

UNIVERSIDADE FEDERAL DO PAMPA

ESTER BITENCOURT GIAMBASTIANI MACHADO

**METODOLOGIAS PARA MODELAGEM GEOLÓGICA VIA FOTOGRAMETRIA
DIGITAL ASSISTIDA POR INTELIGÊNCIA ARTIFICIAL**

**Caçapava do Sul
2026**

ESTER BITENCOURT GIAMBASTIANI MACHADO

**METODOLOGIAS PARA MODELAGEM GEOLÓGICA VIA FOTOGRAMETRIA
DIGITAL ASSISTIDA POR INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso apresentado ao curso de Geologia da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Bacharel em Geologia.

Orientador: Ítalo Gomes Gonçalves

**Caçapava do Sul
2026**

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

MM149mm Machado, Ester Bitencourt Giambastiani
Metodologias para modelagem geológica via fotogrametria
digital assistida por inteligência artificial / Ester
Bitencourt Giambastiani Machado.
61 p.

Trabalho de Conclusão de Curso(Graduação)-- Universidade
Federal do Pampa, GEOLOGIA, 2026.
"Orientação: Ítalo Gomes Gonçalves".

1. Transferência de rótulos. 2. Inteligência artificial.
3. U-Net. 4. Fotogrametria digital. I. Título.

ESTER BITENCOURT GIAMBASTIANI MACHADO**METODOLOGIAS PARA MODELAGEM GEOLÓGICA VIA FOTOGRAMETRIA DIGITAL ASSISTIDA POR INTELIGÊNCIA ARTIFICIAL**

Trabalho de Conclusão de Curso apresentado ao
curso de Geologia da Universidade Federal do
Pampa, como requisito parcial para obtenção do
Título de Bacharel em Geologia.

Trabalho de Conclusão de Curso defendido e aprovado em 09 de Julho de 2026.

Banca Examinadora:
Prof. Dr. Ítalo Gomes Gonçalves (Orientador)
UNIPAMPA

Prof. Dr. Everton Frigo
UNIPAMPA

Prof. Dr. Marcus Vinicius Aparecido Gomes de Lima
UNIPAMPA



Assinado eletronicamente por **MARCUS VINICIUS APARECIDO GOMES DE LIMA, PROFESSOR DO MAGISTERIO SUPERIOR**, em 10/07/2026, às 18:03, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **EVERTON FRIGO, PROFESSOR DO MAGISTERIO SUPERIOR**, em 13/07/2026, às 07:52, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **ITALO GOMES GONCALVES, PROFESSOR DO MAGISTERIO SUPERIOR**, em 13/07/2026, às 10:09, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



A autenticidade deste documento pode ser conferida no site
https://sei.unipampa.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2090282** e o código CRC **B2AC4690**.

RESUMO

A integração entre fotogrametria digital e inteligência artificial tem ampliado as possibilidades de aquisição, interpretação e representação tridimensional de dados geológicos. Com base nesse contexto, o trabalho teve como objetivo analisar a aplicação de técnicas de inteligência artificial na segmentação de imagens geológicas obtidas por fotogrametria, com ênfase na transferência de rótulos entre imagens e na avaliação da consistência espacial dos resultados em modelos 3D. A área de estudo selecionada intencionalmente foi uma frente de lavra de mármore na região das Caieiras, em Caçapava do Sul (RS), localizada às margens da BR-392. A região constitui um importante distrito mineiro voltado à extração de calcário e produção de cal. A metodologia foi baseada na aquisição de imagens aéreas por drone, processadas no software Agisoft Metashape para a geração de produtos fotogramétricos, tais como nuvem de pontos, malha tridimensional e modelo texturizado. Posteriormente, foram produzidas máscaras de referência para classes denominadas mármore, intrusão e estéril, utilizadas na transferência automática de rótulos e no treinamento de uma rede neural convolucional para segmentação do tipo U-Net. Essas máscaras preditas foram posteriormente associadas aos produtos fotogramétricos, permitindo a construção de modelos tridimensionais temáticos para cada classe litológica respectiva. Obteve-se como resultados referências de bom desempenho geral da segmentação, acurácia global entre 0,98 e 0,99 em duas etapas avaliadas separadamente. As classes mármore e estéril distinguiram-se por apresentarem os melhores resultados, enquanto a classe intrusão concentrou as maiores limitações, principalmente em razão de sua menor representatividade, geometria mais estreita, contatos menos regulares e maior influência de sombras e variações texturais. Essa integração das máscaras ao modelo 3D permitiu visualizar a distribuição espacial das unidades classificadas e avaliar a continuidade das litologias na frente de lavra. Conclui-se que a metodologia proposta apresenta potencial como ferramenta de apoio à modelagem geológica, reduzindo parte do esforço manual de delimitação e ampliando a base de dados rotulados, além de fornecer uma base tridimensional temática compatível com a geometria do afloramento.

Palavras-chave: Transferência de rótulos, Inteligência artificial, U-Net, Fotogrametria digital. Modelagem geológica tridimensional.

ABSTRACT

The integration of digital photogrammetry and artificial intelligence has expanded the possibilities for the acquisition, interpretation, and three-dimensional representation of geological data. Based on this context, this study aimed to analyze the application of artificial intelligence techniques in the segmentation of geological images obtained via photogrammetry, emphasizing label transfer between images and evaluating the spatial consistency of the results in 3D models. The study area intentionally selected was a marble quarry face in the Caieiras region, in Caçapava do Sul (RS). Located along the BR-392 highway, the region constitutes an important mining district focused on limestone extraction and lime production. The methodology was based on the acquisition of aerial images by drone, processed in the Agisoft Metashape software for the generation of photogrammetric products, such as point cloud, 3D mesh, and textured model. Subsequently, reference masks were produced for classes named marble, intrusion, and waste rock, which were used in the automatic transfer of labels and in the training of the U-Net convolutional neural network. These predicted masks were then associated with the photogrammetric products, enabling the construction of thematic three-dimensional models for each respective lithological class. The results indicated a strong overall performance in segmentation, with a global accuracy between 0.98 and 0.99 across two separately evaluated stages. The marble and waste rock classes stood out for presenting the best results, whereas the intrusion class concentrated the main limitations, primarily due to its lower representativeness, narrower geometry, less regular contacts, and greater influence from shadows and textural variations. This integration of masks into the 3D model allowed for the visualization of the spatial distribution of the classified units and the evaluation of lithological continuity across the mine face. In conclusion, the proposed methodology shows potential as a supporting tool for geological modeling by reducing part of the manual delineation effort and expanding the labeled dataset, while providing a thematic three-dimensional base compatible with the outcrop geometry.

Keywords: Label transfer, Artificial intelligence, U-Net, Digital photogrammetry. 3D geological modeling.

LISTA DE FIGURAS

Figura 1	– Representação do princípio do algoritmo de <i>Structure from Motion</i> . O ponto P na imagem representa o resultado da identificação de feições, e os índices representam a sua posição em cada imagem. Os diferentes pontos são usados para calcular a posição do ponto P, do objeto no espaço.	17
Figura 2	– Arquitetura da U-Net aplicada à segmentação semântica.	20
Figura 3	– Províncias estruturais brasileiras (A) e províncias geológicas do Rio Grande do Sul (B).	25
Figura 4	– Mapa das principais unidades tectônicas do Rio Grande do Sul.	27
Figura 5	– Mapa de localização da área de estudo.	29
Figura 6	– Fotografia aérea evidenciando as bancadas da cava de mineração.	30
Figura 7	– Perfil das principais litologias observadas na área de estudo: o mármore, o xisto e o granito.	31
Figura 8	– Fluxograma das etapas metodológicas desenvolvidas neste trabalho.	33
Figura 9	– Equipamentos e infraestrutura utilizados durante o levantamento fotogramétrico: (a) antena RTK; (b) drone DJI Matrice 300 equipado com câmera Zenmuse P1; e (c) local de decolagem e pouso.	34
Figura 10	– Distribuição espacial das fotografias após o alinhamento no Metashape. Os retângulos azuis representam as posições e orientações das câmeras durante a aquisição das imagens, enquanto as linhas indicam a sequência de aquisição ao longo da missão de voo.	35
Figura 11	– Exemplo de correspondências entre pontos característicos identificados em duas imagens sobrepostas utilizando o algoritmo SIFT.	38
Figura 12	– Correspondências estabelecidas entre imagens sobrepostas da bancada.	38
Figura 13	– Modelo tridimensional texturizado da área de estudo obtido por processamento fotogramétrico.	47
Figura 14	– Resultado da segmentação litológica apresentando a imagem original, a predição e mapa de entropia, empregado como medida da incerteza da classificação.	50
Figura 15	– Modelo geológico temático gerado pela integração do processamento fotogramétrico com a segmentação litológica.	52

LISTA DE TABELAS

Tabela 1	–	Classes utilizadas na rotulação manual e principais características observadas nas imagens.	37
Tabela 2	–	Principais parâmetros utilizados no treinamento da rede neural U-Net. . . .	41
Tabela 3	–	Síntese dos principais resultados do alinhamento fotogramétrico.	45
Tabela 4	–	Produtos gerados no processamento fotogramétrico.	46
Tabela 5	–	Métricas de validação obtidas para a segmentação semântica.	48

LISTA DE ABREVIATURAS E SIGLAS

2D – Bidimensional

3D – Tridimensional

ANN – Artificial Neural Networks (Redes Neurais Artificiais)

CDF – Cinturão Dom Feliciano

CGCS – Complexo Granítico Caçapava do Sul

CMPF – Complexo Metamórfico Passo Feio

CNN – Convolutional Neural Network (Rede Neural Convolucional)

CPRM – Serviço Geológico do Brasil

ESRG – Escudo Sul-Rio-Grandense

F1-score – Métrica de desempenho baseada na média harmônica entre precisão e recall

GNSS – Global Navigation Satellite System (Sistema Global de Navegação por Satélite)

GSD – Ground Sampling Distance (Distância de Amostragem do Solo)

IA – Inteligência Artificial

IoU – Intersection over Union (Interseção sobre União)

LABMODEL – Laboratório de Modelagem Geológica

MDA – Modelo Digital de Afloramento

MDE – Modelo Digital de Elevação

MVA – Modelo Virtual de Afloramento

MVS – Multi-View Stereo

RAM – Random Access Memory (Memória de Acesso Aleatório)

RS – Rio Grande do Sul

RTK – Real-Time Kinematic (Posicionamento Cinemático em Tempo Real)

SfM – Structure-from-Motion

SfM-MVS – Structure-from-Motion-Multi-View Stereo

SIFT – Scale-Invariant Feature Transform

TSG – Terreno São Gabriel

U-Net – Arquitetura de rede neural convolucional para segmentação semântica

UNIPAMPA – Universidade Federal do Pampa

UV – Coordenadas de mapeamento de textura

VANT – Veículo Aéreo Não Tripulado

ZCCS – Zona de Cisalhamento Caçapava do Sul

ZCI – Zona de Cisalhamento Ibaré

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Justificativa	13
1.1.1	Caracterização do problema e hipóteses	13
1.2	Objetivos	14
1.2.1	Objetivo Geral	14
1.2.2	Objetivos Específicos	14
2	REVISÃO BIBLIOGRÁFICA	15
2.1	Modelagem Geológica	15
2.2	Fotogrametria Digital	16
2.3	Visão Computacional	17
2.4	Inteligência Artificial	18
2.5	Redes Neurais - U-Net	19
2.6	Transferência de Rótulos	20
3	ESTADO DA ARTE	22
3.1	Fotogrametria digital aplicada à modelagem geológica	22
3.2	Aplicação de inteligência artificial em imagens geológicas	22
3.3	Integração entre fotogrametria e inteligência artificial	23
4	ÁREA DE ESTUDO	24
4.1	Geologia Regional	24
4.2	Escudo Sul-Rio-Grandense	25
4.3	Domínio Ocidental do ESRG	27
4.4	Geologia Estrutural	28
4.5	Geologia Local	28
5	MATERIAIS E MÉTODOS	32
5.1	Fluxo de Trabalho	32
5.2	Aquisição dos Dados	34
5.3	Processamento Fotogramétrico	35
5.4	Rotulação Manual	36
5.5	Transferência de Rótulos	37
5.6	Segmentação Semântica	39
5.6.1	Particionamento das Imagens	39
5.6.2	Treinamento da Rede Neural	40
5.6.2.1	Parâmetros do Treinamento	40
5.6.3	Predição das Máscaras	41
5.7	Construção dos Modelos Geológicos Tridimensionais	41
5.7.1	Avaliação do Desempenho da Rede	42
6	RESULTADOS E DISCUSSÕES	44
6.1	Processamento Fotogramétrico	44
6.2	Segmentação Semântica	48
6.3	Avaliação Visual das Segmentações	49
6.4	Reconstrução Tridimensional das Litologias	50

6.4.1	Modelo Tridimensional do Mármore	50
6.4.2	Modelo Tridimensional das Intrusões	51
6.4.3	Modelo Tridimensional do Estéril	51
6.4.4	Integração dos Modelos Litológicos	51
6.5	Integração entre Segmentação e Modelo Tridimensional	53
7	CONSIDERAÇÕES FINAIS	54
7.1	Recomendações para Trabalhos Futuros	55
	REFERÊNCIAS	57

1 INTRODUÇÃO

O crescente avanço das geotecnologias tem transformado significativamente os métodos de aquisição, processamento e interpretação de dados geológicos. É nesse contexto que a modelagem geológica consolidou-se como uma das ferramentas fundamentais para a compreensão da geometria e da distribuição de distintas unidades litológicas, podendo ser amplamente aplicada em estudos acadêmicos e também na indústria mineral (Goudinho, 2023).

Diante de muitas técnicas disponíveis, a fotogrametria digital destaca-se por permitir a reconstrução tridimensional de afloramentos a partir de imagens bidimensionais, através da sobreposição de imagens e da identificação de pontos homólogos. Essa metodologia possibilita a geração de modelos digitais com alto nível de detalhamento, servindo de base para a realização de análises estruturais e para a caracterização espacial de feições geológicas (Viana, 2021).

Aplicar este tipo de técnica ganha relevância em contextos de afloramentos bem expostos, visto que a diversidade litológica e estrutural oferece as condições ideais para o estudo detalhado de feições geológicas em escala de alta resolução. Em especial, a região de Caçapava do Sul, serve como base para este estudo aplicado em frentes de lavra por apresentar exposições representativas de mármores e corpos intrusivos associados à evolução do Escudo Sul-Rio-Grandense (ESRG), cuja a extração comercial atua como o principal motor econômico do município. Nesse tipo de ambiente, a geração de modelos a partir de dados fotogramétricos permite integrar observações de campo com representações digitais contínuas da superfície rochosa, aprimorando a confiabilidade dos dados na análise de contatos litológicos.

Paralelamente, ferramentas de inteligência artificial (IA) ganham espaço na resolução de problemas geológicos, especialmente no campo da visão computacional. Diante disso, redes neurais convolucionais (Convolutional Neural Networks - CNNs) vêm sendo empregadas em tarefas de segmentação semântica, possibilitando a classificação pixel a pixel de diferentes feições em imagens geológicas (Wang *et al.*, 2025). Essas redes aprendem as características dos dados por meio de calibrações contínuas, melhorando, de forma progressiva, a capacidade do modelo de identificar estruturas complexas em novos cenários (Rubo, 2022).

Aplicações recentes, como as de Zhang *et al.* (2019), Chen *et al.* (2022), Barros (2024), entre outros, indicam que o uso da visão computacional na segmentação de feições geológicas a partir de imagens tem melhorado seu potencial na análise automatizada. Dessa forma, a integração entre fotogrametria digital e IA ganha espaço como uma alternativa promissora para o avanço da modelagem geológica, especialmente na automação da interpretação de imagens.

Diante desse cenário, este trabalho investiga a aplicação de CNNs na segmentação de imagens geológicas obtidas por fotogrametria digital, com ênfase na utilização da transferência de rótulos entre imagens bidimensionais a partir da correspondência de feições. Adicionalmente, busca-se avaliar de que forma essa estratégia influencia a consistência das segmentações quando projetadas e analisadas em modelos tridimensionais de afloramentos.

1.1 Justificativa

A interpretação de imagens geológicas obtidas por fotogrametria ainda depende da delimitação manual de unidades litológicas sobre modelos tridimensionais reconstruídos. Nesse processo, a segmentação é realizada a partir da leitura visual do afloramento, considerando variações de textura, cor e continuidade dos contatos geológicos. Trata-se de uma etapa dependente da experiência do intérprete, o que pode introduzir diferenças sutis na definição dos limites entre classes, especialmente onde transições não são bem definidas.

Apesar do avanço dos modelos de alta resolução, a geração de máscaras depende de intervenção manual, o que limita a automatização completa dos fluxos de interpretação baseados em dados fotogramétricos. Nesse cenário, CNNs vêm sendo exploradas como alternativa para a segmentação semântica de imagens geológicas (Guadagnin *et al.*, 2025). No entanto, o desempenho desses modelos depende diretamente da disponibilidade de dados rotulados, cuja produção segue exatamente o mesmo processo manual descrito anteriormente, tornando a construção de bases de treinamento uma atividade custosa e demorada.

Já a escolha pela indústria de calcário deve-se ao fato de que, no Rio Grande do Sul (RS), a maior concentração de atividades mineradoras desse recurso está localizada no município de Caçapava do Sul, o qual responde por mais de 85% da produção estadual (Rangel *et al.*, 2014). Trata-se de uma atividade de forte relevância econômica regional, com impacto direto na geração de empregos e na dinâmica do comércio local.

Dessa forma, a pesquisa contribui para a modernização das práticas de modelagem geológica, a partir da integração entre métodos computacionais e dados de afloramentos. Em âmbito acadêmico, o estudo desenvolve técnicas de aprendizado profundo aplicadas à geologia. Já no contexto industrial, essas metodologias podem auxiliar na caracterização de frentes de lavra, agregando para o suporte às etapas de planejamento e aproveitamento de jazidas.

1.1.1 Caracterização do problema e hipóteses

A rotulação de imagens geológicas obtidas por fotogrametria ainda depende, em grande parte, de interpretação manual, sendo realizada sobre os modelos tridimensionais, conforme já mencionado. Esse processo pode gerar variações na delimitação das classes, especialmente em áreas com transições graduais ou baixa distinção textural, e se torna ainda mais limitante no contexto do uso de redes como a U-Net, cujo desempenho está condicionado à disponibilidade e qualidade de dados rotulados, o que é dificultado pela heterogeneidade das rochas, variações de iluminação e semelhança entre unidades litológicas.

Além disso, o treinamento dessas redes frequentemente requer o redimensionamento de imagens de alta resolução, o que pode reduzir a riqueza de detalhes necessária para a separação mais precisa das classes.

Diante disso, este trabalho investiga o uso da transferência de rótulos entre imagens como estratégia para ampliação do conjunto de dados, a partir da correspondência de feições

entre registros de um mesmo afloramento. Parte-se da hipótese de que a integração entre redes do tipo U-Net e a transferência de rótulos pode contribuir para a melhoria da segmentação de unidades litológicas em imagens geológicas, reduzindo a dependência de rotulação manual e mantendo a consistência espacial dos resultados em modelos tridimensionais.

1.2 Objetivos

1.2.1 Objetivo Geral

Analisar a aplicação de técnicas de IA na segmentação de imagens geológicas obtidas por fotogrametria digital, com ênfase na transferência de rótulos entre imagens e na avaliação da consistência espacial dos resultados em modelos tridimensionais.

1.2.2 Objetivos Específicos

- Realizar a aquisição e o processamento fotogramétrico para geração de modelos tridimensionais de afloramentos;
- Aplicar técnicas de segmentação semântica utilizando redes neurais convolucionais do tipo U-Net;
- Desenvolver metodologia de transferência de rótulos entre imagens baseada na correspondência de feições;
- Avaliar a consistência espacial e geométrica dos rótulos transferidos no modelo tridimensional;
- Analisar as limitações e potencialidades da abordagem proposta.

2 REVISÃO BIBLIOGRÁFICA

2.1 Modelagem Geológica

Um modelo pode ser entendido, segundo Meyer (2004), como uma representação simplificada da realidade construída com o objetivo de facilitar sua compreensão e análise. No meio digital, essa representação decorre da conversão de elementos reais em estruturas passíveis de manipulação computacional, como ocorre com imagens obtidas por sensores digitais (Viana, 2021). A modelagem digital, nesse sentido, envolve a construção de representações físico-matemáticas tridimensionais, usualmente expressas em modelos ou malhas 3D (Vaughan, 2011).

No âmbito das geociências, o modelo geológico corresponde a uma representação virtual de um ambiente geológico destinada à estimativa de observações e medições futuras (Goudinho, 2023). Sua função principal está na descrição da distribuição espacial de unidades litológicas e na geometria dos corpos rochosos, servindo como base para interpretação e tomada de decisão. Com a evolução das geotecnologias, essa representação passou a incorporar dados digitais de maior resolução, tornando-se mais integrada e continuamente validável (Goudinho, 2023).

A fotogrametria digital baseada no fluxo SfM-MVS (*Structure-from-Motion – Multi-view Stereo*) ocupa papel central na aquisição remota desses dados. A partir desse fluxo, são gerados Modelos Digitais de Afloramento (MDAs), também conhecidos como modelos virtuais de afloramento (MVAs), que permitem descrever quantitativamente a geometria e as relações espaciais entre feições geológicas. A principal consequência desse processo é a redução da dependência exclusiva de observações diretas em campo, ampliando a análise para ambientes digitais e áreas de difícil acesso (Viana, 2021).

A confiabilidade dos MDAs está diretamente associada às condições de construção do modelo (Goudinho, 2023). Parâmetros como resolução das imagens (*Ground Sampling Distance* - GSD), sobreposição fotográfica e geometria de aquisição determinam a precisão das medidas e a capacidade de separação entre unidades geológicas. Além disso, fatores ambientais interferem de forma significativa: sombras podem gerar lacunas estruturais, a vegetação dificulta a reconstrução da superfície e o intemperismo reduz a distinção de contatos litológicos, conforme discutido por Viana (2021) e Grohmann *et al.* (2020b).

Entre os aspectos operacionais, a relação entre escopo, tempo e custo aparece de forma interdependente. O aumento do detalhamento implica maior esforço computacional e tempo de processamento, enquanto restrições de custo tendem a limitar tanto a aquisição quanto o nível de refinamento possível. Alterações em qualquer um desses fatores repercutem diretamente nos demais, refletindo no resultado final do modelo (Viana, 2021).

Mesmo com o avanço de métodos automatizados e o uso de aprendizado de máquina na classificação litológica, a interpretação especializada ainda se mantém como etapa essencial (Barros, 2024). Os MDAs funcionam como suporte à análise geológica, ampliando a escala

de observação, mas não substituem a interpretação crítica do especialista. A integração entre dados digitais e conhecimento geológico permanece, assim, como eixo central na construção de modelos representativos da realidade (Viana, 2021).

2.2 Fotogrametria Digital

A fotogrametria consiste em um método científico voltado à obtenção de informações métricas e temáticas a partir de imagens, permitindo a reconstrução de objetos e superfícies com precisão controlada, conforme Brito (2007). Sua evolução das abordagens analógicas e analíticas para o ambiente digital foi impulsionada pelo avanço dos sensores e pelo aumento da capacidade de processamento computacional (Viana, 2021).

Brito (2007) e Barros (2024) explicam que as imagens digitais são representadas como matrizes compostas por pixels, cada um associado a valores numéricos de intensidade de radiação captada pelo sensor. Essa estrutura viabiliza o uso de técnicas de processamento digital e visão computacional, que vão desde correções radiométricas até tarefas mais complexas como reconhecimento de feições e reconstrução tridimensional.

A reconstrução tridimensional a partir de imagens bidimensionais baseia-se no princípio da estereoscopia, dependente da sobreposição entre imagens obtidas sob diferentes perspectivas (Grohmann *et al.*, 2019). Essa sobreposição permite a identificação de pontos homólogos e a estimativa de coordenadas espaciais por triangulação, constituindo a base da modelagem tridimensional (Viana, 2021).

A integração entre fotogrametria e visão computacional levou ao desenvolvimento do método SfM, no qual a geometria da cena e os parâmetros das câmeras são estimados simultaneamente a partir de imagens não ordenadas. Nesse processo, algoritmos como o SIFT (*Scale-Invariant Feature Transform*) identificam pontos-chave, posteriormente refinados pelo *bundle adjustment*, resultando em uma nuvem de pontos esparsa (Viana, 2021; Carrivick; Smith; Quincy, 2016). Em seguida, técnicas de MVS aumentam a densidade dessa nuvem e refinam a geometria da superfície, originando o MDA, representado por nuvens densas, malhas triangulares ou superfícies texturizadas (Viana, 2021; Goudinho, 2023), conforme ilustrado na Figura 1.


O uso de Veículos Aéreos Não Tripulados (VANTs) ampliou significativamente a aplicação dessas técnicas, permitindo aquisição de imagens com alta resolução espacial, maior flexibilidade operacional e redução de custos. A integração com sistemas Sistema Global de Navegação por Satélite (*Global Navigation Satellite System* - GNSS), especialmente por meio de RTK (*Real-Time Kinematic*), possibilita o georreferenciamento direto das imagens com maior precisão, reduzindo a necessidade de pontos de controle em campo (Barros, 2024; Shirmard *et al.*, 2022; Sato, 2025; Liang *et al.*, 2022).

A qualidade dos modelos gerados permanece condicionada às condições de aquisição. Iluminação inadequada compromete a identificação de feições, enquanto iluminação difusa favorece a reconstrução. Superfícies com baixa variação tonal ou textura limitada dificultam a

correspondência entre imagens e podem gerar falhas na nuvem de pontos (Viana, 2021). Parâmetros como sobreposição e geometria de aquisição também influenciam diretamente o resultado, podendo introduzir distorções como o “efeito domo”, mitigado com o uso de imagens oblíquas e melhor distribuição dos pontos de vista (Grohmann *et al.*, 2020a).

A fotogrametria digital se estabelece, assim, como uma ferramenta consolidada para geração de modelos tridimensionais aplicados às geociências. Sua eficácia depende diretamente do planejamento da aquisição e do controle de qualidade no processamento, o que exige compreensão clara de suas limitações para garantir a confiabilidade das interpretações (Viana, 2021; Goudinho, 2023).

Figura 1 – Representação do princípio do algoritmo de *Structure from Motion*. O ponto P na imagem representa o resultado da identificação de feições, e os índices representam a sua posição em cada imagem. Os diferentes pontos são usados para calcular a posição do ponto P, do objeto no espaço.



Fonte: Retirado de Viana (2021).

2.3 Visão Computacional

A visão computacional é um campo interdisciplinar voltado ao desenvolvimento de modelos capazes de interpretar e extrair informações de imagens digitais por meio de representações internas do conteúdo visual (Lecun; Kavukcuoglu; Farabet, 2010). Sua aplicação em geociências tem crescido com a disponibilidade de imagens de alta resolução e o aumento da capacidade computacional, sendo particularmente útil na análise automatizada de afloramentos e identificação de litologias (Rubo, 2022; Viana, 2021).

Dentro desse contexto, a segmentação de imagens ocupa posição central, pois permite dividir a imagem em regiões homogêneas com base em atributos como cor, textura e padrões espaciais. Esse processo possibilita a separação de unidades geológicas, como domínios litológicos ou zonas mineralizadas, servindo de base para análises posteriores (Shirmard *et al.*, 2022; Rubo, 2022; Yu *et al.*, 2023).

Três níveis de segmentação são usualmente considerados: segmentação semântica, segmentação por instância e segmentação panóptica. Em aplicações geológicas, a segmentação semântica se mostra mais adequada, pois realiza a classificação pixel a pixel, atribuindo cada elemento da imagem a uma classe geológica sem a necessidade de individualizar objetos. Essa abordagem favorece a representação contínua de unidades litológicas e a identificação de contatos geológicos em afloramentos e frentes de lavra (Yu *et al.*, 2023; Guedes, 2023).

Os métodos tradicionais de segmentação, baseados na definição manual de atributos, apresentam limitações diante da elevada variabilidade textural e das condições de iluminação observadas em ambientes geológicos. Nesse contexto, técnicas de aprendizado profundo passaram a desempenhar papel importante na visão computacional aplicada às geociências, permitindo a extração automática de padrões complexos presentes nas imagens (Lecun; Kavukcuoglu; Farabet, 2010; Yu *et al.*, 2023; Lin *et al.*, 2025).

2.4 Inteligência Artificial

A IA corresponde ao desenvolvimento de métodos capazes de extrair informações relevantes a partir de dados, permitindo tarefas como reconhecimento de padrões e apoio à tomada de decisão, conforme Molossi *et al.* (2025). Na análise de imagens, esses métodos permitem processar grandes volumes de dados, reduzindo limitações associadas à interpretação manual (Barros, 2024; Molossi *et al.*, 2025).

Nas geociências, sua aplicação tem se consolidado diante da complexidade dos dados geológicos, caracterizados por alta variabilidade textural, iluminação heterogênea e transições graduais entre litologias. Essas condições tornam abordagens baseadas em regras fixas pouco eficientes, favorecendo métodos capazes de lidar com padrões não lineares (Barros, 2024; Rubo, 2022).

Segundo Rubo (2022) e Wang *et al.* (2025), o aprendizado supervisionado é uma das abordagens mais utilizadas, baseado no treinamento de modelos a partir de dados rotulados. O desempenho depende diretamente da qualidade e da representatividade do conjunto de treinamento, bem como do equilíbrio entre as classes. Quando há desbalanceamento entre as classes, a rede tende a privilegiar o aprendizado daquelas com maior número de amostras, reduzindo sua capacidade de reconhecer corretamente as classes menos representadas. Como consequência, a capacidade de generalização do modelo pode ser comprometida, tornando necessárias estratégias como a ponderação das classes durante o treinamento, a ampliação do conjunto de dados rotulados ou a aplicação de técnicas de aumento de dados (Rubo, 2022; Wang *et al.*, 2025).

A IA, nesse contexto, atua como suporte à interpretação geológica, permitindo sistema-

tizar padrões e ampliar a escala de análise (Molossi *et al.*, 2025). Sua aplicação, entretanto, depende da consistência dos dados e da validação dos resultados com base no conhecimento geológico, garantindo coerência interpretativa (Viana, 2021).

2.5 Redes Neurais - U-Net

As redes neurais artificiais (*Artificial Neural Networks* – ANN) representam uma das principais abordagens da IA voltadas à modelagem de padrões complexos em dados multidimensionais (Lecun; Kavukcuoglu; Farabet, 2010; Molossi *et al.*, 2025). Entre essas arquiteturas, CNNs assumem papel de destaque em aplicações envolvendo imagens digitais, pois permitem aprender representações diretamente a partir dos dados de entrada, dispensando a definição manual de atributos (Lecun; Kavukcuoglu; Farabet, 2010; Rubo, 2022).


Segundo LeCun, Kavukcuoglu e Farabet (2010), esse processo possibilita a extração de informações em diferentes níveis de abstração, abrangendo desde características simples, como bordas e orientações, até padrões mais complexos relacionados à textura e à organização espacial dos materiais. Em aplicações geológicas, essa capacidade favorece a identificação de feições associadas às diferentes litologias e às relações entre os constituintes do afloramento (Lin *et al.*, 2025).

Na segmentação de imagens, as CNNs são amplamente empregadas em tarefas de segmentação semântica, nas quais cada pixel é associado a uma determinada classe (Yu *et al.*, 2023; Wang *et al.*, 2025). Conforme discutido por Sato (2025) e Wang *et al.* (2025), esse tipo de abordagem é particularmente adequado às geociências, onde a delimitação de unidades litológicas e descontinuidades depende frequentemente de variações sutis de cor, textura e rugosidade. Em contraste com métodos tradicionais, as redes convolucionais extraem automaticamente as características mais relevantes, tornando-se mais robustas frente à elevada variabilidade observada em afloramentos e frentes de lavra (Ullah *et al.*, 2024; Shirmard *et al.*, 2022; Lin *et al.*, 2025).

Entre as arquiteturas propostas para segmentação semântica, a U-Net consolidou-se como uma das mais difundidas nas geociências (Guedes, 2023; Yu *et al.*, 2023; Wang *et al.*, 2025). Sua estrutura é baseada em um arranjo codificador–decodificador, no qual a etapa de codificação é responsável pela extração de características em múltiplas escalas, enquanto a etapa de decodificação promove a reconstrução do mapa de segmentação na resolução original (Figura 2). As conexões de atalho estabelecidas entre essas duas etapas preservam informações espaciais de maior resolução, contribuindo para a delimitação de contatos litológicos e outras feições mais sutis (Guedes, 2023; Wang *et al.*, 2025; Molossi *et al.*, 2025). Conforme apresentado na Figura 2, as setas horizontais representam o fluxo de processamento da rede, em que a imagem passa sucessivamente por operações de convolução e redução da resolução durante a etapa de codificação, até atingir a representação de maior abstração. Na etapa de decodificação, convoluções transpostas restauram gradualmente a resolução da imagem, enquanto as conexões de atalho, indicadas pelas setas laterais, transferem informações espaciais da etapa de codificação para a correspondente etapa de decodificação, permitindo recuperar detalhes perdidos

durante o processo de redução da resolução e favorecendo uma segmentação mais precisa.

Figura 2 – Arquitetura da U-Net aplicada à segmentação semântica.



Fonte: Retirado de Guedes (2023).

A aplicação dessas arquiteturas em imagens de alta resolução impõe restrições relacionadas ao custo computacional e ao consumo de memória. Por essa razão, é comum que o processamento seja realizado sobre blocos (*tiles*), estratégia que permite dividir a imagem em regiões menores e tornar a inferência computacionalmente viável (Lin *et al.*, 2025; Wang *et al.*, 2025). A escolha do tamanho desses blocos envolve um compromisso entre a preservação dos detalhes locais e a manutenção do contexto espacial necessário à interpretação geológica. Após a inferência, os resultados obtidos para cada bloco são recompostos, restabelecendo a continuidade espacial dos rótulos, como ilustrado na Figura 2.

Neste trabalho, a U-Net foi aplicada à segmentação de imagens fotogramétricas da frente de lavra, possibilitando a classificação pixel a pixel das litologias. As máscaras produzidas serviram de base para a transferência de rótulos e sua posterior projeção no espaço tridimensional, permitindo a construção de modelos geológicos temáticos em 3D.

2.6 Transferência de Rótulos

A transferência de rótulos consiste na associação das informações obtidas em imagens bidimensionais ao modelo tridimensional, permitindo a geração de modelos geológicos 3D temáticos (Sato, 2025). Segundo Guedes (2023), essa integração estabelece uma ligação entre as máscaras de segmentação produzidas em duas dimensões e a nuvem de pontos densa gerada pelo fluxo SfM-MVS.

A base desse processo está na relação geométrica entre espaço-imagem (2D) e espaço-objeto (3D) estabelecida na reconstrução fotogramétrica (Liang *et al.*, 2022). Conforme discutido por Viana (2021) e Liang *et al.* (2022), a estimativa dos parâmetros de orientação das câmeras, obtida por meio do ajustamento de feixes perspectivos (*bundle adjustment*), possibilita relacionar cada pixel das fotografias à sua posição correspondente no espaço tridimensional. Com base nessa relação, a reprojeção viabiliza a transferência dos rótulos para a nuvem de pontos ou malha 3D (Sato, 2025). Para aumentar a coerência espacial, podem ser aplicadas transformações geométricas, interpolação dos dados e outras estratégias de integração das informações provenientes de diferentes imagens. Uma das estratégias descritas na literatura é a votação majoritária, na qual a classe mais frequentemente atribuída a um mesmo ponto é adotada como resultado final, reduzindo inconsistências na classificação (Sato, 2025; Guedes, 2023).

De acordo com Chen *et al.* (2022) e Sato (2025), a qualidade da transferência de rótulos depende tanto da precisão geométrica do modelo fotogramétrico quanto da consistência da segmentação semântica. Fatores como sombras, oclusões, baixa variabilidade textural e imprecisões na reconstrução podem comprometer a correspondência entre as imagens e o modelo tridimensional (Viana, 2021). Da mesma forma, erros presentes nas regiões de contato entre litologias tendem a ser propagados durante a projeção dos rótulos, influenciando a qualidade da classificação obtida em três dimensões (Chen *et al.*, 2022; Sato, 2025).

Apesar dessas limitações, a transferência automatizada de rótulos tem ampliado as possibilidades de integração entre segmentação semântica e modelagem tridimensional. Conforme observado por Sato (2025) e Molossi *et al.* (2025), essa abordagem reduz parte da subjetividade associada à interpretação exclusivamente manual e favorece a obtenção de modelos mais contínuos e reproduzíveis. Como consequência, torna-se possível incorporar informações temáticas aos modelos fotogramétricos, ampliando seu potencial de aplicação em diferentes escalas de análise (Sato, 2025; Liang *et al.*, 2022).

3 ESTADO DA ARTE

3.1 Fotogrametria digital aplicada à modelagem geológica

A consolidação da fotogrametria digital nas geociências, especialmente com a popularização dos VANTs e dos fluxos baseados em SfM-MVS, ampliou significativamente a capacidade de obtenção de modelos tridimensionais de afloramentos com elevado nível de detalhamento. Esses modelos vêm sendo empregados em diferentes aplicações, incluindo caracterização geométrica de superfícies rochosas, análise estrutural e estimativas volumétricas em ambientes geológicos e minerários.

Os trabalhos desenvolvidos por Grohmann *et al.* (2019) e Goudinho (2023) evidenciam a eficiência dessas abordagens na reconstrução digital de afloramentos e na extração de informações geométricas a partir dos modelos gerados. O avanço observado nas etapas de aquisição e representação espacial dos dados permitiu ampliar a escala das análises e reduzir parte das limitações associadas às observações exclusivamente realizadas em campo.

Apesar desse progresso, a interpretação geológica dos modelos tridimensionais permanece fortemente dependente da análise especializada. A delimitação de unidades litológicas e a identificação de padrões geológicos continuam sendo realizadas, em grande medida, por meio de procedimentos manuais, o que pode introduzir subjetividade e dificultar a reprodução e a padronização dos resultados. Dessa forma, embora a reconstrução geométrica tenha alcançado elevado grau de maturidade, a atribuição automática de informações temáticas ainda representa um desafio em aberto.

3.2 Aplicação de inteligência artificial em imagens geológicas

O uso de técnicas de IA, especialmente aprendizado profundo, tem se expandido na análise de imagens geológicas, permitindo avanços em tarefas de classificação e segmentação semântica. CNNs têm demonstrado elevada capacidade de extração de características e reconhecimento de padrões, sendo aplicadas em tarefas de classificação e segmentação semântica de imagens (Lecun; Kavukcuoglu; Farabet, 2010).

Aplicações recentes reportadas na literatura demonstram resultados consistentes na segmentação de imagens geológicas e MDA, indicando potencial para automatização parcial de etapas tradicionalmente interpretativas (Viana, 2021). Esses avanços evidenciam o potencial da IA para automatizar etapas tradicionalmente dependentes da interpretação humana e reduzir parte da subjetividade inerente ao processo. Ainda assim, o desempenho dessas abordagens permanece diretamente relacionado à disponibilidade de conjuntos de dados rotulados, além da capacidade de generalização dos modelos frente à variabilidade litológica, textural e de iluminação observada em diferentes contextos geológicos.

3.3 Integração entre fotogrametria e inteligência artificial

A integração entre fotogrametria digital e IA representa uma abordagem recente na modelagem geológica, associando a aquisição de modelos tridimensionais de alta resolução à automatização da interpretação das imagens utilizadas na reconstrução.

Nesse contexto, estudos recentes têm explorado a aplicação de modelos de segmentação semântica em imagens derivadas de levantamentos fotogramétricos, permitindo a propagação de informações litológicas para modelos tridimensionais. Entretanto, muitas dessas aplicações ainda tratam separadamente as etapas de aquisição, segmentação e integração espacial dos dados.

Dessa forma, a utilização de metodologias voltadas à transferência de rótulos entre imagens e sua posterior associação ao modelo tridimensional apresenta-se como uma alternativa para ampliar conjuntos de dados segmentados e reduzir a dependência de rotulação manual, contribuindo para análises mais contínuas e reproduzíveis em modelagem geológica.

4 ÁREA DE ESTUDO

4.1 Geologia Regional

O estado do RS está inserido na porção central da Província Mantiqueira, sendo constituído predominantemente por rochas neoproterozoicas e paleozoicas iniciais. A leste ocorre a Província Costeira, formada por depósitos cenozoicos, enquanto as porções norte e oeste são ocupadas pela Província Paraná, composta principalmente por unidades sedimentares e vulcânicas do Permiano ao Jurássico. Na região sul da Província Mantiqueira localiza-se o Escudo Sul-Rio-Grandense (ESRG), conforme ilustrado na Figura 3 (Porcher; Lopes, 2000).

O ESRG é constituído por um conjunto de blocos crustais de idade pré-cambriana e paleozoica inicial, englobando parte do Cráton Rio de La Plata e do Cinturão Dom Feliciano (CDF). Enquanto o Cráton Rio de La Plata concentra exposições de rochas paleoproterozoicas, especialmente no setor sudoeste do escudo, o CDF constitui uma faixa móvel neoproterozoica amplamente distribuída pelas porções leste e central do estado, preservando registros de intensa reativação tectônica e retrabalhamento crustal (Laux, 2021; Hartmann; Chemale; Philipp, 2007; Philipp; Pimentel; Chemale jr., 2016).

A configuração atual desses blocos reflete uma evolução tectônica vinculada aos processos de fragmentação do supercontinente Rodínia e posterior amalgamação do Gondwana durante a Orogênese Brasileira–Pan-Africana, entre aproximadamente 890 e 540 Ma. Como resultado, a província registra associações de rochas metamórficas, ígneas e sedimentares com diferentes idades, origens e graus de evolução tectônica, refletindo a complexa história geodinâmica da margem sul do continente sul-americano (Laux, 2021; Philipp; Pimentel; Chemale jr., 2016; Philipp; Pimentel; Basei, 2018).

A estruturação regional do escudo é controlada principalmente por lineamentos NE–SW e NW–SE, associados aos eventos tectônicos brasileiros (Porcher; Lopes, 2000). Esses processos envolveram acréscimo de crosta juvenil, formação de arcos magmáticos vulcano-plutônicos e intensa reciclagem crustal, compatíveis com modelos de tectônica de placas e sucessivos episódios de convergência continental (Laux, 2021; Philipp; Pimentel; Chemale jr., 2016).

Figura 3 – Províncias estruturais brasileiras (A) e províncias geológicas do Rio Grande do Sul (B).



Fonte: Retirado de CPRM, Projeto Escudo Sul-Rio-Grandense (2021), modificado de Laux (2021).

4.2 Escudo Sul-Rio-Grandense

O ESRG resulta de sucessivos processos de formação e deformação crustal associados principalmente aos ciclos orogênicos Transamazônico (2,26–2,00 Ga) e Brasileiro (900–535 Ma), ambos fundamentais para a evolução da porção meridional do continente sul-americano. Embora não haja registros preservados do embasamento arqueano no estado, a evolução neoproterozoica desenvolveu-se sobre fragmentos crustais mais antigos pertencentes ao Cráton Rio de La Plata (Hartmann; Chemale; Philipp, 2007).


Durante o Neoproterozoico, as interações entre placas tectônicas resultaram na forma-

ção do CDF, unidade tectônica com área aflorante do ESRG (Hartmann; Chemale; Philipp, 2007). Sua origem está associada à convergência entre os crátons Rio de La Plata e Kalahari, promovendo a justaposição de diferentes associações petrotectônicas e definindo grande parte da configuração estrutural atual do sul do Brasil (Fernandes *et al.*, 1995).

Com base em dados geoquímicos, isotópicos e geocronológicos, a porção meridional do ESRG pode ser subdividida em diferentes domínios tectônicos (Laux, 2021), conforme sintetizado na Figura 4:

- Cinturão Vila Nova (Terreno São Gabriel): composto por gnaisses tonalíticos a granodioríticos, rochas vulcanossedimentares nas fácies xisto-verde a anfibolito, unidades máfico-ultramáficas e granitos foliados.
- Cinturão Tijucas (Terreno Tijucas): constituído por rochas supracrustais metamorfizadas nas fácies xisto-verde a anfibolito, além de exposições de embasamento gnáissico paleoproterozoico.
- Batólito Pelotas: domínio composto predominantemente por granitos, gnaisses e migmatitos.
- Complexo Granulítico/Bloco Taquarembó (Terreno Taquarembó): formado por gnaisses quartzofeldspáticos, rochas máficas e ultramáficas e unidades supracrustais metamorfizadas nas fácies granulito a anfibolito, posteriormente intrudidas por granitos brasileiros.

Figura 4 – Mapa das principais unidades tectônicas do Rio Grande do Sul.



Fonte: Retirado de Laux (2021).

4.3 Domínio Ocidental do ESRG

O Cinturão Vila Nova (Chemale, 2000), também denominado Terreno São Gabriel (TSG), corresponde a um prisma acrescionário juvenil formado durante o Neoproterozoico. Esse domínio reúne associações petroectônicas relacionadas a ambientes de margem passiva, sistemas de retro-arco, ofiolitos e arcos magmáticos vulcano-sedimentares e plutônicos (Hartmann; Chemale; Philipp, 2007).

Esse domínio encontra-se delimitado estruturalmente por importantes zonas de cisalhamento regionais, com destaque para a Zona de Cisalhamento de Caçapava do Sul (ZCCS), interpretada como possível sutura tectônica, além do Lineamento Ibaré (ZCI), que marca a compartimentação sul do sistema, e, ao norte e oeste, por coberturas sedimentares fanerozoicas da Bacia do Paraná (Da Costa, 2023; Laux, 2021).

A evolução do TSG está associada à Orogênese São Gabriel, responsável pela formação de dois principais arcos magmáticos. O Arco Passinho, localizado mais ao sul, é interpretado como um arco de ilhas intraoceânico e apresenta rochas de assinatura geoquímica mais primitiva. Já o Arco Continental São Gabriel desenvolveu-se em uma margem continental ativa, registrando um magmatismo progressivamente mais evoluído (Laux, 2021; Hartmann; Chemale; Philipp, 2007; Philipp; Pimentel; Basei, 2018).

No TSG destaca-se o CMPF, que corresponde à principal sequência supracrustal da região de Caçapava do Sul (Porcher; Lopes, 2000). Essa sequência metavulcano-sedimentar é composta predominantemente por metapelitos, mármore e quartzitos, com ocorrências subordinadas de anfibolitos e metabasaltos, registrando metamorfismo variando entre as fácies xisto-verde e anfibolito inferior (Hoerlle *et al.*, 2023). Dados isotópicos indicam ainda contribuição de fontes crustais diversas, evidenciadas por zircões detríticos com ampla variação de idades, entre o Arqueano e o Neoproterozoico (De Toni; Da Costa, 2024; Philipp; Pimentel; Chemale jr., 2016).

A evolução desse conjunto foi posteriormente marcada pela intrusão do Complexo Granítico Caçapava do Sul (CGCS), um corpo granítico sintectônico alongado na direção N–S, cuja colocação ocorreu entre aproximadamente 600 e 557 Ma (Hoerlle *et al.*, 2023; Remus *et al.*, 2000). Essa intrusão está relacionada à dinâmica da ZCCS, um importante sistema transpressivo responsável por acomodar parte significativa da deformação regional (De Toni; Da Costa, 2024).

4.4 Geologia Estrutural

A evolução estrutural da região está associada aos eventos tectônicos neoproterozoicos relacionados ao desenvolvimento do CDF (Fernandes *et al.*, 1995). No domínio ocidental do TSG predominam zonas de cisalhamento transcorrentes de deformação progressiva, entre as quais se destaca a ZCCS, de direção preferencial NNE–SSW (De Toni; Da Costa, 2024).

A intrusão do CGCS ocorreu de forma sintectônica ao longo da ZCCS durante o Ediacarano, sob um regime transpressivo regional (Da Costa, 2023). Esse comportamento se expressa por indicadores cinemáticos distintos ao longo do corpo granítico, com predominância de movimentação sinistral no setor oeste e dextral no setor sudeste, caracterizando um sistema de deformação transpressiva associado à ascensão do batólito, contribuindo para o soerguimento do Alto Estrutural de Caçapava do Sul (De Toni; Da Costa, 2024).

Na área de estudo, o arcabouço estrutural é marcado por zonas transcorrentes e fraturamentos tardios com direções preferenciais NW–SE e NNW–SSE, além de estruturas subordinadas NE–SW, que afetam tanto CMPF quanto os corpos graníticos intrusivos. Essas descontinuidades exercem importante controle sobre a compartimentação dos taludes e do relevo, além de condicionarem a distribuição espacial dos corpos carbonáticos, que frequentemente ocorrem como lentes alongadas segundo a foliação regional. Também influenciam a circulação de fluidos hidrotermais e a heterogeneidade litológica observada nos afloramentos (Da Costa, 2023).


4.5 Geologia Local

A área de estudo localiza-se na região central do estado do Rio Grande do Sul, no município de Caçapava do Sul, especificamente na localidade industrial de Caieiras. O município

situa-se a aproximadamente 260 km de Porto Alegre, com acesso principal pela BR-290 até o entroncamento com a BR-392, seguindo em direção ao sul.

A região das Caieiras concentra importantes atividades de exploração de calcário e mármore no município (Rangel *et al.*, 2014), sendo caracterizada pela presença de cavas e taludes com elevada exposição rochosa. A área selecionada para o desenvolvimento deste trabalho corresponde a uma dessas frentes de lavra, conforme ilustrado na Figura 5.

Figura 5 – Mapa de localização da área de estudo.



Fonte: Autora (2026).

A geologia local é representada por uma sequência metassedimentar química e clástica pertencente ao CMPF, composta principalmente por mármore, xistos e quartzitos. Esses metassedimentos encontram-se intrudidos por corpos graníticos e, subordinadamente, por intrusões anfibolíticas (Bitencourt, 1983).

A exposição dos taludes permite a observação direta das relações de contato entre as diferentes litologias, bem como das estruturas associadas à deformação regional (Figura 6).

Figura 6 – Fotografia aérea evidenciando as bancadas da cava de mineração.



Fonte: Autora (2026).

O principal litotipo presente na área corresponde a mármore dolomíticos com coloração variando entre branco e cinza claro. Essas rochas apresentam textura predominantemente granoblástica e granulometria fina a média de tamanho variando entre 0,2 e 0,8 cm. Mineralogicamente, são compostas essencialmente por dolomita e calcita, cuja distinção macroscópica é dificultada em observações a olho nu ou com lupa de mão.

Além dos mármore, ocorrem níveis quartzíticos, xistos e zonas de contato com corpos graníticos intrusivos, conferindo elevada heterogeneidade textural e cromática aos afloramentos (Figura 7).

Figura 7 – Perfil das principais litologias observadas na área de estudo: o mármore, o xisto e o granito.



Fonte: Autora (2026).

A exposição contínua dos taludes, associada ao contraste visual entre as litologias e à presença de contatos bem definidos, torna a área particularmente favorável à aplicação de técnicas de fotogrametria digital e segmentação semântica voltadas à distinção litológica e à construção de modelos geológicos tridimensionais.

5 MATERIAIS E MÉTODOS

O trabalho foi desenvolvido a partir de uma base fotogramétrica adquirida em uma frente de lavra de mármore localizada na região das Caieiras, no município de Caçapava do Sul, RS. A área foi tratada como uma superfície geológica exposta, na qual a geometria dos taludes, a continuidade dos contatos e as diferenças visuais entre os materiais puderam ser registradas por imagens aéreas e posteriormente convertidas em produtos tridimensionais.

A metodologia foi organizada para transformar a informação visual do afloramento em modelos geológicos temáticos. Para isso, as imagens do levantamento foram processadas inicialmente no ambiente fotogramétrico, gerando a base geométrica da frente de lavra. Em seguida, parte das imagens foi interpretada manualmente, considerando as unidades reconhecíveis. Essas interpretações serviram como referência para a transferência automática de rótulos, para o treinamento da rede neural e para a predição das máscaras litológicas. Ao final do processo, as máscaras classificadas foram novamente associadas à geometria fotogramétrica, permitindo representar em três dimensões a distribuição espacial das classes mapeadas.

A definição das classes não teve como objetivo substituir uma descrição petrográfica detalhada, mas organizar a superfície exposta em categorias geológicas operacionais. Assim, foram utilizadas três classes principais: Mármore, Intrusão e Estéril. Essa divisão foi suficiente para o objetivo do trabalho porque separa os principais domínios reconhecíveis na frente de lavra, distinguindo a rocha carbonática explorada, os corpos ou faixas intrusivas que interrompem essa continuidade e os materiais sem interesse direto para a interpretação litológica principal. A classificação foi, portanto, conduzida na escala da imagem e do modelo tridimensional, considerando aquilo que poderia ser reconhecido de forma consistente por cor, textura, continuidade superficial e relação de contato.

5.1 Fluxo de Trabalho


A metodologia adotada neste estudo foi organizada em três etapas principais, conforme apresentado no fluxograma da Figura 8. Essa divisão permitiu estruturar as atividades desenvolvidas desde o planejamento da pesquisa até a obtenção do modelo geológico tridimensional temático.

Para a realização do estudo, as atividades foram distribuídas nas seguintes etapas:

1. **Etapa preliminar** – definição do estudo e revisão bibliográfica sobre fotogrametria digital, geologia e aplicações de IA na segmentação de imagens geológicas;
2. **Etapa de campo** – aquisição das imagens do afloramento utilizando VANT equipado com sistema RTK e organização inicial dos dados obtidos;
3. **Etapa pós-campo** – organização e processamento das imagens, envolvendo o processamento fotogramétrico para geração do modelo tridimensional e o processamento com IA

para segmentação das litologias, culminando na integração dos resultados para a construção do modelo geológico tridimensional temático.

Figura 8 – Fluxograma das etapas metodológicas desenvolvidas neste trabalho.




Fonte: Autora (2026).

5.2 Aquisição dos Dados

A base de dados utilizada neste trabalho foi composta por imagens aéreas obtidas na região das Caieiras, em uma frente de lavra de mármore. O levantamento aerofotogramétrico e o planejamento dos voos foram realizados pelo Laboratório de Modelagem Geológica (LAB-MODEL) da Universidade Federal do Pampa (UNIPAMPA).


As imagens foram adquiridas em 08 de novembro de 2024, com o uso de um drone DJI Matrice 300 equipado com sistema de posicionamento RTK e câmera Zenmuse P1 de 35 mm (Figura 9), resolução de 8192×5460 pixels, altitude média de voo de 35,6 m e resolução espacial de 4,80 mm/pixel. A campanha de aquisição foi realizada ao longo de uma tarde, cobrindo uma área de 0,0375 km². A Figura 10 apresenta a distribuição espacial das fotografias e suas respectivas posições durante o voo, registradas diretamente pelo sistema RTK. Esse sistema permitiu o georreferenciamento direto das imagens, reduzindo a necessidade de etapas adicionais de georreferenciamento durante o processamento fotogramétrico.

Figura 9 – Equipamentos e infraestrutura utilizados durante o levantamento fotogramétrico: (a) antena RTK; (b) drone DJI Matrice 300 equipado com câmera Zenmuse P1; e (c) local de decolagem e pouso.



Fonte: Autora (2026).

Figura 10 – Distribuição espacial das fotografias após o alinhamento no Metashape. Os retângulos azuis representam as posições e orientações das câmeras durante a aquisição das imagens, enquanto as linhas indicam a sequência de aquisição ao longo da missão de voo.



Fonte: Autora (2026).

O voo foi planejado para cobrir integralmente os taludes expostos na frente de lavra e para manter sobreposição suficiente entre fotografias consecutivas. Essa condição foi necessária para garantir a reconstrução da geometria da área no processamento fotogramétrico e, posteriormente, permitir a associação entre as imagens, as máscaras litológicas e os modelos tridimensionais.

Após a aquisição das imagens em campo, as fotografias foram organizadas em diretórios de trabalho e utilizadas como entrada nas etapas de reconstrução fotogramétrica, rotulação manual, transferência de rótulos e segmentação semântica.

5.3 Processamento Fotogramétrico

O processamento fotogramétrico foi executado no software Agisoft Metashape Profissional, versão 2.3.1. As fotografias aéreas foram importadas para o projeto e processadas seguindo o fluxo de reconstrução fotogramétrica disponível no programa.

A primeira etapa consistiu no alinhamento das fotografias. Nessa fase, o Metashape identificou pontos homólogos entre as imagens e estimou a posição relativa das câmeras. Como resultado, foi gerada a nuvem de pontos esparsa, utilizada para verificar a consistência inicial do bloco fotogramétrico e a cobertura da área de estudo. Com o alinhamento concluído, foram gerados os mapas de profundidade. Essa etapa foi configurada com qualidade média e filtragem suave, buscando manter um equilíbrio entre detalhamento geométrico e viabilidade de proces-

samento. A partir dos mapas de profundidade, foi produzida a nuvem de pontos densa, que serviu como base para a reconstrução da superfície tridimensional da frente de lavra.

Na etapa seguinte, foi construída a malha tridimensional. A malha foi gerada a partir dos mapas de profundidade, utilizando superfície arbitrária, elevada densidade de faces e interpolação habilitada. A interpolação permitiu preencher pequenas discontinuidades da superfície reconstruída em regiões onde a densidade de pontos era menor, produzindo uma representação mais contínua da malha. A opção por superfície arbitrária foi adequada ao contexto da frente de lavra porque os taludes não se comportam como uma superfície topográfica simples. A exposição apresenta variações abruptas, faces inclinadas, quebras de relevo e discontinuidades associadas ao corte da lavra. A representação por malha permitiu preservar essas variações e manter a leitura tridimensional das unidades ao longo da superfície exposta.

Depois da geração da malha, foram produzidas as texturas associadas ao modelo. O mapeamento foi realizado com a opção *Keep UV*, e a mistura das imagens foi configurada no modo mosaico. Esse procedimento permitiu manter a correspondência entre a geometria tridimensional, as fotografias originais e as máscaras produzidas pela segmentação. Como a classificação litológica foi feita sobre as imagens, a coerência entre textura e geometria foi necessária para que os rótulos não fossem tratados apenas como uma informação bidimensional, mas como uma interpretação projetada sobre a superfície do afloramento.

Os produtos fotogramétricos resultantes dessa etapa foram utilizados como base geométrica para a construção dos modelos geológicos tridimensionais.

5.4 Rotulação Manual

A preparação do conjunto inicial de treinamento começou pela escolha de imagens representativas da área de estudo. Foram selecionadas dez imagens do levantamento aerofotogramétrico, considerando variações de iluminação, visibilidade dos taludes, presença das principais unidades e ocorrência de contatos reconhecíveis entre os materiais. A seleção não buscou apenas imagens visualmente melhores, mas fotografias que reunissem situações geológicas relevantes para a classificação.

A rotulação foi realizada por meio de interpretação visual direta das imagens, utilizando o software GIMP (*GNU Image Manipulation Program*) para a criação das máscaras de segmentação. Em cada fotografia selecionada, foram delimitadas manualmente as áreas correspondentes às classes litológicas de interesse. A separação das classes levou em conta principalmente a coloração, a textura superficial e a relação de contato observada entre os materiais.

Foram definidas três classes para o treinamento, conforme Tabela 1:

Tabela 1 – Classes utilizadas na rotulação manual e principais características observadas nas imagens.

Classe	Características visuais predominantes	Critérios de interpretação
Mármore	Tonalidades claras, textura relativamente homogênea e ampla continuidade espacial na frente de lavra.	Unidade carbonática principal, identificada pela coloração clara e pela predominância na superfície exposta.
Intrusão	Faixas ou corpos estreitos, geralmente mais escuros e com maior contraste em relação ao mármore.	Feições descontínuas, delimitadas principalmente pelo contraste visual e pelas relações de contato com as demais unidades.
Estéril	Materiais de coloração variável, frequentemente mais escuros ou avermelhados, com textura heterogênea.	Regiões que não pertencem à unidade carbonática principal e que correspondem aos materiais de cobertura e demais porções sem interesse de lavra.

Fonte: Autora.


As máscaras resultantes dessa etapa formaram o conjunto inicial de dados rotulados. Esse conjunto foi utilizado primeiro na transferência automática de rótulos e, posteriormente, no treinamento supervisionado da rede neural. A rotulação manual foi mantida restrita às imagens selecionadas, enquanto a ampliação do banco de dados foi realizada por propagação automática.

5.5 Transferência de Rótulos

Após a produção das máscaras manuais, foi executada a transferência automática de rótulos para ampliar o conjunto de treinamento. Essa etapa foi implementada em Python, utilizando as bibliotecas *OpenCV* (OpenCV, 2026), *NumPy* (NumPy Developers, 2026), *Matplotlib* (Matplotlib Development Team, 2026), *TensorFlow* (TensorFlow, 2026), *scikit-image* (scikit-image Developers, 2026) e *scikit-learn* (scikit-learn Developers, 2026).

O procedimento partiu das imagens previamente rotuladas e explorou a sobreposição existente entre as fotografias obtidas no levantamento aerofotogramétrico. Como uma mesma porção da frente de lavra é registrada em diferentes imagens, ainda que sob pequenas variações de perspectiva, escala e iluminação, foi possível estabelecer correspondências entre essas fotografias e propagar automaticamente as máscaras para novas imagens. A Figura 11 apresenta um exemplo do estabelecimento de correspondências entre pontos característicos em duas imagens sobrepostas, ilustrando o princípio utilizado para identificar feições equivalentes antes da propagação das máscaras.


Figura 11 – Exemplo de correspondências entre pontos característicos identificados em duas imagens sobrepostas utilizando o algoritmo SIFT.



Fonte: Adaptado de OpenCV (2025).

Para essa identificação de correspondências foram empregadas técnicas de visão computacional disponíveis na biblioteca OpenCV (OpenCV, 2024). Inicialmente, o algoritmo SIFT (*Scale-Invariant Feature Transform*) foi utilizado para detectar pontos característicos nas imagens e gerar descritores capazes de representar essas feições de forma robusta a variações de escala e rotação. Em seguida, os descritores foram comparados utilizando o algoritmo FLANN (*Fast Library for Approximate Nearest Neighbors*), que realiza a busca eficiente pelas correspondências mais semelhantes entre duas imagens, conforme observado na Figura 12 em um exemplo das imagens obtidas pelo drone.

Figura 12 – Correspondências estabelecidas entre imagens sobrepostas da bancada.



Fonte: Autora (2026).

As correspondências obtidas foram submetidas ao teste da razão de Lowe (*Lowe's Ratio Test*), que mantém apenas aquelas consideradas suficientemente distintas das demais possibi-

dades de associação, reduzindo a ocorrência de correspondências ambíguas (OpenCV, 2024). Posteriormente, foi aplicado o algoritmo RANSAC (*Random Sample Consensus*) para eliminar associações incompatíveis com a geometria comum entre as imagens, preservando apenas as correspondências consistentes para a projeção das máscaras.

Durante a transferência foi utilizado o parâmetro *distance buffer* igual a 10, responsável por controlar a tolerância espacial adotada na associação entre as feições correspondentes e os rótulos propagados. Ao final do processo, as imagens e suas respectivas máscaras foram organizadas em um banco de dados destinado ao treinamento supervisionado da rede neural.

Esse procedimento permitiu ampliar o conjunto de treinamento sem a necessidade de rotular manualmente todas as fotografias do levantamento, reduzindo o esforço de interpretação e mantendo as classes litológicas definidas na etapa inicial.

5.6 Segmentação Semântica

A segmentação semântica foi realizada em ambiente Python, utilizando a biblioteca TensorFlow. O desenvolvimento e a execução dos códigos foram feitos no Spyder, distribuído pela plataforma Anaconda.

A rede foi configurada no formato U-Net, com cinco níveis de profundidade (*blocks* = 5) e trinta e dois canais iniciais (*channels* = 32), sendo preparada para classificar três classes de saída: Mármore, Intrusão e Estéril.

O processo foi dividido em três momentos: preparação do banco de dados, treinamento, e aplicação do modelo. Essa divisão foi necessária para manter o controle sobre o tamanho das imagens, a correspondência entre imagens e máscaras e a recomposição dos resultados após a inferência.

5.6.1 Particionamento das Imagens

As imagens originais do levantamento apresentavam resolução elevada. Para viabilizar o treinamento dentro das limitações de memória disponíveis, as imagens foram particionadas em blocos menores de processamento, denominados *tiles*. A resolução de processamento foi ajustada para 384×256 pixels.

A escolha desse tamanho considerou o equilíbrio entre viabilidade computacional e preservação da informação geológica necessária para a classificação. Blocos muito grandes aumentariam o custo de processamento e poderiam limitar o treinamento. Blocos muito pequenos, por outro lado, tenderiam a reduzir o contexto espacial disponível para a rede, dificultando a leitura de contatos, continuidade de faixas e relações entre materiais vizinhos. A resolução adotada permitiu manter detalhes visuais suficientes para a distinção das classes, sem exceder a capacidade de processamento disponível.

Após a inferência, os blocos processados foram recompostos, de modo que a segmentação final voltasse a representar a imagem completa. Com isso, foi possível trabalhar com

imagens de alta resolução sem perder a correspondência espacial entre fotografia original, máscara predita e produto fotogramétrico.

5.6.2 Treinamento da Rede Neural

O treinamento supervisionado foi realizado com as imagens rotuladas manualmente e com as máscaras adicionais geradas pela transferência automática de rótulos. Antes do treinamento, as imagens e máscaras foram organizadas em pares correspondentes, garantindo que cada entrada da rede tivesse sua respectiva máscara de referência.

Foram utilizados lotes de dez imagens, definidos pelo parâmetro *batch size* = 10, e cem épocas de treinamento, definidas pelo parâmetro *epochs* = 100. Inicialmente, foi separado um subconjunto de validação correspondente a 10% dos dados disponíveis, indicado pelo parâmetro *validation split* = 0,1. Esse treinamento inicial foi utilizado para acompanhar o comportamento da rede durante o ajuste dos pesos e verificar a resposta do modelo diante de imagens não utilizadas diretamente no treinamento.

A validação foi necessária porque as classes apresentavam diferenças visuais associadas à própria superfície da rocha, mas também sofriam influência de sombra, orientação do talude, alteração superficial e variação de textura. Assim, o acompanhamento das métricas não foi interpretado apenas como desempenho computacional, mas como indicação da capacidade do modelo de manter coerência entre a segmentação e a organização geológica observada nas imagens.

Após a análise dos resultados obtidos na validação, foi realizado um novo treinamento utilizando todo o conjunto de dados rotulados. Esse segundo treinamento teve como objetivo gerar o modelo final empregado na predição das máscaras litológicas do levantamento.

Todos os procedimentos de treinamento da rede neural e geração das predições foram executados em um computador equipado com processador Intel® Core™ i5-13600KF (3,50 GHz), 32 GB de memória RAM e placa de vídeo NVIDIA GeForce RTX 3060, utilizando o sistema operacional Windows 11 Pro.

5.6.2.1 Parâmetros do Treinamento

Os principais parâmetros utilizados durante o treinamento da rede neural são apresentados na Tabela 2.

Tabela 2 – Principais parâmetros utilizados no treinamento da rede neural U-Net.

Parâmetro	Valor
Arquitetura	U-Net
Número de classes	3
Classes	Mármore, Intrusão e Estéril
Channels	32
Blocks	5
Batch size	10
Epochs	100
Resolução de processamento	384×256 pixels
Framework	TensorFlow
Validation split	0,1
Distance buffer	10

Fonte: Autora (2026).

5.6.3 Predição das Máscaras

Com o modelo final treinado, foi executada a etapa de predição nas imagens. As imagens foram processadas no mesmo padrão utilizado no treinamento, respeitando a resolução de 384×256 pixels e o particionamento em blocos.

Para cada imagem processada, a rede gerou uma máscara de segmentação contendo as três classes definidas no trabalho. As máscaras resultantes foram verificadas visualmente e organizadas para uso na etapa de construção dos modelos tridimensionais temáticos. Essa verificação foi necessária porque a resposta da rede, embora automatizada, ainda precisava ser analisada à luz da coerência geológica da superfície. Essas máscaras passaram a representar a distribuição espacial das classes Mármore, Intrusão e Estéril nas imagens, servindo como base para a individualização das unidades litológicas.

5.7 Construção dos Modelos Geológicos Tridimensionais

A construção dos modelos geológicos tridimensionais foi realizada a partir da associação entre as máscaras preditas pela rede neural e os produtos fotogramétricos gerados no Metashape. As máscaras foram utilizadas para separar as regiões correspondentes a cada classe litológica nas imagens do levantamento.

O procedimento foi executado por classe. Inicialmente, foram selecionadas as imagens e máscaras correspondentes à classe Mármore. A partir dessa seleção, foi gerado um modelo tridimensional com textura temática associada a essa unidade. O mesmo procedimento foi repetido para as classes Intrusão e Estéril. Para cada unidade litológica, foram produzidos modelos independentes no Metashape. Em seguida, esses modelos foram integrados em uma única representação tridimensional temática da frente de lavra. Essa organização permitiu visualizar a distribuição espacial das classes classificadas e observar a continuidade das unidades ao longo

dos taludes.

A integração final permitiu visualizar a frente de lavra como um modelo tridimensional classificado, no qual as unidades deixam de ser apenas polígonos ou máscaras bidimensionais e passam a ocupar uma posição espacial coerente com a geometria do afloramento.

5.7.1 Avaliação do Desempenho da Rede

O desempenho da rede neural foi avaliado a partir das métricas obtidas durante a etapa de validação. Para essa avaliação foram utilizados os valores de *accuracy*, *precision*, *recall*, *F1-score* e *support*, métricas amplamente empregadas na avaliação de modelos de classificação e segmentação semântica (scikit-learn Developers, 2026).

As métricas apresentadas são calculadas a partir da matriz de confusão, composta pelos verdadeiros positivos (*True Positives* – TP), correspondentes às amostras corretamente classificadas como pertencentes à classe; verdadeiros negativos (*True Negatives* – TN), referentes às amostras corretamente classificadas como não pertencentes à classe; falsos positivos (*False Positives* – FP), que representam amostras incorretamente atribuídas à classe; e falsos negativos (*False Negatives* – FN), correspondentes às amostras da classe que não foram identificadas pelo modelo.

A métrica *precision* representa a proporção de predições positivas corretamente classificadas pelo modelo, sendo definida pela Equação 5.1.

$$Precision = \frac{TP}{TP + FP} \quad (5.1)$$

O *recall* mede a capacidade do modelo em identificar corretamente os elementos pertencentes a uma determinada classe, conforme expresso na Equação 5.2.

$$Recall = \frac{TP}{TP + FN} \quad (5.2)$$

O *F1-score* corresponde à média harmônica entre *precision* e *recall*, permitindo avaliar simultaneamente a precisão e a capacidade de detecção do modelo, sendo calculado de acordo com a Equação 5.3.

$$F_1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (5.3)$$

A *accuracy* expressa a proporção de classificações corretas em relação ao total de amostras avaliadas, conforme descrito na Equação 5.4.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.4)$$

O *support* corresponde ao número de amostras reais pertencentes a cada classe presentes no conjunto de validação. Diferentemente das demais métricas, ele não representa uma medida de desempenho do modelo, sendo utilizado apenas para indicar a quantidade de amostras disponíveis em cada classe.

As métricas foram utilizadas para verificar a resposta do modelo durante o treinamento e para comparar o desempenho entre as classes Mármore, Intrusão e Estéril. A interpretação desses valores foi feita em conjunto com a análise visual das máscaras, pois uma métrica global elevada não garante, isoladamente, boa representação dos contatos litológicos. Por esse motivo, os resultados quantitativos foram tratados como apoio à avaliação geológica das segmentações, e não como único critério de validação.

6 RESULTADOS E DISCUSSÕES

Os resultados foram organizados a partir das três saídas principais do fluxo de trabalho: a reconstrução fotogramétrica da frente de lavra, a segmentação das classes litológicas nas imagens e a projeção dessas classes no modelo tridimensional.

A análise concentrou-se nas classes Mármore, Intrusão e Estéril, definidas para a interpretação da frente de lavra. O interesse não foi apenas verificar se a rede apresentou valores altos de acurácia, mas observar se as classes mantiveram relação espacial plausível com a superfície reconstruída, especialmente nas zonas de contato, nas faixas descontínuas e nas áreas afetadas por sombra ou variação textural.

6.1 Processamento Fotogramétrico

O processamento fotogramétrico resultou em um modelo tridimensional capaz de representar a geometria principal da frente de lavra. Das 6.816 imagens processadas, valor correspondente ao somatório dos três conjuntos utilizados na geração dos modelos temáticos, com 2.272 imagens associadas a cada classe, desse total consolidado, 6.810 estações de câmera foram alinhadas. Assim, os valores apresentados são resultados do processamento organizado por classe.

A distribuição das câmeras apresentou elevada sobreposição na maior parte da frente de lavra, condição importante tanto para a reconstrução dos taludes quanto para a posterior associação entre imagens, máscaras e modelos tridimensionais.

O alinhamento gerou 1.604.879 pontos de amarração, distribuídos em 20.479.024 projeções. O erro médio de reprojeção foi de 0,904 pixel. Para a escala deste trabalho, esse valor indicou ajuste suficiente entre fotografias, posição das câmeras e superfície reconstruída. A etapa também permitiu verificar que a geometria geral dos taludes foi preservada, sem perdas relevantes nas áreas principais de interpretação (Tabela 3).

Tabela 3 – Síntese dos principais resultados do alinhamento fotogramétrico.

Parâmetro	Resultado
Imagens processadas no relatório consolidado	6.816
Imagens por conjunto temático	2.272
Estações de câmera alinhadas	6.810
Altitude média de voo	35,6 m
Resolução espacial	4,80 mm/pixel
Área de cobertura	0,0375 km ²
Pontos de amarração	1.604.879
Projeções	20.479.024
Erro de reprojeção	0,904 pixel
Modelo da câmera	Zenmuse P1, 35 mm
Resolução da imagem	8192 × 5460 pixels

Fonte: Autora (2026).

A estimativa média de erro das posições das câmeras foi de 5,40 cm no eixo X, 6,80 cm no eixo Y e 3,58 cm no eixo Z, resultando em erro total médio de 9,39 cm. Como a análise proposta neste trabalho está voltada à distribuição litológica sobre a superfície exposta, e não à demarcação cadastral de limites, esse erro não inviabilizou a aplicação do modelo. Ainda assim, ele deve ser considerado na leitura dos contatos, principalmente quando as feições interpretadas apresentam pequena espessura ou geometria descontínua.

Após o alinhamento, foram gerados 1.977 mapas de profundidade, configurados com qualidade média e filtragem suave. A nuvem de pontos densa resultante apresentou 310.656.640 pontos, com precisão coordenada de 4,80 mm. Essa densidade permitiu representar as principais irregularidades da frente de lavra, incluindo mudanças de inclinação, quebras de relevo e superfícies expostas nos taludes.

A reconstrução também gerou um modelo digital de elevação com resolução de 3,25 cm/pixel e densidade de 946 pontos/m². Embora esse produto não seja o resultado final da modelagem litológica, ele contribuiu para verificar a distribuição altimétrica da área e a continuidade geral da superfície reconstruída (Tabela 4). Na leitura geológica, essa etapa funcionou como controle da forma do afloramento antes da aplicação das classes temáticas.

Tabela 4 – Produtos gerados no processamento fotogramétrico.

Produto	Resultado
Mapas de profundidade	1.977
Nuvem de pontos densa	310.656.640 pontos
Precisão coordenada da nuvem	4,80 mm
Modelo inicial	71.162.369 faces e 35.612.503 vértices
Modelo final	19.809.536 faces e 9.912.488 vértices
Textura final	2048 × 2048 × 168
Resolução do MDE	3,25 cm/pixel
Densidade do MDE	946 pontos/m ²

Fonte: Autora (2026).

A malha final foi composta por 19.809.536 faces e 9.912.488 vértices. A redução em relação ao modelo inicial, feita por meio da decimação de faces, tornou o arquivo mais manejável no ambiente do Metashape, sem eliminar a geometria necessária para a interpretação dos taludes. A textura aplicada ao modelo manteve as diferenças cromáticas mais relevantes da frente de lavra, como as porções claras associadas ao mármore, os materiais superiores de tonalidade mais escura vinculadas ao estéril e as faixas de contraste relacionadas às intrusões.

A Figura 13 apresenta o modelo tridimensional texturizado gerado no Metashape, utilizado como base espacial para a integração posterior das classes litológicas.

Figura 13 – Modelo tridimensional texturizado da área de estudo obtido por processamento fotogramétrico.

Perspective 30°

Snap: Axis, 3D



Fonte: Autora (2026).

Visualmente, a superfície apresentou continuidade suficiente para acompanhar os principais domínios da lavra. As lacunas observadas em bordas e regiões com menor cobertura não comprometeram a leitura da área central, onde se concentrou a avaliação das classes.

6.2 Segmentação Semântica

A avaliação quantitativa da U-Net apresentou elevado desempenho global, com acurácia de 0,99. As métricas de precisão, *recall* e *F1-score* também apresentaram valores elevados, indicando boa capacidade de reprodução das máscaras de referência. Os resultados obtidos para cada classe são apresentados na Tabela 5.

Além das classes geológicas, ocorre a categoria *Other*. Essa classe foi mantida como categoria auxiliar da segmentação, representando pixels não atribuídos diretamente a nenhuma das outras classes, como, por exemplo, vegetação, equipamentos e outras feições não contempladas pelas classes litológicas.

Tabela 5 – Métricas de validação obtidas para a segmentação semântica.

Classe	Suporte	Precisão	Recall	F1-score
Estéril	122.603	1,00	0,99	0,99
Intrusão	15.677	0,91	0,83	0,87
Mármore	298.481	0,99	0,99	0,99
<i>Other</i>	54.759	0,98	0,99	0,99
Acurácia global	491.520		0,99	
Média macro	491.520	0,97	0,95	0,96
Média ponderada	491.520	0,99	0,99	0,99

Fonte: Autora (2026).

A classe Mármore apresentou precisão, *recall* e *F1-score* de 0,99, resultado associado tanto à sua maior representatividade no conjunto, com 298.481 pixels, quanto à continuidade visual da unidade na frente de lavra. Nas áreas em que a tonalidade clara e o padrão textural estavam bem definidos, a rede reconheceu o mármore com baixa fragmentação.

A classe Estéril também alcançou *F1-score* de 0,99 e, embora reúna materiais visualmente mais variados, apresentou suporte elevado, com 122.603 pixels, o que favoreceu o aprendizado dos padrões predominantes, principalmente nos setores em que o contraste com o mármore era mais evidente.

A classe Intrusão concentrou as maiores limitações do modelo, apresentando precisão de 0,91, *recall* de 0,83 e *F1-score* de 0,87. Esse desempenho reflete as características da própria classe, marcada por menor área de ocorrência, feições mais estreitas, contatos menos regulares e maior influência de sombras e texturas semelhantes às classes vizinhas.

De modo geral, os resultados indicam que a U-Net apresentou elevada capacidade de segmentação para as classes mais representativas da frente de lavra. Em contrapartida, a classe Intrusão, que possui o menor suporte no conjunto avaliado (15.677 pixels), concentrou as prin-

cipais limitações do modelo. Esse resultado indica que o aumento da representatividade dessa classe no conjunto de treinamento pode ser mais efetivo para melhorar o desempenho da segmentação do que alterações gerais na arquitetura da rede.

6.3 Avaliação Visual das Segmentações

A avaliação visual confirmou o comportamento observado nas métricas de validação, conforme exemplificado na Figura 14. De maneira geral, as classes mais extensas apresentaram maior continuidade espacial, enquanto as feições mais estreitas e localizadas exibiram maior fragmentação.


Nas áreas classificadas como Mármore, as máscaras acompanharam adequadamente a distribuição da unidade carbonática ao longo da frente de lavra. As principais divergências ocorreram em trechos de sombra e em zonas de contato, mas sem comprometer a identificação geral da unidade.

Para o Estéril, a segmentação reproduziu satisfatoriamente os domínios superiores e as áreas visualmente distintas do mármore. As maiores incertezas foram observadas em regiões de transição gradual, onde os limites entre as classes não se apresentam de forma abrupta na própria imagem.

As feições classificadas como Intrusão apresentaram comportamento mais descontínuo. Em setores de maior contraste visual, a rede conseguiu individualizar essas ocorrências de maneira coerente, entretanto, em áreas de contato difuso, observou-se perda de continuidade e fragmentação das máscaras.

A classe *Other* concentrou principalmente regiões sem correspondência direta com as classes litológicas adotadas, como vegetação, equipamentos e outros elementos presentes na cena. Sua utilização contribuiu para evitar que todos os pixels fossem forçados para uma das classes geológicas de interesse. Além da predição das classes, foi gerado um mapa de entropia para representar a incerteza da classificação, destacando as regiões onde o modelo apresentou menor confiança na atribuição das classes litológicas.

Figura 14 – Resultado da segmentação litológica apresentando a imagem original, a predição e mapa de entropia, empregado como medida da incerteza da classificação.



Fonte: Autora (2026).

6.4 Reconstrução Tridimensional das Litologias

A aplicação das máscaras permitiu gerar modelos separados para as três classes. As nuvens de pontos, malhas e texturas foram avaliadas por classe, conforme demonstrado abaixo, permitindo observar a distribuição espacial de cada litologia antes da integração final.

6.4.1 Modelo Tridimensional do Mármore

O modelo da classe Mármore apresentou a distribuição mais contínua entre os produtos gerados. Essa resposta permitiu acompanhar a distribuição da unidade carbonática ao longo dos taludes, preservando a geometria geral da frente de lavra. O mármore acompanhou as

faixas claras da superfície exposta e manteve leitura espacial compatível com a morfologia reconstruída.

A representação obtida indica que a rede conseguiu preservar a leitura da principal unidade da frente de lavra. As pequenas variações observadas nas bordas do modelo não comprometeram a interpretação geral, permanecendo restritas a setores de menor exposição.

6.4.2 Modelo Tridimensional das Intrusões

A classe Intrusão teve comportamento mais restrito e fragmentado. No modelo tridimensional, as intrusões foram representadas como feições localizadas, o que evidenciou a dificuldade de manter sua continuidade espacial ao longo da superfície reconstruída. Por isso, pequenos deslocamentos na máscara ou alterações locais de iluminação tiveram maior efeito sobre sua representação final. Mesmo assim, a classe foi identificada em setores onde havia contraste visual suficiente em relação ao mármore e ao estéril.

Esse comportamento está relacionado tanto à geometria mais restrita das intrusões quanto à maior sensibilidade dessa classe aos contatos com as unidades vizinhas.

6.4.3 Modelo Tridimensional do Estéril

A classe Estéril concentrou-se principalmente em porções superiores e em áreas de maior variação visual. O resultado foi adequado para separar os domínios que não correspondiam diretamente à unidade carbonática principal. No modelo tridimensional, essa classe apresentou transições menos definidas em alguns setores, refletindo a variabilidade visual observada na própria superfície da frente de lavra.


O estéril funciona como domínio de separação entre a unidade carbonática de interesse e as áreas mais heterogêneas da frente de lavra. Essa distinção possui valor operacional, pois auxilia na organização visual dos setores que não correspondem diretamente ao mármore ou às intrusões individualizadas.

6.4.4 Integração dos Modelos Litológicos

A integração dos modelos permitiu representar a distribuição espacial das litologias diretamente sobre a geometria da frente de lavra, fornecendo uma base tridimensional para a análise dos contatos e da continuidade das unidades mapeadas.

Para a geração dessa representação, as máscaras produzidas pela segmentação foram utilizadas para classificar a nuvem de pontos no Metashape, empregando as classes disponíveis no software apenas como recurso para diferenciar visualmente as litologias mapeadas. Posteriormente, os modelos correspondentes a cada litologia foram integrados no CorelDRAW 2021, resultando no modelo geológico tridimensional temático apresentado na Figura 15.

Figura 15 – Modelo geológico temático gerado pela integração do processamento fotogramétrico com a segmentação litológica.



Fonte: Autora (2026).

6.5 Integração entre Segmentação e Modelo Tridimensional

A integração das máscaras ao modelo tridimensional permitiu avaliar se a segmentação mantinha coerência espacial quando projetada sobre a frente de lavra. Essa etapa foi decisiva porque inconsistências pouco evidentes na imagem plana tornam-se mais perceptíveis na superfície tridimensional, especialmente em contatos inclinados, faces irregulares ou áreas de menor cobertura fotogramétrica.

A projeção das classes sobre a geometria reconstruída mostrou que, de modo geral, o padrão observado nas máscaras bidimensionais foi preservado no ambiente tridimensional. A visualização integrada permitiu verificar a continuidade das unidades, a posição relativa entre as classes e a coerência dos contatos ao longo da superfície exposta, fornecendo uma perspectiva que não seria obtida apenas pela análise das imagens individuais.

De modo geral, o fluxo permitiu converter a classificação das imagens em uma representação geológica espacializada. Embora a metodologia não elimine a necessidade de validação por especialista, ela reduz o esforço manual de delimitação e fornece uma base visual para a análise dos contatos, da continuidade e da distribuição das unidades litológicas na frente de lavra.

7 CONSIDERAÇÕES FINAIS

As análises realizadas ao longo deste trabalho permitiram avaliar a aplicação integrada de fotogrametria digital, transferência de rótulos e segmentação semântica por U-Net na construção de modelos geológicos tridimensionais temáticos de uma frente de lavra de mármore na região das Caieiras, em Caçapava do Sul. A partir dos resultados obtidos, verificou-se que o fluxo proposto foi capaz de transformar imagens fotogramétricas em máscaras litológicas e, posteriormente, em representações tridimensionais individualizadas para as classes Mármore, Intrusão e Estéril. Dessa forma, a metodologia mostrou-se adequada como ferramenta de apoio à interpretação geológica, especialmente por permitir a associação entre classificação visual das imagens e geometria real do afloramento.

O processamento fotogramétrico gerou uma base tridimensional adequada para a continuidade do trabalho, com elevado aproveitamento das imagens no processamento consolidado, erro médio de reprojeção inferior a um pixel e densidade suficiente para representar a frente de lavra em escala de afloramento. A nuvem de pontos, a malha e o modelo texturizado permitiram preservar a geometria principal dos taludes e serviram como suporte para a aplicação das máscaras produzidas pela rede neural.

A etapa de segmentação semântica também apresentou resultados positivos. A U-Net alcançou acurácia global de 0,99, indicando elevada capacidade de reconhecimento das classes definidas. As classes Mármore e Estéril apresentaram os melhores resultados, com *F1-score* de 0,99. Esse desempenho está relacionado à maior representatividade dessas classes no conjunto de dados e à maior continuidade visual dos domínios correspondentes nas imagens.

A classe Intrusão concentrou as principais limitações do modelo, apresentando *F1-score* de 0,87. Esse resultado não comprometeu a aplicação geral da metodologia, mas indicou que feições de menor área, geometria mais estreita e contatos menos regulares exigem maior volume de exemplos rotulados e maior controle na interpretação das máscaras. A menor resposta dessa classe foi coerente com sua própria expressão na frente de lavra, onde as intrusões aparecem de forma mais localizada e descontínua, tornando-se mais sensíveis a sombras, variações texturais e contatos difusos.

A transferência de rótulos contribuiu para ampliar o conjunto de dados utilizado no treinamento, reduzindo a dependência de rotulação manual em todas as imagens. Esse procedimento mostrou-se útil dentro do fluxo proposto, pois aproveitou a sobreposição entre fotografias do levantamento e permitiu propagar interpretações previamente realizadas. Entretanto, os resultados também demonstraram que essa etapa depende diretamente da qualidade das máscaras iniciais e da coerência geométrica do modelo fotogramétrico, uma vez que erros de delimitação ou deslocamentos podem ser incorporados ao treinamento e refletidos nos modelos finais.

A reconstrução tridimensional das litologias permitiu avaliar os resultados para além da imagem bidimensional. A integração desses produtos em uma representação temática final permitiu observar a distribuição das classes sobre a geometria da frente de lavra, contribuindo

para a análise dos contatos e da continuidade das unidades.

De forma geral, conclui-se que a integração entre fotogrametria digital e IA apresentou bom potencial para a modelagem geológica temática em ambiente de mineração. A metodologia proposta não substitui a interpretação geológica realizada por profissionais especializados, mas atua como uma ferramenta de apoio, contribuindo para maior rapidez, padronização e eficiência na análise de afloramentos. Além disso, o fluxo desenvolvido reduz o esforço de rotulação manual, uma vez que a interpretação geológica é realizada apenas sobre um conjunto representativo de imagens, sendo posteriormente propagada automaticamente para as demais fotografias por meio da transferência de rótulos. Assim, o fluxo desenvolvido pode ser utilizado como apoio à caracterização de frentes de lavra, principalmente em áreas onde a exposição rochosa é ampla e a interpretação visual direta pode ser dificultada por variações de iluminação, rugosidade, materiais desagregados e transições graduais entre classes.

Apesar dos resultados positivos, a aplicação ainda apresenta limitações. A definição de apenas três classes foi adequada para os objetivos deste trabalho, mas simplifica parte da variabilidade interna observada na frente de lavra. Além disso, a classe Intrusão demonstrou que feições menos representadas no conjunto de treinamento tendem a apresentar maior perda de classificação. Portanto, a confiabilidade do método depende da qualidade da base rotulada, da representatividade das classes e da validação geológica dos produtos gerados.

7.1 Recomendações para Trabalhos Futuros

Como continuidade deste estudo, recomenda-se ampliar a aplicação da metodologia para outras frentes de lavra e diferentes contextos geológicos, de modo a avaliar a capacidade do fluxo em representar litologias com maior variabilidade textural, estrutural e cromática. A aplicação em outros depósitos com boa exposição de taludes pode contribuir para verificar a robustez dos modelos tridimensionais temáticos e sua utilidade em situações operacionais distintas.

Também se recomenda explorar o uso dos modelos tridimensionais gerados como apoio ao planejamento de lavra. A individualização das unidades litológicas em ambiente 3D pode auxiliar na delimitação de contatos, na visualização da continuidade dos corpos rochosos e na separação entre materiais de interesse econômico e estéril. Com o refinamento da metodologia, esses produtos podem contribuir para o acompanhamento da frente de lavra, atualização de modelos geológicos e tomada de decisão durante o avanço da mineração.

Outra possibilidade está na integração dos modelos temáticos com dados de sondagem, amostragem, mapeamento estrutural e informações geoquímicas. Essa associação permitiria avaliar o potencial da metodologia não apenas como ferramenta visual, mas também como suporte à estimativa de recursos e reservas, especialmente em depósitos onde a geometria das unidades expostas fornece informações relevantes para o entendimento da continuidade dos corpos mineralizados.

Por fim, recomenda-se investigar formas de incorporar os modelos tridimensionais clas-

sificados a fluxos de trabalho utilizados na indústria mineral, incluindo softwares de modelagem geológica, planejamento de mina e controle de produção. A ampliação dessa integração pode transformar os produtos gerados por fotogrametria e IA em ferramentas mais aplicáveis ao cotidiano operacional, contribuindo para maior agilidade na interpretação geológica, melhor controle das frentes de lavra e maior confiabilidade na representação espacial das unidades mapeadas.

REFERÊNCIAS

- BARROS, J. L. d. C. d. **Utilização de Veículos Aéreos Não Tripulados e Aprendizagem de Máquina para Classificação Litológica Automática em Frente de Lavra**. Dissertação (Mestrado em Engenharia) — Universidade Federal do Rio Grande do Sul (UFRGS), Escola de Engenharia, Programa de Pós-Graduação em Engenharia de Minas, Materiais e Metalúrgica, Porto Alegre, 2024.
- BITENCOURT, M. d. F. A. S. **Geologia, petrologia e estrutura dos metamorfitos da região de Caçapava do Sul, RS**. 161 p. Dissertação (Dissertação (Mestrado em Geociências)) — Universidade Federal do Rio Grande do Sul, Porto Alegre, 1983.
- BRITO, J. L. N. E. S. **Fotogrametria Digital**. [S.l.]: Eduerj, 2007. (Série Ponto De Partida). ISBN 978-85-7511-114-7.
- CARRIVICK, J.; SMITH, M.; QUINCEY, D. **Structure from Motion in the Geosciences**. [S.l.]: Wiley, 2016. (Analytical Methods in Earth and Environmental Science). ISBN 9781118895825.
- CHEMALE, F. Evolução geológica do escudo sul-rio-grandense. In: **Geologia do Rio Grande do Sul**. Porto Alegre: CIGO-UFRGRS, 2000. p. 13–52.
- CHEN, J. *et al.* Differentiating outcropping strata from oblique photogrammetric data using an octree-based convolutional neural network with spatial parameters. **Computers & Geosciences**, v. 169, p. 105245, 2022. ISSN 0098-3004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0098300422001947>>.
- Da Costa, J. D. A. L. **ANÁLISE CINEMÁTICA DO COMPLEXO GRANÍTICO CAÇAPAVA DO SUL**. Tese (Doutorado) — UNIVERSIDADE FEDERAL DO PAMPA, Caçapava do Sul, 2023.
- De Toni, G. B.; Da Costa, J. d. A. L. Kinematic analysis of the caçapava do sul granitic complex, southern brazil: Ediacaran syntectonic magmatism and strain partitioning during inclined ductile extrusion along a transpressional shear zone, dom feliciano belt. **Journal of South American Earth Sciences**, v. 143, p. 104996, 2024.
- FERNANDES, L. A. D. *et al.* Evolução tectônica do cinturão dom feliciano no escudo sul-rio-grandense: Parte i - uma contribuição a partir do registro geológico. **Revista Brasileira de Geociências**, v. 25, n. 4, p. 351–374, 1995.
- GOUDINHO, M. M. **Modelagem Geológica de um Corpo de Minério de Mármore a partir de Aerofotogrametria Digital**. 2023.
- GROHMANN, C. H. *et al.* Dune field morphometrics from ALS, TLS and SfM-MVS point clouds. **Computers & Geosciences**, v. 143, p. 104569, 2020.
- GROHMANN, C. H. *et al.* Dune migration and volume change from airborne lidar, terrestrial lidar and structure from motion-multi view stereo. **Computers & Geosciences**, v. 143, p. 104569, 2020.
- GROHMANN, C. H. *et al.* Semi-automatic UAV-based SfM survey of vertical surfaces. In: **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto**. Santos, SP: INPE, 2019. p. 128–131. Disponível em: <<https://proceedings.science/sbsr-2019/papers/semi-automatic-uav-based-sfm-survey-of-vertical-surfaces>>.

GUADAGNIN, F. *et al.* Building of classified 3d point clouds of outcrop with automatically segmented images. **Geodata and AI**, Elsevier, v. 4, p. 100024, 2025. ISSN 2950-483X.

GUEDES, P. L. **CLASSIFICAÇÃO SUPERVISIONADA DE ELEMENTOS ARQUITETURAIS DO MODELO 3D DE LA JARDINERA, BACIA DE NEUQUÉN ARGENTINA**. Tese (Doutorado) — UNIVERSIDADE FEDERAL DO PAMPA, 2023.

HARTMANN, L. A.; CHEMALE, F.; PHILIPP, R. Evolução geotectônica do rio Grande do sul no pré-cambriano. **Ianuzzi R. & Frantz JC.(Org.)**, v. 50, p. 97–123, 2007.

HOERLLE, G. S. *et al.* Metasomatic reactions triggered by localized and dynamically evolving fluid flux record multistage intrusion history: An example from the syntectonic Caçapava do Sul Granitic Complex, Southern Brazil. **Lithos**, v. 442-443, p. 107103, abr. 2023. ISSN 00244937. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0024493723000877>>.

LAUX, J. H. o. **Escudo Sul-Rio-Grandense, estado do Rio Grande do Sul**. Porto Alegre, 2021. (Programa Geologia, Mineração e Transformação Mineral, Levantamentos Geológicos e de Potencial Mineral de Novas Fronteiras). 1 recurso eletrônico: PDF; il. Escala 1:500.000. Disponível em: <<https://rigeo.sgb.gov.br/handle/doc/20521>>.

LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional networks and applications in vision. In: IEEE. **Proceedings of 2010 IEEE international symposium on circuits and systems**. [S.l.], 2010. p. 253–256.

LIANG, B. *et al.* 3d quantitative characterization of fractures and cavities in digital outcrop texture model based on lidar. **Energies**, v. 15, n. 5, 2022.

LIN, S. *et al.* An efficient and automated classification system for rocks based on visually explainable deep learning. **Lithosphere**, 2025. Disponível em: <https://doi.org/10.2113/2025/lithosphere_2024_239>.

Matplotlib Development Team. **Matplotlib Documentation**. 2026. <<https://matplotlib.org/stable/>>. Acesso em: 23 jun. 2026.

MEYER, W. **Concepts of Mathematical Modeling**. Dover Publications, 2004. (Dover Books on Mathematics Series). ISBN 9780486435152. Disponível em: <<https://books.google.com.br/books?id=zC19naSd0TcC>>.

MOLOSSI, A. *et al.* Deep learning-assisted borehole image analysis for enhanced geothermal reservoir evaluation: a case study in the west netherlands basin. **Geoenergy**, Geological Society of London, v. 3, 2025.

NumPy Developers. **NumPy Documentation**. 2026. <<https://numpy.org/doc/>>. Acesso em: 23 jun. 2026.

OpenCV. **Feature Matching with FLANN**. 2024. <https://docs.opencv.org/3.4.20/d5/d6f/tutorial_feature_flann_matcher.html>. Acesso em: 21 jun. 2026.

OpenCV. **OpenCV Documentation**. 2026. <<https://docs.opencv.org/>>. Acesso em: 23 jun. 2026.

PHILIPP, R. P.; PIMENTEL, M. M.; BASEI, M. A. S. The tectonic evolution of the são gabriel terrane, dom feliciano belt, southern brazil: The closure of the charrua ocean. In: SIEGESMUND, S. *et al.* (Ed.). **Geology of Southwest Gondwana**. [S.l.]: Springer, 2018, (Regional Geology Reviews). cap. 10, p. 243–265.

- PHILIPP, R. P.; PIMENTEL, M. M.; CHEMALE JR., F. Tectonic evolution of the dom feliciano belt in southern Brazil: Geological relationships and U-Pb geochronology. **Brazilian Journal of Geology**, v. 46, n. Suppl 1, p. 83–104, 2016.
- PORCHER, C. A.; LOPES, R. d. C. **Programa Levantamentos Geológicos Básicos do Brasil - Cachoeira do Sul**. Brasília, 2000. Disponível em: <<https://rigeo.sgb.gov.br/handle/doc/8476>>. Folha SH.22-Y-A. Estado do Rio Grande do Sul. CPRM.
- RANGEL, A. C. *et al.* **Os Minerais Calcário e Dolomito na Região do Pampa**. Bagé: [s.n.], 2014. <<https://sites.unipampa.edu.br/pibid2014/files/2015/08/indicador-5-banner-mineralogia.pdf>>.
- REMUS, M. *et al.* The link between hydrothermal epigenetic copper mineralization and the Caçapava Granite of the Brasiliano Cycle in southern Brazil. **Journal of South American Earth Sciences**, v. 13, n. 3, p. 191–216, jul. 2000. ISSN 08959811. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0895981100000171>>.
- RUBO, R. A. **Petrografia Digital: quantificação e caracterização de minerais, poros, texturas e litofácies com base em inteligência artificial**. 197 f. p. Tese (Doutorado em Ciências) — Escola Politécnica da Universidade de São Paulo (USP), Departamento de Engenharia de Minas e de Petróleo, São Paulo, 2022.
- SATO, R. Methodological developments using image analysis for field surveys. **AAPG Bulletin**, 2025. Manuscript accepted December 2024.
- scikit-image Developers. **scikit-image Documentation**. 2026. <<https://scikit-image.org/docs/stable/>>. Acesso em: 23 jun. 2026.
- scikit-learn Developers. **scikit-learn Documentation**. 2026. <<https://scikit-learn.org/stable/>>. Acesso em: 23 jun. 2026.
- SHIRMARD, H. *et al.* A review of machine learning in processing remote sensing data for mineral exploration. **Remote Sensing of Environment**, v. 268, p. 112750, 2022. ISSN 0034-4257. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0034425721004703>>.
- TensorFlow. **TensorFlow Documentation**. 2026. <<https://www.tensorflow.org/>>. Acesso em: 23 jun. 2026.
- ULLAH, F. *et al.* Conventional to deep ensemble methods for hyperspectral image classification: A comprehensive survey. **arXiv preprint arXiv:2401.03154**, 2024. Acesso aos dados de pesquisa em 25 de abril de 2023. Disponível em: <<https://arxiv.org/abs/2401.03154>>.
- VAUGHAN, W. **Digital modeling**. [S.l.]: New Riders, 2011.
- VIANA, C. D. **Fotogrametria digital multi-escala para aquisição de dados estruturais**. Tese (Doutorado em Recursos Minerais e Meio Ambiente) — Universidade de São Paulo, São Paulo, nov. 2021. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/44/44137/tde-18012022-122057/>>.
- WANG, R. *et al.* Advanced identification of geological discontinuities with deep learning. **Applied Computing and Geosciences**, Elsevier, v. 27, p. 100256, 2025. ISSN 2590-1974.

YU, J. *et al.* Superpixel segmentations for thin sections: Evaluation of methods to enable the generation of machine learning training data sets. **Computers & Geosciences**, v. 170, p. 105232, 2023. ISSN 0098-3004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0098300422001819>>.

ZHANG, T.-F. *et al.* Generating geologically realistic 3D reservoir facies models using deep learning of sedimentary architecture with generative adversarial networks. **Petroleum Science**, v. 16, n. 3, p. 541–549, jun. 2019. ISSN 1995-8226. Disponível em: <<https://doi.org/10.1007/s12182-019-0328-4>>.