

DIAGNÓSTICO DA EROSÃO EM ÁREAS DE MANANCIAL VIA GEOTECNOLOGIAS E INTELIGÊNCIA ARTIFICIAL: UMA ABORDAGEM INTEGRADA COM RPA, REDES U-NET E VALIDAÇÃO RUSLE

**DIAGNOSIS OF EROSION IN SPRING AREAS USING GEO-TECHNOLOGIES
AND ARTIFICIAL INTELLIGENCE: AN INTEGRATED APPROACH USING RPA,
U-NET NETWORKS, AND RUSLE VALIDATION**

Ciências Exatas e da Terra, Ciências Agrárias • 07/09/2026

REGISTRO DOI: [10.70773/revistatopicos/788586996](https://doi.org/10.70773/revistatopicos/788586996)

Alison Antony Ribeiro¹

Arlindo Fabrício Corrêa²

Armin Feiden³

RESUMO

O artigo apresenta uma metodologia integrada de diagnóstico erosivo para áreas de manancial rural, combinando sensoriamento remoto por Aeronave Pilotada Remotamente (RPA), atributos espectrais derivados das bandas RGB e segmentação semântica por rede neural convolucional U-Net. O estudo aplicou essa metodologia a 59,24 hectares em área do entorno de nascentes do Arroio Fundo, manancial de abastecimento público de Marechal Cândido Rondon (PR) a partir de ortomosaico com resolução de 3,7 cm/pixel obtido pela RPA DJI Phantom 4 RTK. Seis atributos derivados ampliam a capacidade discriminativa do modelo, treinado e calibrado ao longo de dez versões experimentais. O Modelo V9 foi selecionado por apresentar acurácia de validação de 76,7% e eliminar confusões semânticas críticas entre classes de cobertura. O diagnóstico do cenário em 2025 indicou que 60,31% da área apresenta Alto Risco erosivo, com 1,61 hectares de erosão ativa e perda média de solo de até 114,52 t ha⁻¹ ano⁻¹, valor obtido por comparação com a Equação Universal de Perda de Solo Revisada (*RUSLE*) como verificação de consistência. A simulação do cenário prospectivo (2035), baseada na restauração das Áreas de Preservação Permanente, projeta a eliminação das áreas de Risco Crítico e a redução de 72,8% nas áreas de Alto Risco. A metodologia, construída majoritariamente com software gratuito e de código aberto, mostra potencial de replicação por equipes técnicas municipais, contribuindo para o planejamento territorial orientado ao desenvolvimento rural sustentável. Limitações relativas à avaliação por classe e à independência da validação são discutidas como direções para trabalhos futuros.

Palavras-chave: Aeronave Pilotada Remotamente; Redes Neurais Convolucionais; Erosão Hídrica; Conservação do Solo.

ABSTRACT

This article presents an integrated methodology for diagnosing erosion in rural water source areas, combining remote sensing via unmanned aerial vehicles (UAVs), spectral attributes derived from RGB bands, and semantic segmentation using a U-Net convolutional neural network. The study applied this methodology to 59.24 hectares in the area surrounding the headwaters of Arroio Fundo, a public water source for Marechal Cândido Rondon (PR), using an orthomosaic with a resolution of 3.7 cm/pixel obtained by a DJI Phantom 4 RTK UAV. Six derived attributes enhance the model's discriminative capacity; the model was trained and calibrated across ten experimental versions. Model V9 was selected because it achieved a validation accuracy of 76.7% and eliminated critical semantic confusion between land cover classes. The diagnosis of the 2025 scenario indicated that 60.31% of the area is at high risk of erosion, with 1.61 hectares of active erosion and an average soil loss of up to 114.52 t ha⁻¹ year⁻¹, a value obtained by comparison with the Revised Universal Soil Loss Equation (RUSLE) as a consistency check. The simulation of the prospective scenario (2035), based on the restoration of Permanent Preservation Areas, projects the elimination of Critical Risk areas and a 72.8% reduction in High Risk areas. The methodology, developed primarily using free and open-source software, shows potential for replication by municipal technical teams, contributing to land-use planning geared toward sustainable rural development. Limitations related to class-based assessment and the independence of validation are discussed as directions for future work.

Keywords: Remotely Piloted Aircraft; Convolutional Neural Networks; Water Erosion; Soil Conservation.

1. INTRODUÇÃO

A gestão dos recursos hídricos em territórios rurais é, antes de tudo, uma questão de sobrevivência produtiva. Onde a agricultura familiar predomina, a qualidade da água sustenta a irrigação, a dessedentação animal, o abastecimento das famílias e a continuidade das safras. No oeste do Paraná, esse cenário se repete com intensidade: municípios pequenos, dependentes de mananciais locais, pressionados por décadas de uso intensivo do solo e supressão da vegetação ciliar. O resultado é o assoreamento progressivo, a perda de solo fértil e o comprometimento crescente dos recursos hídricos que sustentam a produção (Morais; Fadul; Cerqueira, 2018).

A intensificação agrícola sem planejamento conservacionista é uma das principais causas da degradação de mananciais em bacias hidrográficas rurais. O Brasil perde, todos os anos, entre 500 milhões e 1 bilhão de toneladas de solo agricultável por erosão hídrica, com prejuízos estimados em mais de R\$ 8 bilhões para a agricultura nacional (Bertoni; Lombardi Neto, 2010). Esses processos atingem de forma desproporcional as pequenas propriedades da agricultura familiar, que representam 70% da produção de feijão, 87% da mandioca, 60% do leite e 59% do rebanho suíno no Brasil (IDR-Paraná, 2022), operando sobre solos que se degradam a cada chuva intensa.

Tecnologias de sensoriamento remoto por Aeronave Pilotada Remotamente (RPA) avançaram significativamente na última década, tornando viável a obtenção de imagens com resolução centimétrica em escala local. Associadas a modelos de aprendizado profundo, como as redes neurais convolucionais do tipo U-Net, permitem a classificação automatizada do uso e cobertura do solo com elevado detalhamento espacial (Ketkar; Moolayil, 2021). A

integração dessas abordagens com métodos físico-empíricos de estimativa de erosão, como a Equação Universal de Perda de Solo Revisada (*RUSLE*), amplia a confiabilidade dos diagnósticos e sua utilidade para a gestão territorial (Wischmeier; Smith, 1978). Estudos recentes, no entanto, documentam a consolidação dessas tecnologias predominantemente em escalas regionais amplas e dependentes de imagens de satélite de resolução moderada (Haider *et al.*, 2024; UNESCO, 2025), ou aplicadas à agricultura de precisão em larga escala, sem aprofundamento nas especificidades locais da agricultura familiar em municípios de pequeno porte (Pilatti, 2022; Prates *et al.*, 2023). Permanece, portanto, uma lacuna entre o avanço técnico dessas ferramentas e sua aplicação efetiva a diagnósticos de precisão em escala de microbacia, justamente onde municípios pequenos, com menor capacidade técnica e financeira, mais precisariam desses instrumentos.

A ausência de diagnósticos ambientais precisos em escala local impede que gestores públicos, técnicos de extensão rural e agricultores tomem decisões informadas sobre intervenções conservacionistas prioritárias, sobretudo diante do conflito de uso entre a produção agrícola e a preservação das Áreas de Preservação Permanente (APPs) ao longo dos cursos d'água (Assis, 2006). Esse é o problema central que orienta esta pesquisa: municípios rurais de pequeno porte carecem de metodologias acessíveis e replicáveis de diagnóstico erosivo, capazes de orientar investimentos de conservação com precisão espacial e a custo compatível com a realidade orçamentária local.

Este artigo teve como objetivo apresentar e validar uma metodologia integrada de diagnóstico erosivo para áreas de manancial rural, baseada em levantamento aerofotogramétrico por

RPA, cálculo de atributos derivados das bandas RGB, segmentação semântica por rede neural convolucional U-Net e comparação com estimativas da *RUSLE*, aplicada a 59,24 hectares em uma das nascentes do Arroio Fundo, manancial de abastecimento público do município de Marechal Cândido Rondon, localizado na divisa com Quatro Pontes, oeste do Paraná. Buscou-se, especificamente, diagnosticar o risco erosivo atual da área de estudo, simular um cenário prospectivo de restauração ambiental e verificar a consistência dos resultados por método físico-empírico independente.

A justificativa desta pesquisa está na possibilidade de oferecer, por meio de software gratuito e de código aberto, um instrumento replicável por equipes técnicas municipais sem infraestrutura computacional especializada, contribuindo para o planejamento territorial orientado ao desenvolvimento rural sustentável.

2. REVISÃO DA LITERATURA

2.1. Erosão Hídrica, Bacias Hidrográficas e Agricultura Familiar

A erosão hídrica é o processo pelo qual partículas de solo são desprendidas e transportadas pela ação da água da chuva e do escoamento superficial, constituindo uma das formas mais severas de degradação do solo agrícola. Em bacias hidrográficas rurais, esse processo é amplificado pela ausência de cobertura vegetal nas encostas, pela compactação do solo pelo maquinário agrícola e pela supressão das Áreas de Preservação Permanente associadas aos cursos d'água (Bertoni; Lombardi Neto, 2010). As consequências se manifestam em duas escalas: na escala da propriedade, como perda de fertilidade e redução da produtividade; e na escala da bacia,

como assoreamento dos cursos d'água, comprometimento da qualidade da água e redução da capacidade de regulação hídrica.

A gestão hídrica em bacias hidrográficas rurais deve ser compreendida como ação integrada que articula produção agrícola, conservação ambiental e bem-estar social (Soglio; Kubo, 2016). As Áreas de Preservação Permanente, definidas pelo Código Florestal Brasileiro (Lei nº 12.651/2012), desempenham papel estratégico nesse sistema: a vegetação ciliar atua como barreira física ao escoamento, promove a infiltração de água no solo, reduz a energia cinética das enxurradas e filtra sedimentos antes que alcancem os cursos d'água. A supressão ou degradação dessas áreas compromete diretamente os serviços ecossistêmicos de regulação hídrica e amplifica os processos erosivos (Marmontel; Rodrigues, 2015).

No contexto da agricultura familiar do oeste paranaense, a pressão produtiva sobre as APPs é uma realidade documentada. A diversidade dos sistemas produtivos, que inclui suinocultura, avicultura, pecuária leiteira e cultivos anuais de grãos, combinada com o relevo ondulado característico da região, cria condições de alta suscetibilidade erosiva nas propriedades mais próximas aos cursos d'água. A ausência de diagnósticos ambientais precisos em escala local impede que gestores públicos, técnicos de extensão rural e agricultores tomem decisões informadas sobre intervenções conservacionistas prioritárias (Assis, 2006).

2.2. Sensoriamento Remoto por RPA e Atributos Espectrais Derivados

As Aeronaves Pilotadas Remotamente (RPA), denominação oficial estabelecida pela Organização de Aviação Civil Internacional (ICAO)

e adotada pelo Regulamento Brasileiro de Aviação Civil Especial nº 94 (ANAC, 2023), representam uma alternativa de baixo custo operacional ao sensoriamento remoto por satélite para aplicações de diagnóstico ambiental em escala local. Enquanto imagens de satélite comerciais de alta resolução custam entre US\$ 10 e US\$ 40 por km² por cena e dependem de janelas livres de nuvens, levantamentos por RPA permitem aquisição sob demanda com resolução centimétrica, viabilizando a detecção de feições erosivas menores que 1 metro de largura (Santos *et al.*, 2020; Wildmann *et al.*, 2014).

A câmera RGB da RPA DJI Phantom 4 RTK captura informações nas três bandas do espectro visível: vermelho (R), verde (G) e azul (B). A análise exclusiva dessas bandas apresenta limitações para distinguir feições ambientais espectralmente próximas, como solo exposto seco e solo exposto úmido. Para ampliar a capacidade discriminativa do modelo, calcularam-se seis atributos derivados sobre as bandas RGB do ortomosaico (AD1 a AD6), baseados em adaptações de índices espectrais consagrados na literatura, como *Brightness Index* (BI), *Bare Soil Index* (BSI), *Normalized Difference Vegetation Index* (NDVI) e *Normalized Difference Moisture Index* (NDMI), recalculados na ausência das bandas NIR e SWIR que tais índices originalmente requerem. Esses atributos fornecem à rede neural descritores matemáticos da variação espectral relativa entre *pixels*, sem correspondência biofísica direta com os índices multiespectrais originais.

A opção por combinar as três bandas RGB brutas com os seis atributos derivados, em vez de utilizar apenas as bandas originais como entrada do modelo, baseou-se na hipótese de que transformações não lineares entre canais ampliam a separabilidade

espectral entre classes espectralmente próximas, como solo exposto seco e solo exposto úmido, ou estradas rurais e corpos d'água. Essa hipótese não foi testada nesta pesquisa por meio de comparação sistemática entre um modelo treinado somente com as bandas RGB e modelos treinados com subconjuntos incrementais dos atributos derivados. A quantificação do ganho marginal de cada atributo (AD1 a AD6) permanece como lacuna metodológica, discutida na Seção 5.

2.3. Redes Neurais Convolucionais e Segmentação Semântica

A arquitetura U-Net, proposta por Ronneberger, Fischer e Brox (2015) para segmentação de imagens biomédicas, demonstrou ampla aplicabilidade em tarefas de segmentação semântica de imagens de sensoriamento remoto. Sua estrutura *encoder-decoder* com conexões de salto (*skip connections*) permite a recuperação de detalhes espaciais finos mesmo com conjuntos de treinamento reduzidos, característica importante para aplicações em escala local onde a anotação manual de dados de treinamento é custosa (Ketkar; Moolayil, 2021). Estudos recentes documentam aplicações de U-Net e arquiteturas derivadas para mapeamento de uso do solo, detecção de erosão e classificação de cobertura vegetal a partir de imagens de RPA (Haider *et al.*, 2024; UNESCO, 2025; Pilatti, 2022).

A estratégia de ponderação de classes (*class weights*) é uma técnica de treinamento que atribui pesos distintos a cada classe durante o cálculo da função de perda, compensando o desbalanceamento entre classes majoritárias e minoritárias. Em aplicações de mapeamento erosivo, as classes de maior interesse ambiental, como erosão ativa e vegetação nativa, tendem a ser sub-representadas nos conjuntos de treinamento, o que pode levar o modelo a privilegiar a classe majoritária (agricultura) em detrimento das classes críticas. A

ponderação adequada melhora a sensibilidade do modelo às feições ambientalmente mais relevantes, ainda que ao custo de redução marginal da acurácia global (Ketkar; Moolayil, 2021).

2.4. Equação Universal de Perda de Solo Revisada — *RUSLE*

A Equação Universal de Perda de Solo Revisada (*RUSLE*) é um modelo empírico utilizado para estimativa de perdas de solo por erosão hídrica laminar (Wischmeier; Smith, 1978). O modelo expressa a perda média anual de solo (*A*, em $t\ ha^{-1}\ ano^{-1}$) como produto de cinco fatores: erosividade da chuva (*R*), erodibilidade do solo (*K*), comprimento e grau de declive combinados (*LS*), cobertura e manejo do solo (*C*) e práticas conservacionistas (*P*), conforme a Equação 1.

Equação 1 — Equação Universal de Perda de Solo Revisada

$$A = R \times K \times LS \times C \times P$$

Fonte: *Wischmeier e Smith (1978); Bertoni e Lombardi Neto (2010)*

Cada fator é estimado a partir de dados climatológicos, pedológicos, topográficos e de uso do solo, com referências regionais calibradas para as condições do sul do Brasil (Bertoni; Lombardi Neto, 2010; Netto; Virgens Filho; Neves, 2018).

A *RUSLE* funciona como método de referência independente dos modelos de inteligência artificial, sendo usada para comparação de consistência de diagnósticos erosivos obtidos por sensoriamento remoto. A correspondência entre as classes de risco geradas por modelos computacionais e os gradientes quantitativos estimados pela *RUSLE* fornece evidência de consistência metodológica,

especialmente quando os dois métodos operam a partir de princípios distintos, como o reconhecimento de padrões espectrais e as equações empíricas calibradas para condições físicas específicas (Silva *et al.*, 2018). Ressalva-se, contudo, que essa independência é apenas parcial nesta pesquisa, conforme detalhado na Seção 3.6.

A revisão realizada evidencia que os fundamentos teóricos necessários a esta pesquisa, erosão hídrica em bacias hidrográficas familiares, sensoriamento remoto por RPA, segmentação semântica por redes neurais convolucionais e validação por *RUSLE*, encontram-se consolidados isoladamente na literatura, mas raramente integrados em um único fluxo metodológico voltado à escala da microbacia rural. Essa integração, e não cada componente isoladamente, é a lacuna que esta pesquisa busca preencher, conforme detalhado no Material e Métodos a seguir.

3. METODOLOGIA


Esta pesquisa caracteriza-se por abordagem quantitativa, natureza aplicada e objetivo exploratório. A abordagem quantitativa justifica-se pela coleta e análise sistemática de dados numéricos, que permitem a mensuração precisa de variáveis espaciais e ambientais, a identificação de relações de causa e efeito e a replicabilidade dos resultados em outros contextos territoriais (Prodanov; Freitas, 2013; Paranhos; Rodolpho, 2017). O planejamento metodológico manteve flexibilidade para incorporar ajustes decorrentes dos testes realizados com os modelos de inteligência artificial e da obtenção de novas imagens aéreas ao longo do período de coleta (Wessner; Frozza; Molz, 2024).

A população de referência desta pesquisa corresponde à totalidade da área de estudo (59,24 hectares), segmentada em 16.510 *tiles* de 512×512 *pixels* para fins de classificação automatizada pelo modelo treinado (Seção 3.5). A amostra utilizada para o treinamento e a calibração do modelo consistiu em 150 *tiles* selecionados intencionalmente, e não por sorteio aleatório, com base em critério de diversidade visual e temática entre as cinco classes de uso e cobertura do solo, posteriormente ampliados para 900 amostras por meio de *Data Augmentation* (Seção 3.4). Os instrumentos de coleta de dados, a Aeronave Pilotada Remotamente DJI Phantom 4 RTK, e os procedimentos de processamento, tabulação e análise, baseados em QGIS, Python e GRASS GIS, são detalhados nas subseções a seguir.

3.1. Área de Estudo

A área de estudo compreende 59,24 hectares localizados em uma das nascentes do Arroio Fundo, manancial de abastecimento público do município de Marechal Cândido Rondon, situado na divisa com o município de Quatro Pontes, oeste do Paraná, Brasil, inserido na Bacia Hidrográfica do Paraná 3 (Figura 1). Sua delimitação foi determinada operacionalmente pela autonomia energética da RPA, com dois voos de 30 minutos cada, e pela representatividade dos sistemas produtivos locais: a área abrange trechos com suinocultura, pecuária de leite e cultivos anuais de grãos, além de fragmentos de vegetação nativa e cursos d'água associados às nascentes do manancial. O Arroio Fundo constitui a principal fonte de abastecimento público de Marechal Cândido Rondon, município com população de aproximadamente 48 mil habitantes.

Figura 1. Mapa de localização da área de estudo na zona de nascente do Arroio Fundo, Quatro Pontes (PR)



Fonte: Os Autores, 2026.

3.2. Levantamento Aerofotogramétrico por RPA

O levantamento aerofotogramétrico foi realizado com a Aeronave Pilotada Remotamente DJI Phantom 4 RTK, equipada com câmera RGB de 20 megapixels e sistema de posicionamento RTK (*Real-Time Kinematic*) integrado, que permite o georreferenciamento centimétrico das imagens durante o voo. Os levantamentos foram realizados em cinco datas: 28 de agosto de 2024, 18 de outubro de 2024, 14 de novembro de 2024, 10 de novembro de 2025 e 19 de novembro de 2025, cobrindo diferentes estágios do ciclo agrícola regional. Os voos foram planejados na plataforma DroneDeploy com altitude de 120 metros AGL, sobreposição frontal e lateral de 80%, e missão em grade dupla (*double grid*), resultando em um *Ground Sample Distance* (GSD) médio de 3,7 cm/pixel. O processamento fotogramétrico foi realizado no Agisoft Metashape Professional, utilizado na versão de avaliação gratuita, gerando ortomosaicos

georreferenciados no sistema SIRGAS 2000 / UTM Zona 22S (EPSG:31982).

Cabe registrar que o Agisoft Metashape Professional (versão 1.8) é *software* proprietário, disponibilizado nesta pesquisa por meio de licença de avaliação gratuita concedida pelo fabricante para fins acadêmicos, sem restrições funcionais para o processamento realizado, o que relativiza parcialmente a caracterização do fluxo de trabalho como integralmente baseado em ferramentas de código aberto. Para contextos de replicação com restrições orçamentárias, alternativas de código aberto como WebODM (Opendronemap, 2026) oferecem funcionalidades equivalentes para geração de ortomosaicos e modelos digitais de elevação a partir de imagens de RPA, e deveriam ser avaliadas em versões futuras da metodologia (Seção 5.7).

3.3. Cálculo dos Atributos Derivados

Seis atributos derivados (AD1 a AD6) foram calculados sobre as bandas RGB de cada ortomosaico por meio de um pipeline automatizado em Python, desenvolvido com as bibliotecas Rasterio (v.1.3), NumPy (v.1.24) e GDAL (v.3.6). Os atributos são adaptações matemáticas de índices espectrais da literatura, como BI, BSI, SATVI, NDVI e NDMI, recalculados sobre imagens RGB na ausência das bandas NIR e SWIR que tais índices originalmente requerem. A banda *Alpha* gerada automaticamente pelo Agisoft Metashape foi incorporada como variável de entrada adicional em quatro dos seis atributos. O Quadro 1 apresenta as equações e a finalidade de cada atributo derivado.

Quadro 1. Atributos Derivados calculados sobre as bandas RGB do ortomosaico

Sigla	Nome	Equação	Bandas	Finalidade
AD1	Atributo Derivado de Brilho 1	$\sqrt{((R^2 + G^2) / 2)}$	R, G	Indicador de brilho geral
AD2	Atributo Derivado de Brilho 2	$\sqrt{((R^2 + G^2 + B^2) / 3)}$	R, G, B	Complement a AD1 com banda azul
AD3	Atributo Derivado de Solo Exposto	$((\tilde{B}+R)-(\alpha+B)) / ((\tilde{B}+R)+(\alpha+B)+\epsilon)$	R,G,B, α	Realça solo exposto
AD4	Atributo Derivado de Vegetação Ajustada	$((\tilde{B}-R) / ((\tilde{B}+R+0,5)+\epsilon) \times 1,5$	R,G,B	Solo exposto em vegetação esparsa
AD5	Atributo Derivado de Densidade Vegetal	$(\alpha-R) / (\alpha+R+\epsilon)$	R, α	Densidade relativa da vegetação
AD6	Atributo Derivado de Umidade	$(\tilde{B}-\alpha) / (\tilde{B}+\alpha+\epsilon)$	R,G,B, α	Variações de umidade relativa


Fonte: Os Autores, 2026.

Nota: α = banda *Alpha* (Agisoft Metashape); $\tilde{B}$ = $(R+G+B)/3$ (substituto do SWIR); ϵ = 10^{-6} (estabilização numérica).

A Figura 2 apresenta os seis atributos derivados calculados sobre o ortomosaico dos voos de 28 de agosto de 2024, 18 de outubro de 2024 e 10 de novembro de 2025, datas selecionadas por

apresentarem as melhores condições de iluminação e cobertura da área de estudo no conjunto de dados de treinamento.

Figura 2. AD1 a AD6 calculados sobre o ortomosaico



Fonte: O Autor, 2026.

Calculados a partir das bandas R, G e da combinação RGB, o AD1 e o AD2 expressam o brilho geral da superfície: áreas de solo exposto seco e superfícies construídas tendem a apresentar valores mais elevados, enquanto corpos d'água e vegetação densa exibem valores menores. O AD3 realça as áreas de solo exposto sem cobertura vegetal, identificadas pelos tons mais claros da escala adotada. O AD4, adaptação do SATVI para imagens RGB, discrimina transições entre solo e vegetação esparsa, sendo sensível a variações

espectrais na faixa do vermelho. O AD5 quantifica a densidade relativa da cobertura vegetal, com valores mais altos nas matas ciliares e fragmentos florestais. O AD6 detecta variações de umidade relativa da superfície, realçando os cursos d'água e as zonas de maior saturação hídrica do solo.

Quanto à incorporação da banda *Alpha* em quatro dos seis atributos, cabe uma ressalva metodológica: em ortomosaicos gerados pelo Agisoft Metashape, a banda *Alpha* codifica primariamente a máscara de cobertura de dados do mosaico, isto é, a distinção entre regiões efetivamente imageadas e regiões de preenchimento nas bordas e em áreas de oclusão, e não necessariamente uma propriedade radiométrica da superfície. É possível, portanto, que parte do sinal atribuído a esses atributos derivados reflita artefatos de bordas de mosaico e de costura entre blocos fotogramétricos, e não variações reais de umidade ou densidade vegetal. Essa possibilidade não foi quantificada neste estudo e deveria ser verificada em trabalhos futuros por meio de comparação entre os atributos calculados com e sem a banda *Alpha*, restringindo a análise ao núcleo do mosaico, distante das bordas de aquisição (Seção 5.2).

3.4. Desenvolvimento e Treinamento do Modelo U-Net

O modelo foi desenvolvido em Python com a biblioteca TensorFlow 2.12, seguindo a arquitetura U-Net com *encoder* de quatro blocos de convolução dupla e *decoder* simétrico com conexões de salto. A entrada é um tensor de 512×512×6 *pixels*, correspondendo aos seis atributos derivados empilhados como bandas. A saída é um mapa de probabilidades para cinco classes de uso e cobertura do solo: Agricultura (0), Erosão (1), Água (2), Vegetação (3) e Construção (4). O

modelo foi treinado e calibrado ao longo de dez versões experimentais (V1 a V10), cada uma incorporando ajustes progressivos de estratégia conforme apresentado no Quadro 2.

Quadro 2. Evolução da estratégia de pesos por classe (V1 a V10)

Versão	C0: Agricultur a	C1: Erosão	C2: Água	C3: Vegetação	C4: Constr o
V1-V5	1.0	1.0	1.0	1.0	1.0

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em:
<https://revistatopicos.com.br/artigos/diagnostico-da-erosao-em-areas-de-manancial-via-geotecnologias-e-inteligencia-artificial-uma-abordagem-integrada-com-rpa-redes-u-net-e-validacao-rusle?noblockage>

Fonte: Os Autores, 2026.

No Quadro 3, as versões V1 a V4 utilizaram treinamento base com aumento incremental do conjunto de dados (50 a 150 amostras). A versão V5 introduziu a estratégia de *Data Augmentation* com fator de multiplicação $\times 6$, expandindo o conjunto de treinamento para 600 amostras. As versões V6 a V9 incorporaram a ponderação de classes (*class weights*) para corrigir confusões semânticas críticas identificadas anteriormente. O Modelo V9 foi selecionado como versão definitiva por combinar acurácia de 76,7% com eliminação

das confusões semânticas entre estradas rurais úmidas e corpos d'água, erro considerado inaceitável para um diagnóstico de gestão territorial, com acurácia que, embora inferior aos 77,8% do V7, representa maior qualidade semântica nas classes ambientalmente críticas.

Quadro 3. Parâmetros e métricas de desempenho das dez versões do modelo

Versão	<i>Tiles</i> Rotulados (Manual)	<i>Data</i> <i>Augmenta</i> <i>tion</i>	Total de Amostras (Treino)	Acurácia (Validação)	Loss (Valida)
V1	50	Não	50	63,5%	0,95
V2	80	Não	80	70,9%	0,86

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em:

<https://revistatopicos.com.br/artigos/diagnostico-da-erosao-em-areas-de-manancial-via-geotecnologias-e-inteligencia-artificial-uma-abordagem-integrada-com-rpa-redes-u-net-e-validacao-rusle?noblockage>

Fonte: Os Autores, 2026.

Os *tiles* das imagens de 18 de outubro de 2024 e 10 de novembro de 2025 alimentaram preferencialmente o conjunto de treinamento, e os *tiles* das imagens de 14 de novembro de 2024 e 19 de novembro de 2025 compuseram preferencialmente o conjunto de validação interna. Essa alocação por data introduz alguma diversidade

temporal à validação, mas não constitui um teste de generalização temporal independente: os valores reportados no Quadro 3 já correspondem a essa validação, e não a uma avaliação adicional sobre dados completamente apartados do processo de calibração. Após a rotulagem, o conjunto foi ampliado por *Data Augmentation* e dividido aleatoriamente na proporção de 80% para ajuste dos pesos da rede e 20% para monitoramento da acurácia de validação durante o treinamento, por meio da função `train_test_split` da biblioteca *Scikit-learn* (`test_size=0.2`, `random_state=42`), aplicada sobre o conjunto já ampliado, de modo que todas as variações geométricas de um mesmo tile original permanecessem no mesmo subconjunto, evitando vazamento de informação entre treino e validação decorrente das transformações.

Como os 150 *tiles* rotulados manualmente foram selecionados a partir de uma grade de recorte com sobreposição espacial de 50% (Seção 3.3), *tiles* originais distintos, e não apenas suas variações por *augmentation*, podem ocupar posições espacialmente próximas ou parcialmente sobrepostas no mosaico, ainda que tenham sido distribuídos aleatoriamente entre treino e validação interna. Esse resíduo de proximidade espacial entre *tiles* de treino e de validação interna não foi eliminado por um desenho de blocos espacialmente disjuntos, e constitui limitação reconhecida (Seção 5.3). Não há, nesta pesquisa, um conjunto de teste adicional, temporal ou espacialmente disjunto, avaliado de forma independente da validação interna reportada no Quadro 4; a ausência dessa avaliação independente é discutida na Seção 5.3.

Quadro 4. Hiperparâmetros de treinamento do Modelo V9

Parâmetro	Valor	Justificativa técnica
-----------	-------	-----------------------

Arquitetura	U-Net customizada	Estrutura encoder-decoder adequada à segmentação de bordas em imagens de sensoriamento remoto
Dimensão de entrada	512 × 512 × 6	Resolução compatível com a memória de GPU disponível e inclusão dos 6 atributos derivados
Tamanho do lote (batch)	4	Ajustado para estabilidade do gradiente descendente sem exceder a VRAM disponível
Épocas	50	Suficiente para convergência da loss sem overfitting severo
Otimizador	Adam	Convergência rápida e eficiente para o volume de dados disponível
Função de perda	Sparse Categorical Crossentropy, ponderada por classe	Adequada à classificação multiclasse com pesos diferenciados por classe (Quadro 2)
<i>Data Augmentation</i>	Rotações de 90° e 180°, espelhamentos horizontal e vertical, e combinações entre rotação e espelhamento (fator ×6)	Ampliação do conjunto de 150 para 900 amostras sem novos dados de campo

Fonte: Os Autores, 2026.


As métricas de acurácia global e *loss* reportadas no Quadro 4 permitem comparar o desempenho relativo entre versões, mas não substituem a avaliação por classe. Métricas de precisão, revocação e *IoU* por classe, especialmente para a classe Erosão, não foram

calculadas nesta etapa da pesquisa e constituem lacuna reconhecida, tratada na Seção 5.1.

3.5. Mapeamento do Risco Erosivo e Simulação de Cenários

O diagnóstico do cenário atual (2025), Figura 3, foi gerado pela aplicação do Modelo V9 sobre 16.510 *tiles* de 512×512 *pixels* cobrindo a totalidade da área de estudo, com sobreposição de 50% entre *tiles* adjacentes (*stride* de 256 *pixels*).

Figura 3. Mapa de risco de erosão, área de estudo (cenário 2025)



Fonte: Os Autores, 2026.

O mosaico classificado foi reconstituído por álgebra de mapas no QGIS 3.44 (versão LTR), cruzando a classificação da U-Net com o raster de declividade obtido a partir do Modelo Digital de Elevação de 1 metro, pela equação apresentada na Equação 2, onde $F_{declividade}$ assume valor 1 para declives inferiores a 8%, 3 para 8–15%, 5 para 15–30% e 10 para declives superiores a 30%.

Equação 2 - Índice de risco erosivo por álgebra de mapas


$$\text{Risco} = (\text{IA}_{\text{erosão}} \times 10) + (\text{IA}_{\text{veg}} \times 1) + (\text{IA}_{\text{const}} \times 1) + (\text{IA}_{\text{agri}} \times \text{F}_{\text{declividade}})$$

Fonte: O Autor, 2026.

Os pesos atribuídos às classes de cobertura nessa equação (10 para Erosão; 1 para Vegetação e Construção; fator variável para Agricultura conforme a declividade) e os limiares de declividade adotados (8%, 15% e 30%) não resultam de calibração estatística ou de análise de sensibilidade formal, mas de julgamento especialista informado pela hierarquia qualitativa de contribuição à perda de solo estabelecida pela *RUSLE*, na qual o fator C atribuído à erosão ativa (0,800) é substancialmente superior ao da vegetação e construção (0,001, Seção 3.6). Essa correspondência ordinal não constitui uma transformação proporcional calibrada. A ausência de testes de sensibilidade, como a perturbação dos pesos e dos limiares de declividade com registro de como as áreas de cada classe de risco respondem a essas variações, é reconhecida como limitação e discutida na Seção 5.6.

A simulação do cenário prospectivo (2035), Figura 4, foi construída como exercício normativo baseado na premissa de restauração integral das APPs ao longo da rede de drenagem, conforme os parâmetros do Código Florestal Brasileiro (Lei nº 12.651/2012), adotando a faixa teórica de 30 metros a partir das margens dos cursos d'água. A rede de drenagem utilizada foi obtida da base cartográfica do IDR-Paraná (2022). Todos os *pixels* localizados dentro da faixa de APP foram reclassificados para a classe Vegetação, e a equação de risco foi reaplicada sobre o mapa modificado.

Figura 4. Mapa de risco de erosão, área de estudo (cenário 2035)



Fonte: Os Autores, 2026.

3.6. Comparação com Estimativas da RUSLE

Os mapas de risco foram comparados com estimativas da *RUSLE*, implementada no QGIS 3.44 com suporte do provedor GRASS GIS 8.4 e das bibliotecas GDAL e GEOS. Os parâmetros adotados foram: $R = 8.500 \text{ MJ mm ha}^{-1} \text{ h}^{-1} \text{ ano}^{-1}$, obtido das isoerodentes regionais de Netto, Virgens Filho e Neves (2018) para o estado do Paraná; $K = 0,013 \text{ t h MJ}^{-1} \text{ mm}^{-1}$ para Latossolo Vermelho Distroférrico típico (LVdf13) e $K = 0,015$ para Nitossolo Vermelho Eutroférrico típico (NVef2), conforme o *shapefile* pedológico do Instituto Água e Terra do Paraná (IAT, escala 1:250.000) e a caracterização de Silva *et al.* (2018) para essa mesma sub-bacia, com o fator K especializado a partir do próprio fator LS, atribuindo-se $K = 0,013$ onde $LS \leq 5$ e $K = 0,015$ onde $LS > 5$, de modo a preservar a correspondência entre tipo de solo e posição topográfica; LS calculado pelo algoritmo *r.watershed* do *GRASS GIS* a partir do MDE reamostrado de 3,7

cm/*pixel* para 1 metro/*pixel*; $C = 0,200$ para Agricultura, $0,800$ para Erosão, $0,000$ para Água e $0,001$ para Vegetação e Construção (Wischmeier; Smith, 1978; Bertoni; Lombardi Neto, 2010); e P (fator de práticas conservacionistas), definido a partir da observação visual dos ortomosaicos e de inspeção direta em campo durante as missões de voo, que identificou a presença de terraceamento nas áreas de cultivo agrícola. Foram calculados dois cenários de P para fins comparativos: um cenário sem terraceamento ($P = 1,0$ para todas as classes) e um cenário com terraceamento ($P = 0,50$ para Agricultura, valor de referência de Bertoni e Lombardi Neto (2010) para declividades entre 2% e 7%, faixa predominante nas áreas de cultivo da área de estudo; $P = 1,0$ para as demais classes).

O cenário sem terraceamento produziu perdas de solo de até $1.054,75 \text{ t ha}^{-1} \text{ ano}^{-1}$, e o cenário com terraceamento reduziu esse máximo para $163,77 \text{ t ha}^{-1} \text{ ano}^{-1}$, uma redução de 84,5% nas áreas de maior risco, resultado consistente com a prática conservacionista efetivamente observada em campo. A perda média de solo por classe de risco foi estimada por estatísticas zonais no QGIS, com os resultados confrontados com os gradientes de risco gerados pela U-Net. Esclarece-se que os $114,52 \text{ t ha}^{-1} \text{ ano}^{-1}$ reportados no restante deste artigo correspondem à média zonal da classe de Risco Crítico no cenário sem terraceamento, ao passo que os valores de $1.054,75$ e $163,77 \text{ t ha}^{-1} \text{ ano}^{-1}$ referem-se aos máximos pontuais de pixel nos cenários sem e com terraceamento, respectivamente; são estatísticas distintas e não conflitantes, adotando-se de forma consistente a média zonal por classe ao longo do texto.

Cabe registrar que essa comparação tem caráter de verificação de consistência interna, e não de validação externa independente: o Fator C da *RUSLE* foi derivado das classes geradas pela U-Net,

criando dependência parcial entre os dois métodos. Os demais fatores R, K, LS e P foram calculados por fontes independentes do modelo de inteligência artificial, o que confere validade parcial à comparação, mas não a torna equivalente a uma validação externa. O cálculo de dois cenários distintos de P constitui, na prática, uma análise de sensibilidade parcial da *RUSLE*, ainda que não estenda essa mesma lógica aos pesos e limiares da equação de risco por álgebra de mapas (Seção 3.5). A obtenção de uma estimativa independente do fator C, a partir de mapeamentos oficiais de uso e cobertura do solo ou de avaliação de campo em um subconjunto de parcelas, permitiria reduzir a circularidade remanescente em versões futuras da comparação, conforme discutido na Seção 5.5.

4. RESULTADOS E DISCUSSÕES

Esta Seção apresenta os resultados obtidos em função dos três objetivos específicos formulados na Introdução: diagnosticar o risco erosivo atual da área de estudo, simular um cenário prospectivo de restauração ambiental e verificar a consistência dos resultados por método físico-empírico independente. Os resultados foram organizados em cinco subseções, cobrindo o desempenho evolutivo do modelo de inteligência artificial, o diagnóstico do cenário atual, a simulação prospectiva, a comparação com a *RUSLE* e a discussão integrada dos achados.


4.1. Desempenho do Modelo U-Net

O processo evolutivo de desenvolvimento do modelo resultou em dez versões experimentais, cuja trajetória evidencia três fases distintas de aprendizado. Na primeira fase (V1 a V4), o aumento incremental do conjunto de treinamento de 50 para 150 *tiles*

rotulados produziu ganho direto de acurácia, de 63,5% para 71,8%. A incorporação do *Data Augmentation* na V5 produziu o maior salto de desempenho do processo, elevando a acurácia para 80,1% e reduzindo a taxa de erro para 0,53, confirmando que a limitação das versões anteriores decorria do volume insuficiente de amostras. A análise visual dos mapas gerados, porém, revelou confusões semânticas críticas: estradas rurais úmidas foram classificadas sistematicamente como corpos d'água.

A fase final de calibração (V6 a V10), baseada na ponderação de classes, corrigiu essas confusões ao custo de redução moderada da acurácia bruta, de 80,1% na V5 para 76,7% na V9. Essa troca reflete uma escolha metodológica deliberada: a acurácia bruta privilegia a classe majoritária (Agricultura), enquanto a precisão semântica nas classes Erosão e Vegetação é determinante para a qualidade do mapa de risco. O Modelo V9, com pesos {0: 3.0, 1: 6.0, 2: 1.0, 3: 6.0, 4: 5.0}, eliminou as confusões entre estradas e corpos d'água com *loss* de 0,10. Essa articulação entre métricas computacionais e análise contextual é coerente com a argumentação de Ketkar e Moolayil (2021) sobre a avaliação de modelos de segmentação em contextos ambientais. Como discutido na Seção 5.1, essa análise permanece qualitativa, e a confirmação quantitativa por classe é indicada como próximo passo desta pesquisa.

Figura 5. Evolução da acurácia e *loss* de validação, Modelos V1 a V10



Fonte: Os Autores, 2026.

Nota: para o desenvolvimento desta figura, foi utilizado apoio da ferramenta de inteligência artificial Manus IA.

4.2. Diagnóstico Erosivo (Cenário 2025)

A aplicação do Modelo V9 sobre os 16.510 *tiles* da área de estudo gerou o Mapa de Uso e Cobertura do Solo e, após o cruzamento com o *raster* de declividade, o Mapa de Risco de Erosão para o cenário atual de 2025 (Figura 3). O dado mais expressivo do diagnóstico é a predominância da classe de Alto Risco: 35,73 hectares, equivalentes a 60,31% da área total. Essa categoria reúne as áreas de cultivo agrícola sobre relevos com declividade igual ou superior a 8%, condição que amplifica a energia do escoamento superficial e o transporte de sedimentos.

O diagnóstico identificou 1,61 hectares de Risco Crítico (2,72%), correspondendo a feições de erosão ativa, como sulcos, ravinas e áreas de solo severamente degradado. A localização dessas feições mostra correlação direta com dois fatores: o conflito de uso nas APPs, onde a ausência de mata ciliar permite que o escoamento

alcance os cursos d'água com energia máxima; e os trechos de estradas rurais não pavimentadas em declive, que funcionam como canais de transporte preferencial de sedimentos. As classes de Baixo e Médio Risco somam 21,15 hectares (35,7%), concentrando-se nas áreas de vegetação nativa e nos trechos agrícolas de menor declividade. O Quadro 5 apresenta a distribuição quantitativa das classes de risco erosivo.

Quadro 5. Distribuição das classes de risco erosivo (cenário 2025)

Classe de Risco	Área (ha)	Percentual (%)
Baixo (1)	10,70	18,06%
Médio (3)	10,45	17,63%
Alto (5)	35,73	60,31%
Crítico (10)	1,61	2,72%
Outros (0)	0,75	1,27%
TOTAL	59,24	100,00%

Fonte: Os Autores, 2026.

4.3. Cenário Prospectivo 2035 (Restauração das APPs)

A simulação do cenário prospectivo de 2035, baseada na restauração integral das APPs ao longo da rede de drenagem, resultou em inversão estrutural expressiva da distribuição do risco erosivo. A classe de Baixo Risco passou de 10,70 para 44,94 hectares, incremento de 319,9%, tornando-se a categoria dominante com 75,85% da área total. A classe de Risco Crítico foi completamente eliminada, e as áreas de Alto Risco retraíram 72,8%, passando de

35,73 para 9,70 hectares. A conversão de 26,02 hectares de agricultura em relevo inadequado para vegetação seria suficiente para eliminar toda a erosão ativa identificada no cenário atual e reduzir em 72,8% as áreas de alta vulnerabilidade, segundo os critérios de risco adotados nesta pesquisa.

4.4. Comparação com Estimativas da *RUSLE*

A progressão da perda média de solo estimada pela *RUSLE*, de 0,20 t ha⁻¹ ano⁻¹ na classe de Baixo Risco até 114,52 t ha⁻¹ ano⁻¹ na classe de Risco Crítico no cenário sem terraceamento, diferença de 572 vezes entre os extremos, indica que as classes de risco atribuídas pela U-Net correspondem a gradientes quantitativos coerentes de erosividade, na medida em que a *RUSLE* é parcialmente dependente das mesmas classes (Seção 3.6). A comparação com os valores reportados por Bertoni e Lombardi Neto (2010) para solos argilosos do oeste do Paraná sob cultivo intensivo, que classificam perdas superiores a 50 t ha⁻¹ ano⁻¹ como Alta e acima de 200 t ha⁻¹ ano⁻¹ como Muito Alta, indica coerência dos parâmetros adotados com as condições locais. O Quadro 6 apresenta a perda média por classe nos dois cenários de prática conservacionista (P).

Quadro 6. Perda média de solo estimada pela *RUSLE* por classe de risco (cenário 2025)

Classe de Risco	Sem terraceamento (t ha ⁻¹ ano ⁻¹)	Com terraceamento (t ha ⁻¹ ano ⁻¹)	Redução
Baixo (1)	0,20	n.d.	n.d.
Médio (3)	8,01	4,01	50,0%
Alto (5)	77,50	38,76	50,0%

Crítico (10)	114,52	n.d.	n.d.
--------------	--------	------	------

Fonte: Os Autores, 2026.

n.d. = não disponível. As classes Baixo e Crítico no cenário com terraceamento apresentaram amostras insuficientes para análise estatística robusta.

Nas classes Médio e Alto, o terraceamento reduziu a perda média estimada em exatamente 50%, resultado matematicamente esperado para $P = 0,50$ (Seção 3.6) e que confirma a representatividade do valor adotado para as condições locais observadas em campo durante as missões de voo.

No cenário prospectivo de 2035, a *RUSLE* (sem terraceamento) indicou reduções de 99,5% a 99,8% nas perdas médias de solo nas classes de maior vulnerabilidade, conforme o Quadro 7.

Quadro 7. Perda de solo pela *RUSLE*, cenário 2025 vs. 2035 (sem terraceamento)

Classe de Risco	2025 (t ha ⁻¹ ano ⁻¹)	2035 (t ha ⁻¹ ano ⁻¹)	Redução
Baixo (1)	0,20	0,22	*
Médio (3)	8,01	0,04	99,5%
Alto (5)	77,50	0,41	99,5%
Crítico (10)	114,52	0,22	99,8%

Fonte: Os Autores, 2026.

*A classe de Baixo Risco apresentou leve aumento no valor médio entre os cenários, pois a reclassificação das APPs como Vegetação

alterou a composição da classe no cenário 2035, incorporando *pixels* antes classificados como Médio Risco, com valores *RUSLE* ligeiramente superiores.

Cabe reforçar que as escalas de classificação dos dois métodos não são diretamente comparáveis: a U-Net gera classes qualitativas de risco (Baixo, Médio, Alto, Crítico), enquanto a *RUSLE* estima valores quantitativos de perda de solo em $t\ ha^{-1}\ ano^{-1}$. A convergência relatada é, portanto, de natureza espacial e tendencial, e não de equivalência numérica direta entre as classes dos dois métodos. Essa convergência, obtida por métodos que compartilham parcialmente seus insumos (Seção 3.6), é consistente com a hipótese de coerência metodológica entre as duas abordagens, mas não constitui prova de validade externa independente.

4.5. Discussão

A metodologia integrada proposta responde a uma lacuna real no campo do diagnóstico ambiental em escala local. Estudos como os de Haider *et al.* (2024) e UNESCO (2025) documentam a consolidação de redes neurais convolucionais na gestão de recursos hídricos, mas operam predominantemente em escalas regionais amplas, dependendo de imagens de satélite de resolução moderada. Pilatti (2022) e Prates *et al.* (2023) avançaram na aplicação de aprendizado de máquina para classificação do uso do solo em contextos de agricultura de precisão em larga escala, sem aprofundamento nas especificidades locais da agricultura familiar em municípios de pequeno porte. Esta pesquisa busca contribuir para essa lacuna ao integrar, em um fluxo metodológico documentado, a aerofotogrametria centimétrica por RPA, atributos derivados das bandas RGB, segmentação semântica por U-Net e

comparação com a *RUSLE*, calibrada para a escala da microbacia rural.

Do ponto de vista técnico, a literatura recente sobre segmentação semântica em imagens aéreas oferece caminhos concretos para aprimorar as próximas versões do modelo. Funções de perda com reconhecimento de bordas melhoram a delimitação de limites entre classes espectralmente próximas (Bokhovkin; Burnaev, 2019), enquanto arquiteturas com blocos residuais, atenção multi-cabeça e saídas multirresolução elevam o F1 e o *mIoU* em tarefas de detecção de feições geomorfológicas lineares, como deslizamentos de terra (Le *et al.*, 2023). Estratégias de invariância a aumento de dados combinadas com amostragem adaptativa por classe mostraram ganhos específicos para a classe minoritária em imagens aéreas agrícolas (Tavera *et al.*, 2022), e a ampliação por cópia e colagem (*cut-and-paste*) de instâncias raras já demonstrou incrementos relevantes de *mIoU* em segmentação de imagens de satélite (Motoi *et al.*, 2024), sendo potencialmente aplicável à escassez de exemplos da classe Erosão neste estudo.

Arquiteturas do tipo *Feature Pyramid Network* (Seferbekov *et al.*, 2018) e conjuntos de dados de referência como o *UAVid* (Lyu *et al.*, 2018) e o *Farmscapes* (Conserva *et al.*, 2025), este último voltado à segmentação de feições rurais lineares e ao desequilíbrio de classes em paisagens agrícolas, fornecem *benchmarks* e arquiteturas alternativas contra as quais o Modelo V9 poderia ser comparado. Abordagens semissupervisionadas (Liu, 2022) indicam ainda caminhos para reduzir a dependência de grandes volumes de anotação manual, relevante dado o conjunto de apenas 150 *tiles* rotulados manualmente nesta pesquisa. Nenhuma dessas comparações foi implementada na presente versão do artigo, e sua

incorporação é recomendada como direção prioritária de trabalho futuro (Seção 5.4).

A ausência de dados de erosividade e erodibilidade medidos *in situ* na área de estudo constitui limitação adicional para a interpretação quantitativa dos resultados da *RUSLE*, uma vez que os parâmetros R e K adotados foram obtidos da literatura regional (Netto; Virgens Filho; Neves, 2018; Bertoni; Lombardi Neto, 2010), e não de calibração local. Para pesquisas futuras, recomenda-se conduzir campanhas de campo com parcelas experimentais de erosão e pluviômetros automáticos para calibração local desses parâmetros.

Da mesma maneira, a escala de análise adotada (59,24 hectares no entorno das nascentes do Arroio Fundo) não permite inferências diretas sobre a dinâmica sedimentar do sistema hídrico como um todo, que abrange 221,7 km² segundo Morsoleto *et al.* (2022); a expansão da metodologia para a totalidade da bacia, integrando dados de RPA com imagens multiespectrais de satélite (por exemplo, Sentinel-2) e modelos hidrológicos calibrados com dados pluviométricos e fluviométricos locais, e a incorporação de variáveis socioeconômicas das propriedades rurais, são recomendadas como direções de continuidade desta linha de pesquisa, incluindo a integração futura com monitoramento em tempo real (sensores IoT, turbidímetros) para sistemas de alerta precoce de eventos erosivos, relevante diante da intensificação de precipitações extremas projetada para o sul do Brasil (Pörtner *et al.*, 2022).

A replicabilidade é uma dimensão central das contribuições pretendidas por esta pesquisa. A metodologia foi construída majoritariamente sobre *software* gratuito, com *scripts* documentados publicamente no repositório GitHub

(<https://github.com/alisonantonyribeiro/erosion-detection-unet-drone>). O principal custo de capital é a aquisição da RPA, disponível no mercado brasileiro entre R\$ 3.000 e R\$ 8.000 (DJI, 2025). Por comparação, serviços de mapeamento por empresas especializadas para área equivalente custam entre R\$ 5.000 e R\$ 15.000 por campanha, tornando a metodologia proposta competitiva para municípios que possam viabilizar a aquisição do equipamento por meio de editais de fomento ou convênios institucionais. Como observado na Seção 3.2, o uso do Agisoft Metashape sob licença de avaliação relativiza parcialmente essa caracterização, sendo recomendável a validação da metodologia com fotogrametria totalmente aberta em replicações futuras.

No campo do desenvolvimento rural sustentável, os resultados sugerem que adequação ambiental e produtividade não são objetivos opostos (Assis, 2006; Soglio; Kubo, 2016). A conversão de 26,02 hectares de agricultura em relevo inadequado para vegetação, área inferior à metade das zonas de Alto Risco identificadas, seria suficiente, segundo os critérios adotados, para eliminar toda a erosão ativa mapeada, produzindo ganhos ambientais potencialmente maiores que as perdas produtivas implicadas. Esse resultado, ainda que sujeito às limitações discutidas na Seção 5, pode subsidiar tecnicamente políticas de Pagamento por Serviços Ambientais (PSA), previstas na Lei nº 14.119/2021, como mecanismo para compensar agricultores pela retirada da produção das faixas de APP, tornando economicamente viável a restauração ambiental sem imposição de ônus unilateral às famílias produtoras.

5. LIMITAÇÕES E DIREÇÕES PARA PESQUISAS FUTURAS

Esta Seção reúne, de forma explícita, as limitações metodológicas identificadas ao longo do artigo, com o objetivo de situar corretamente o alcance das conclusões apresentadas e de orientar as etapas subsequentes desta linha de pesquisa.

5.1. Avaliação por Classe e Desbalanceamento Entre Classes

A avaliação do Modelo V9 apresentada neste artigo baseia-se em acurácia global e loss de validação (Quadro 3), métricas adequadas para acompanhar a convergência do treinamento, mas insuficientes para caracterizar o desempenho em tarefas de segmentação multiclasse desbalanceada, especialmente para a classe Erosão, que é ao mesmo tempo a mais rara e a mais relevante para o diagnóstico proposto. A ausência de métricas de Interseção sobre União (IoU) e F1-score por classe, de precisão e revocação, e de matrizes de confusão impede avaliar se a acurácia relatada não está sendo sustentada principalmente pelo bom desempenho nas classes majoritárias (Agricultura e Vegetação), mascarando eventual baixo desempenho na classe Erosão. O cálculo dessas métricas sobre o conjunto de validação do Modelo V9, com ênfase na classe Erosão, é indicado como o próximo passo imediato de validação técnica desta pesquisa.

5.2. Impacto dos Atributos Derivados

Conforme discutido na Seção 2.2, o ganho marginal de cada um dos seis atributos derivados (AD1 a AD6) sobre a classificação obtida apenas com as bandas RGB brutas não foi isolado por meio de ablação sistemática. Recomenda-se, em trabalhos futuros, treinar e comparar modelos com entradas RGB puro, RGB mais subconjuntos incrementais dos atributos derivados, e o conjunto completo de seis

atributos, reportando a variação de IoU por classe entre as configurações, de modo a identificar quais atributos efetivamente contribuem para a discriminação de classes espectralmente próximas e quais podem ser redundantes ou instáveis. A verificação específica do papel da banda *Alpha*, discutida na Seção 3.3, deve ser incorporada a essa ablação.

5.3. Delineamento Treino/Validação e Generalização Espacial e Temporal

Conforme detalhado na Seção 3.4, os *tiles* das imagens de 14 de novembro de 2024 e 19 de novembro de 2025 compuseram preferencialmente a validação interna (20%), enquanto os das imagens de 18 de outubro de 2024 e 10 de novembro de 2025 compuseram preferencialmente o treinamento, o que introduz alguma diversidade temporal à validação. Essa alocação por data, contudo, não equivale a um teste de generalização temporal independente: as métricas reportadas no Quadro 3 são as mesmas da validação interna usada para monitorar o treinamento, e não há, nesta pesquisa, uma avaliação adicional do Modelo V9 sobre dados de datas completamente apartadas do processo de calibração. Permanece como limitação também a ausência de uma separação espacialmente disjunta entre os *tiles* de treino e de validação interna: como os 150 *tiles* rotulados manualmente foram extraídos de uma grade com sobreposição de 50%, *tiles* originais distintos podem ocupar posições espacialmente próximas mesmo pertencendo a subconjuntos diferentes, o que pode inflar marginalmente as métricas reportadas no Quadro 4. A validação, além disso, foi realizada sobre uma única microbacia, sem teste de generalização para outras áreas de manancial com características distintas. Um desenho experimental futuro deveria adotar (i) blocos

de treino e validação espacialmente disjuntos e (ii) um teste de generalização temporal genuíno, com um conjunto de imagens de uma data específica mantido fora de todo o processo de treinamento e calibração e avaliado apenas ao final, para caracterizar de forma mais completa a robustez espacial e temporal do modelo.

5.4. Comparação com Arquiteturas e Funções de Perda Alternativas

Conforme discutido na Seção 4.5, a literatura recente sobre segmentação semântica de imagens aéreas oferece alternativas arquiteturais (como FPN e *SegFormer*), funções de perda (Focal, IoU e com reconhecimento de bordas) e estratégias de aumento de dados (cópia e colagem, invariância combinada com amostragem adaptativa) que não foram comparadas ao Modelo V9 nesta pesquisa. A implementação dessas comparações sobre o mesmo conjunto de dados rotulados é recomendada como direção prioritária, de modo a situar o desempenho do Modelo V9 em relação ao estado da arte.

5.5. Independência da Comparação com a *RUSLE* e Validação de Campo

A comparação com a *RUSLE* apresentada nas seções 3.6 e 4.4 tem caráter de verificação de consistência interna, uma vez que o fator C foi derivado das mesmas classes geradas pela U-Net que se pretende avaliar. A presença de terraceamento nas áreas de cultivo, base do fator P, foi confirmada por observação visual dos ortomosaicos e por inspeção direta em campo durante as missões de voo, o que já representa uma verificação de campo parcial. Não foram realizados, contudo, pontos de verificação em campo

georreferenciados (GNSS ou fotográficos) das feições de erosão ativa mapeadas especificamente, nem comparação com uma estimativa do fator C obtida a partir de mapeamentos oficiais de uso do solo totalmente independentes da classificação da U-Net. Ambas as verificações fortaleceriam substancialmente a robustez empírica das conclusões e são recomendadas para a fase de campo subsequente desta linha de pesquisa.

5.6. Sensibilidade da Álgebra de Risco e dos Fatores da RUSLE

O cálculo de dois cenários distintos do fator P (com e sem terraceamento, Seção 3.6) constitui uma análise de sensibilidade parcial dentro da *RUSLE*, que evidenciou redução de 84,5% na perda máxima de solo associada à prática conservacionista observada em campo. Essa mesma lógica de comparação entre cenários não foi estendida, contudo, aos pesos de classe e aos limiares de declividade utilizados na equação de risco por álgebra de mapas (Seção 3.5), que refletem julgamento especialista e não foram submetidos a perturbação sistemática nem comparados a formulações multicritério alternativas. A realização de testes de sensibilidade também sobre esses parâmetros, com registro de como as áreas e percentuais de cada classe de risco variam, é recomendada como etapa complementar de validação metodológica.

5.7. Ferramentas de Fotogrametria

Como observado na Seção 3.2, o uso do Agisoft Metashape Professional sob licença de avaliação gratuita relativiza parcialmente a caracterização da metodologia como integralmente baseada em *software* livre e de código aberto. A avaliação de alternativas totalmente abertas, como OpenDroneMap e MicMac, na etapa de

processamento fotogramétrico, é recomendada para assegurar a replicabilidade plena da metodologia por equipes técnicas municipais sem acesso a licenças comerciais.

6. CONCLUSÃO

Este estudo demonstra que a integração de aerofotogrametria centimétrica por RPA, atributos derivados das bandas RGB e segmentação semântica por rede neural convolucional U-Net é tecnicamente viável, com documentação suficiente para replicação por equipes com formação em geoprocessamento.

O diagnóstico do risco erosivo atual identifica 60,31% da área de estudo em Alto Risco e 2,72% em Risco Crítico, delimitando com precisão as zonas prioritárias de intervenção. A simulação prospectiva confirma que a restauração integral das APPs elimina as áreas de Risco Crítico e reduz em 72,8% as zonas de Alto Risco até 2035. A verificação por método físico-empírico independente indica coerência entre as duas abordagens, com a *RUSLE* apontando reduções de 99,5% a 99,8% nas perdas de solo nas classes de maior vulnerabilidade no mesmo cenário prospectivo.

A pesquisa confirma a hipótese de que técnicas de aprendizado profundo aplicadas a dados de RPA de baixo custo produzem diagnósticos erosivos compatíveis com métodos físico-empíricos consolidados, ainda que essa convergência não substitua validação externa independente.

Assim, a principal contribuição do trabalho é um fluxo metodológico replicável e de baixo custo, com scripts publicados em repositório aberto, que converte dados geoespaciais de alta resolução em subsídio técnico para tomada de decisão por gestores públicos,

comitês de bacia e extensionistas rurais. A metodologia é replicável em outros municípios brasileiros nos quais a agricultura familiar depende de mananciais hoje monitorados com precisão insuficiente.

O estudo apresenta limitações quanto à ausência de validação de campo independente e à calibração local dos parâmetros da *RUSLE*, detalhadas na Seção 5, que também indica as direções de pesquisa necessárias para consolidar essa validação.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de doutorado sanduíche ao primeiro autor, que viabilizou o período de mobilidade acadêmica internacional fundamental para o desenvolvimento desta pesquisa. Agradecem também ao Programa de Pós-Graduação em Desenvolvimento Rural Sustentável (PPGDRS) da Universidade Estadual do Oeste do Paraná (UNIOESTE) pelo suporte institucional, e aos agricultores e gestores do município de Quatro Pontes (PR) pela disponibilização de acesso às áreas de estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. Regulamento Brasileiro da Aviação Civil Especial nº 94 — RBAC-E nº 94. Brasília: ANAC, 2023. Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94>. Acesso em: 13 jan. 2026.

ASSIS, R. L. de. Desenvolvimento rural sustentável no Brasil: perspectivas a partir da integração de ações públicas e privadas com base na agroecologia. Economia Aplicada, v. 10, n. 1, 2006. DOI: 10.1590/S1413-80502006000100005.

BERTONI, J.; LOMBARDI NETO, F. Conservação do solo. 8. ed. Piracicaba: Coleção Brasil Agrícola, 2010.

BOKHOVKIN, A.; BURNAEV, E. Boundary Loss for Remote Sensing Imagery Semantic Segmentation. arXiv:1905.07852, 2019. Disponível em: <https://arxiv.org/abs/1905.07852>. Acesso em: 21 jul. 2026.

BRASIL. Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa. Diário Oficial da União, Brasília, DF, 28 maio 2012.

CONSERVA, M.; WILSON, A.; STANTON, C.; BATCHU, V.; GULSHAN, V. Mapping Farmed Landscapes from Remote Sensing. arXiv:2506.13993, 2025. Disponível em: <https://arxiv.org/abs/2506.13993>. Acesso em: 21 jul. 2026.

DJI. DJI Phantom 4 RTK. 2025. Disponível em: <https://www.dji.com/br/phantom-4-rtk>. Acesso em: 7 mar. 2026.

HAIDER, S.; RASHID, M.; TARIQ, M. A. U. R.; NADEEM, A. The role of artificial intelligence (AI) and ChatGPT in water resources, including its potential benefits and associated challenges. Discover Water, v. 4, n. 1, p. 113, 2024.

IDR-PARANÁ — INSTITUTO DE DESENVOLVIMENTO RURAL DO PARANÁ. Balanço Social 2022. Curitiba: IDR-Paraná, 2022.

KETKAR, N.; MOOLAYIL, J. Convolutional Neural Networks. In: _____. Deep Learning with Python. Berkeley: Apress, 2021. p. 197-242.

LE, C.; PHAM, L.; LAMPERT, J.; SCHLÖGL, M.; SCHINDLER, A. Landslide Detection and Segmentation Using Remote Sensing Images and Deep Neural Network. arXiv:2312.16717, 2023. Disponível em: <https://arxiv.org/abs/2312.16717>. Acesso em: 21 jul. 2026.

LIU, K. Semi-Supervised Confidence-Level-based Contrastive Discrimination for Class-Imbalanced Semantic Segmentation. arXiv:2211.15066, 2022. Disponível em: <https://arxiv.org/abs/2211.15066>. Acesso em: 21 jul. 2026.

LYU, Y.; VOSSELMAN, G.; XIA, G.; YILMAZ, A.; YANG, M. Y. UAVid: A Semantic Segmentation Dataset for UAV Imagery. arXiv:1810.10438, 2018. Disponível em: <https://arxiv.org/abs/1810.10438>. Acesso em: 21 jul. 2026.

MARMONTEL, C. V. F.; RODRIGUES, V. A. Parâmetros indicativos para qualidade da água em nascentes com diferentes coberturas de terra e conservação da vegetação ciliar. Floresta e Ambiente, v. 22, n. 2, p. 171-181, 2015. DOI: 10.1590/2179-8087.082014.

MAXAR TECHNOLOGIES. High-resolution satellite imagery pricing. 2025. Disponível em: <https://www.maxar.com>. Acesso em: 21 jul. 2026.

MORAIS, J. L. M.; FADUL, E.; CERQUEIRA, L. S. Limites e desafios na gestão de recursos hídricos por comitês de bacias hidrográficas: um estudo nos estados do nordeste do Brasil. REAd. Revista Eletrônica de Administração (Porto Alegre), v. 24, n. 1, p. 238-264, 2018.

MORSOLETO, F. M. da S. *et al.* Análise da microbacia hidrográfica do rio Arroio Fundo como possível aplicação em viveiros escavados para a piscicultura. *Research, Society and Development*, v. 11, n. 6, e60029191, 2022. DOI: 10.33448/rsd-v11i6.29191.

MOTOI, I. M.; SARACENI, L.; NARDI, D.; CIARFUGLIA, T. A. Evaluating the Efficacy of Cut-and-Paste Data Augmentation in Semantic Segmentation for Satellite Imagery. *arXiv:2404.05693*, 2024. Disponível em: <https://arxiv.org/abs/2404.05693>. Acesso em: 21 jul. 2026.

NETTO, C. F.; VIRGENS FILHO, J. S.; NEVES, G. L. Análise de Erosividade da Chuva no Estado do Paraná ao Longo do Século XXI. *Revista Brasileira de Climatologia*, v. 22, 2018.

OLIVEIRA, F. P. *et al.* Erosividade das chuvas no estado do Paraná. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 16, n. 8, p. 880-888, 2012. DOI: 10.1590/S1415-43662012000800010.

OPENDRONEMAP. WebODM. [S. l.]: OpenDroneMap, 2026. Disponível em: <https://www.opendronemap.org/webodm/>.

PARANHOS, Lidia Raquel Louback; RODOLPHO, Paulo José. *Metodologia da Pesquisa Aplicada à Tecnologia*. 1ª Edição, SENAI-SP, 2017. p. 144

PILATTI, H. da S. C. *Inteligência geoespacial aplicada ao planejamento e à gestão da bacia hidrográfica do rio Montividiu, sudoeste goiano*. 2022.

PLANET LABS. High-resolution satellite imagery pricing. 2025. Disponível em: <https://www.planet.com>. Acesso em: 21 jul. 2026.

PÖRTNER, H.-O. *et al.* (ed.). Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the IPCC. Cambridge: Cambridge University Press, 2022.

PRATES, L.; SOUZA, C.; LACERDA, A. Classificação de imagens aéreas obtidas por drone utilizando técnicas de inteligência artificial. In: 14ª JORNADA CIENTÍFICA E TECNOLÓGICA, 2023. Anais [...]. Disponível em: <https://www.researchgate.net/publication/370101709>. Acesso em: 5 fev. 2026.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Científico. 2ª ed. [S. l.]: books by language, 2013. online.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional networks for biomedical image segmentation. In: Medical Image Computing and Computer-Assisted Intervention (MICCAI). Springer, 2015. p. 234-241. DOI: 10.1007/978-3-319-24574-4_28.

SANTOS, L. M. dos; FERRAZ, G. A. S.; BARBOSA, B. D. S.; ANDRADE, A. D. Use of remotely piloted aircraft in precision agriculture: a review. DYNA, v. 86, n. 210, p. 284-291, 2020.

SEFERBEKOV, S. S.; IGLOVIKOV, V.; BUSLAEV, A. V.; SHVETS, A. A. Feature Pyramid Network for Multi-Class Land Segmentation. arXiv:1806.03510, 2018. Disponível em: <https://arxiv.org/abs/1806.03510>. Acesso em: 21 jul. 2026.

SILVA, B. A. *et al.* Mapeamento digital de solos e os atributos topográficos das vertentes no alto curso da sub-bacia hidrográfica

do Córrego Quatro Pontes. Revista Brasileira de Geomorfologia, v. 19, n. 4, 2018. DOI: 10.20502/rbg.v19i4.1385.

SOGLIO, F. K. D.; KUBO, R. R. (org.). Agricultura e sustentabilidade: desafios para a construção de sistemas alimentares. Porto Alegre: Editora UFRGS, 2016.

TAVERA, A. *et al.* Augmentation Invariance and Adaptive Sampling in Semantic Segmentation of Agricultural Aerial Images. arXiv:2204.07969, 2022. Disponível em: <https://arxiv.org/abs/2204.07969>. Acesso em: 21 jul. 2026.

UNESCO. Applications of AI for water management. Paris: UNESCO, 2025.

WESSNER, Rodrigo Nunes; FROZZA, Rejane; MOLZ, Rolf Fredi. Métodos para identificação de plantas daninhas em lavouras de milho com uso de inteligência artificial e processamento de imagens. Revista Produção Online, [s. /], v. 24, n. 2, p. 5249–5249, 2024.

WILDMANN, N.; HOFSSÄSS, M.; WEIMER, F.; JOOS, A.; BANGE, J. MASC — a small Remotely Piloted Aircraft (RPA) for wind energy research. Advances in Science and Research, v. 11, n. 1, p. 55-61, 2014.

WISCHMEIER, W. H.; SMITH, D. D. Predicting Rainfall Erosion Losses: A Guide to Conservation Planning. Washington, D.C.: USDA, 1978. (Agriculture Handbook, n. 537).

¹ Doutorando em Desenvolvimento Rural Sustentável pela Universidade do Oeste do Paraná - UNIOESTE. Mestrado em

Tecnologias Computacionais para o Agronegócio pela Universidade Tecnológica Federal do Paraná - UTFPR. Pós-graduação em Banco de Dados - UTFPR. Pós-graduação em Informática Aplicada à Educação - IFRJ. Graduação em Redes de Computadores pelo Centro de Ensino Superior de Foz do Iguaçu - CESUFOZ. Professor do Ensino Básico, Técnico e Tecnológico do Instituto Federal do Paraná - Câmpus Goioerê. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0002-4436-9024>

² Doutorado em Agronomia - UNIOESTE. Mestrado em Energia na Agricultura - UNIOESTE. Graduação em Agronomia - UNIOESTE. Professor no Centro de Ciências Agrárias da UNIOESTE - Câmpus Marechal Cândido Rondon. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0001-8020-5425>

³ Doutorado em Agronomia - UNESP. Mestrado em Engenharia Florestal - UFPR. Graduação em Zootecnia - UEM. Graduação em Agronomia - UFPR. Professor sênior da UNIOESTE. E-mail: [acesse o artigo original para visualizar o e-mail](#). ORCID: <https://orcid.org/0000-0001-8068-5422>