência. Apesar disso, os resultados evidenciam a necessidade de ajustes no treinamento ou no pré-processamento dos dados, visando melhorar a sensibilidade do modelo em identificar áreas de erosão menores, cujo tamanho dificulta o processo de detecção.

Tabela 1 - Resultado do modelo Mask R-CNN na segmentação de erosão.

Acurácia	Precisão	F1 Score	IoU
0,92	0,62	0,61	0,42

2. UNIVERSAL SOIL LOSS EQUATION: USLE

A USLE foi utilizada para gerar o mapa de suscetibilidade à erosão do estado de Minas Gerais, integrando dados em um Sistema de Informações Geográficas. Essa equação combina fatores que representam variáveis ambientais e características do solo, sendo fundamental para a análise de erosão e conservação do solo.

Fatores da USLE:

Fator R (Erosividade da chuva): Calculado com dados pluviométricos de 41 anos (1981–2022) obtidos de 66 pontos de coleta em Minas Gerais. Foi utilizada a interpolação pelo método "Inverso do Quadrado da Distância" para criar um mapa de erosividade com resolução espacial de 30 metros por pixel.

Fator K (Erodibilidade do solo): Representa a suscetibilidade do solo à erosão, considerando sua textura, matéria orgânica, estrutura e permeabilidade. Foram utilizados dados de pesquisas em solos brasileiros com características pedológicas similares às de Minas Gerais e informações espaciais detalhadas da distribuição dos solos no estado.

Fatores C (Uso e cobertura do solo) e P (Práticas conservacionistas): O fator C reflete o impacto do uso da terra e da cobertura vegetal na erosão, enquanto o fator P avalia a redução de perdas em áreas com práticas conservacionistas. Ambos foram determinados a partir de valores disponíveis na literatura e de dados matriciais para Minas Gerais.

Fatores L (Comprimento do declive) e S (Inclinação do terreno): Calculados com base em dados topográficos e Modelos Digitais de Elevação (MDE). As equações foram processadas no software QGIS, utilizando uma abordagem raster que associou valores específicos a cada pixel do mapa.

Os fatores foram combinados para criar o mapa de suscetibilidade à erosão, permitindo a espacialização das áreas mais vulneráveis no estado. Esses mapas são fundamentais para orientar políticas de conservação do solo e servem como base para a criação de modelos de inteligência artificial que utilizam máscaras binárias.

Esse projeto integra dados ambientais, geográficos e computacionais, destacando a importância da análise integrada para a gestão sustentável do solo. As Equações 1, 2, 3, 4 e 5 apresentam as fórmulas de combinação dos fatores para criação do mapa de suscetibilidade à erosão.

$$\beta = \frac{\sin(\theta \cdot 0,01745)}{3 \cdot \sin(\theta \cdot 0,01745)^{0,8} + 0,56} \quad (1)$$

Onde:

θ = ângulo de declividade.

β = razão entre a erosão por sulco (causada pelo fluxo) e a erosão entre sulcos (causada principalmente pelo impacto das gotas de chuva).

$$m = \frac{\beta}{1 + \beta} \quad (2)$$

Onde:

m = constante dependente da declividade da encosta.

$$L_{ij} = \frac{(A_{ij} + D)^m - (A_{ij})^m}{X_{ij} \cdot M^{0,09} \cdot (22,13)^m} \quad (3)$$

Onde:

L_{ij} = fator de comprimento de vertente de uma célula com coordenadas (i, j).

A_{ij} = área de contribuição da célula em coordenadas (i, j) (m²).

D = tamanho da célula em metros.

X_{ij} = coeficiente funcional de ajuste para o grau de célula em coordenadas (i, j).

$$S = 10,8 \cdot \sin(\theta) + 0,03, \quad \text{quando declividade} < 9 \quad (4)$$

$$S = 16,8 \cdot \sin(\theta) - 0,5, \quad \text{quando declividade} \geq 9 \quad (5)$$

Onde:

S = coeficiente funcional da declividade para o grau de célula.

θ = ângulo de declividade. (theta)

3. Mapa de Suscetibilidade Gerado

O estudo realizado levou a confecção de um mapa de suscetibilidade à erosão, com resolução espacial de 30 metros por pixel devido a limitação dos dados utilizados, levando em conta todos os fatores utilizados no cálculo da fórmula de USLE, o potencial de perda de solo variou entre o mínimo de 0,000002 e o máximo de 118.110,94 toneladas por hectare por ano, para facilitar a visualização dos dados passaram por uma reclassificação.

De acordo com a reclassificação feita (Tabela 2), o mapa categorias de suscetibilidade à erosão predominantemente situadas entre 1 e 10 (abrangendo 27.38% do mapa) e indicando um risco ligeiro de erosão, a segunda classe mais predominante é a que indica uma chance de nenhuma ou ligeira de erosão cobrindo 21.52% do mapa, dessa forma é possível inferir que o estado de Minas Gerais tem um baixo nível de suscetibilidade à erosão. A Figura 4 mostra o mapa de suscetibilidade à erosão para o estado de Minas Gerais resultante da aplicação do modelo.

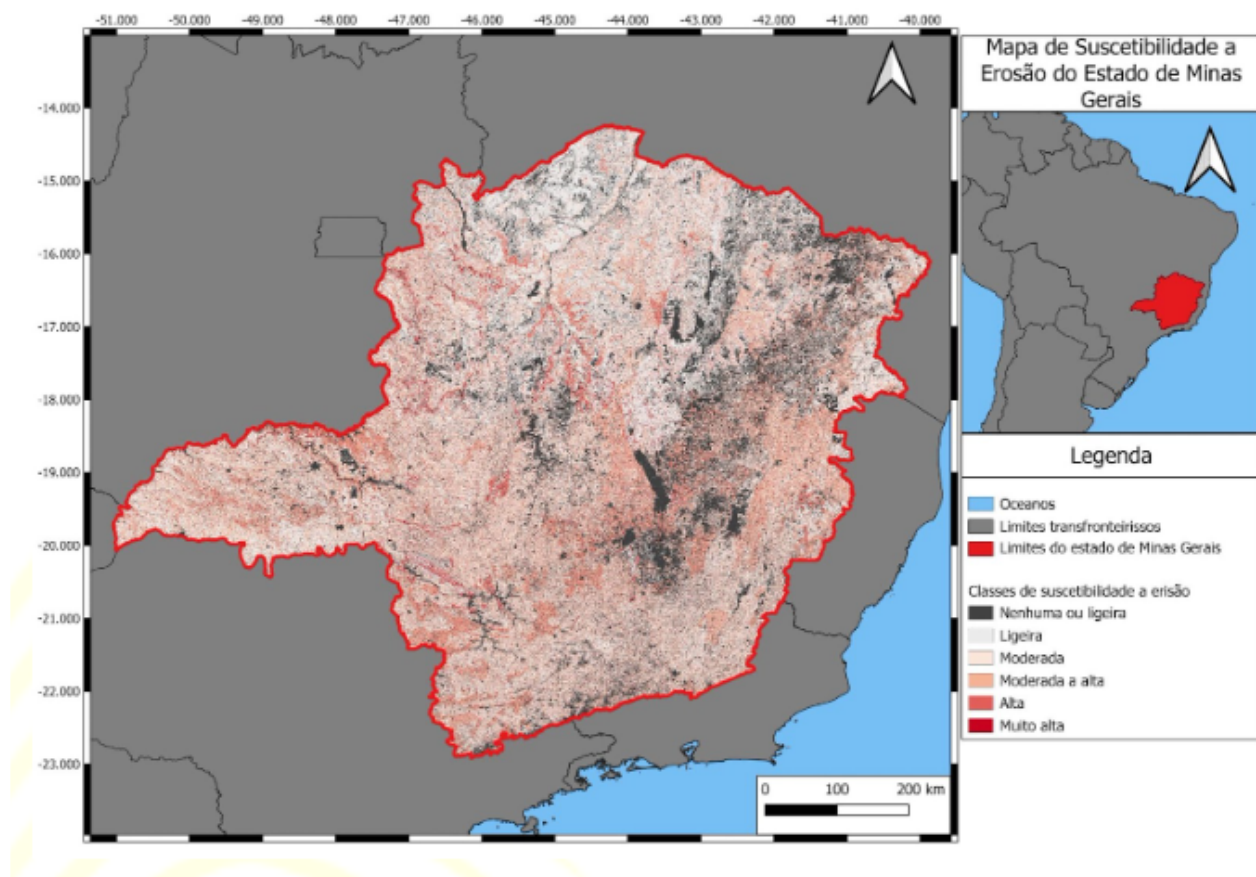


Figura 4 - Mapa de suscetibilidade à erosão para o estado de Minas Gerais.

Tabela 2 - Classificação de erosão segundo o mapa de erodibilidade.

Classificação	Classe	Área (%)
Nenhuma ou Ligeira	0-1	21.52%
Ligeira	1-10	27.38%
Moderada	10-20	21.26%
Moderada a alta	20-50	18.40%
Alta	50-200	9.20%
Muito Alta	< 200	2.24%

4. Análises comparativa

Para realizar uma análise comparativa entre as saídas dos modelos Mask R-CNN e USLE, foram selecionados pontos específicos em regiões com erosão previamente identificadas por um especialista em campo, localizadas próximas às torres de transmissão de energia elétrica. Essas regiões apresentam uma variedade de características, incluindo diferentes tamanhos, formas, texturas e tonalidades, que refletem as particularidades da erosão ao longo do tempo.

A metodologia a seguir ilustra exemplos das predições dos modelos em diferentes regiões com erosão: Subfigura (a): Imagem do Google Maps destacando a localização da região de erosão. O ponto vermelho indica as coordenadas precisas da erosão, enquanto a linha e o ponto amarelos representam, respectivamente, as linhas e as torres de transmissão de energia elétrica. Subfigura (b): Imagem de entrada utilizada pelos modelos, fornecendo a base visual para as análises. Subfigura (c): Mapa de erodibilidade gerado pelo modelo USLE. As áreas com maior suscetibilidade à erosão são apresentadas em tons avermelhados, indicando zonas de maior risco com base em dados históricos e ambientais. Subfigura (d): Máscara predita pelo modelo Mask R-CNN, evidenciando com precisão as áreas afetadas pela erosão, mostrando a capacidade do modelo de identificar essas regiões de forma detalhada.

A Figura 5 apresenta um exemplo de uma região com erosão próxima a torres de transmissão de energia elétrica. Observa-se que o modelo USLE gera um mapa de erodibilidade consistente, indicando uma alta probabilidade de ocorrência do fenômeno com base em dados históricos, destacadas pelas áreas em tons avermelhados no círculo azul na subfigura (c). Em contrapartida, o modelo Mask R-CNN prediz uma máscara que abrange integralmente a área afetada pela erosão, evidenciando o bom desempenho

do modelo no aprendizado e na detecção precisa da região impactada, conforme indicado pelo círculo amarelo na subfigura (d).




Figura 5 - Região de Teste 1 com Áreas de Erosão Identificadas.

O modelo USLE consegue representar alguns pixels correspondentes ao fenômeno de erosão, mas apresenta limitações em abranger toda a área afetada. Além disso, o modelo frequentemente gera índices elevados de suscetibilidade à erosão em regiões onde há vegetação baixa ou áreas de cultivo, mesmo que o fenômeno não esteja presente.

Esse comportamento também pode ser observado na imagem de teste apresentada na Figura 6. Na sub figura (c), é evidente que a região com erosão não foi totalmente detectada. Essa limitação pode ser atribuída à diferença de resolução entre os dados utilizados para construir o modelo USLE (30 m/pixel) e a resolução da imagem de satélite (5 m/pixel). Por outro lado, a sub figura (d) mostra que o modelo Mask R-CNN é capaz de gerar máscaras que delineiam precisamente as áreas de erosão e solo exposto, sem incluir regiões irrelevantes. Isso evidencia a capacidade do Mask R-CNN em oferecer uma segmentação mais detalhada e alinhada à realidade, demonstrando a vantagem de sua aplicação em imagens de alta resolução.




Figura 6 - Região de Teste 2 com Áreas de Erosão Identificadas.

3. Conclusão

O presente projeto realizou uma análise comparativa entre as predições de erosão geradas pelos modelos USLE e Mask R-CNN, com o objetivo de identificar possíveis riscos à infraestrutura elétrica. A abordagem permitiu não apenas localizar áreas já afetadas pela erosão, mas também identificar regiões suscetíveis a esse fenômeno no futuro, proporcionando uma visão abrangente e preventiva para a gestão e manutenção de infraestruturas críticas.

A integração entre a predição de um modelo de segmentação baseado em Mask R-CNN e a informação de um mapa de erodibilidade gerado pelo modelo USLE traz vantagens significativas para a análise e o monitoramento de erosão. Cada uma dessas abordagens fornece insights complementares, que, quando combinados, aumentam a precisão e a aplicabilidade dos resultados em cenários reais.

4. Referências bibliográficas

- GAFUROV, A.; YERMOLAEV, O.** Automatic gully detection: neural networks and computer vision. *Remote Sensing*, v. 12, p. 1743–1759, 2020. Acesso em: 20/01/2025.
- GAFUROV, A.** Mapping of rill erosion of the Middle Volga (Russia) region using deep neural network. *International Journal of Geo-Information*, v. 11, p. 1–24, 2022. Acesso em: 20/01/2025.
- NOGUEIRA, K.; MACHADO, G. L. S.; GAMA, P. H. T.; SILVA, C. V. da; BALANIUK, R.; SANTOS, J. A. dos.** Facing erosion identification in railway lines using pixel-wise deep-based approaches. *Remote Sensing*, v. 12, n. 4, p. 739, 2020. Acesso em: 20/01/2025.
- SHORTEN, C.; KHOSHGOFTAAR, T. M.** A survey on Image Data Augmentation for Deep Learning. *J Big Data*, v. 6, n. 60, 2019. Disponível em: <https://doi.org/10.1186/s40537-019-0197-0>. Acesso em: 20/01/2025.
- PRECHELT, L.** Early stopping—but when?. In: ORR, G. B.; MÜLLER, K.-R. (Ed.). *Neural networks: Tricks of the trade*. Berlin, Heidelberg: Springer, 1998. p. 55-69. Acesso em: 20/01/2025.