

UNIVERSIDADE FEDERAL DO PAMPA

PABLO LOSANO GUEDES

**CLASSIFICAÇÃO SUPERVISIONADA DE ELEMENTOS ARQUITETURAIS DO
MODELO 3D DE LA JARDINERA, BACIA DE NEUQUÉN ARGENTINA**

Caçapava do Sul

2023

PABLO LOSANO GUEDES

**CLASSIFICAÇÃO SUPERVISIONADA DE ELEMENTOS ARQUITETURAIS DO
MODELO 3D DE LA JARDINERA, BACIA DE NEUQUÉN ARGENTINA**

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: Felipe Guadagnin

Coorientador: Ítalo Gomes
Goncalves

Caçapava do Sul

2023

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).

G924c Guedes, Pablo Losano

Classificação supervisionada de elementos arquiteturais do modelo 3d de La Jardinera, Bacia de Neuquén, Argentina / Pablo Losano Guedes.
48 p.

Trabalho de Conclusão de Curso (Graduação)-- Universidade Federal do Pampa, GEOLOGIA, 2023.

"Orientação: Felipe Guadagnin"

"Coorientador: Ítalo Gomes Gonçalves.

1. Redes Neurais Convolucionais. 2. Modelos Virtuais de Afloramento. 3. Classificação automática supervisionada. 4. Estratigrafia. I. Título.

PABLO LOSANO GUEDES

CLASSIFICAÇÃO SUPERVISIONADA DE ELEMENTOS ARQUITETURAIS DO MODELO 3D DE LA JARDINERA, BACIA DE NEUQUÉN ARGENTINA

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 13 de julho de 2023.

Banca examinadora:

Prof. Dr. Felipe Guadagnin

Orientador

Universidade Federal do Pampa

Prof. Dr. Marco Antonio Fontoura Hansen

Universidade Federal do Pampa

Prof. Dr. Maximilian Fries

Universidade Federal do Pampa



Assinado eletronicamente por **MARCO ANTONIO FONTOURA HANSEN, PROFESSOR DO MAGISTERIO SUPERIOR**, em 20/07/2023, às 15:26, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **FELIPE GUADAGNIN, PROFESSOR DO MAGISTERIO SUPERIOR**, em 20/07/2023, às 17:37, conforme horário oficial de Brasília, de acordo com as normativas legais aplicáveis.



Assinado eletronicamente por **MAXIMILIAN FRIES, PROFESSOR DO MAGISTERIO SUPERIOR**, em 21/07/2023, às 08:00, 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 **1190887** e o código CRC **9B7D4D06**.

Universidade Federal do Pampa, Campus Caçapava do Sul

Minha sincera gratidão a todas as pessoas que, por meio de seu apoio e crença em minha capacidade, serviram como uma fonte contínua de inspiração neste trabalho.

AGRADECIMENTO

Gostaria de escrever nesse parágrafo tudo o que me desperta gratidão por contribuir de alguma forma com a possibilidade de escrever esse texto. Pessoas, lugares, oportunidades e momentos. Mas, infelizmente, não é possível grafar tudo e todos. Saibam que há muita coisa que poderia ser escrita aqui.

Agradeço e dedico aos meus pais e familiares, sem vocês não seria nem mesmo possível existir, imagina ter a oportunidade que tenho de estudar, pesquisar e realizar sonhos!!

Sobre crescimento acadêmico, dedico a todos os meus professores, do ensino infantil a faculdade, que me mostrando o prazer da busca pelo conhecimento. Agradeço imensamente aos Professores Felipe Guadagnin, Ítalo Gomes Gonçalves e a todos os participantes do projeto Modelos Virtuais de Afloramento: Construção, Extração e Integração de Informações Estratigráficas, Sedimentológicas, Diagenéticas e Estruturais em 3D.

Sobre crescimento pessoal, que é tão importante quanto, agradeço todos os amigos e colegas que estiveram comigo nessa trajetória.

Agradeço a todas as intuições de ensino do país que se dedicam a busca pelo conhecimento verdadeiro, dando oportunidades de forma democrática e sem preconceitos, como a Unipampa, instituição que tenho imenso orgulho de fazer parte.

Por fim, mas jamais menos importante, agradeço ao governo do Excelentíssimo Senhor Luiz Inácio Lula da Silva e seu ministro da educação, Fernando Haddad, por transformarem um país, mostrando que educação de qualidade é um direito de TODOS.

RESUMO

A interpretação manual de modelos 3D em geociências é altamente dependente do intérprete, demorada, não-reprodutível e não permite o cálculo das incertezas associadas. O afloramento La Jardinera, Bacia de Neuquén, Argentina, expõe rochas sedimentares depositadas em sistemas deposicionais turbidíticos, e foi amplamente estudada por diversos autores. Todos os trabalhos publicados sobre a sedimentologia e estratigrafia dos estratos de La Jardinera foram realizados de forma analógica e manual, seguindo os métodos tradicionais de levantamento faciológico em campo. No âmbito do projeto “Modelos Virtuais de Afloramento: Construção, Extração e Integração de Informações Estratigráficas, Sedimentológicas, Diagenéticas e Estruturais em 3D”, foram adquiridas 719 imagens em campo com aeronave pilotada de forma remota, para a construção de modelo 3D do afloramento La Jardinera. A interpretação manual de modelos 3D de afloramento está inerente as mesmas dificuldades e limitações da interpretação de modelos 3D em geociências. Para automatizar a extração de informações estratigráficas do modelo 3D de afloramento La Jardinera e contribuir com o desenvolvimento metodológico, foi utilizada uma rede neural convolucional, que é uma técnica de classificação supervisionada no âmbito das ferramentas de inteligência artificial (*deep learning*). O objetivo geral é obter a nuvem de pontos classificada por associações de fácies dos depósitos turbidíticos do afloramento La Jardineira. Das 719 imagens captadas em campo, 69 foram interpretadas por associação de fácies. A rotulação consiste em gerar polígonos em cada imagem e atribuir uma classe para cada polígono, dentre as duas associações de fácies que ocorrem no modelo 3D, lobos-interlobos e franja dos lobos. A geração dos polígonos foi realizada com ferramentas guiadas (varinha mágica ou laço poligonal) disponíveis no software Photoshop. Após a geração dos rótulos, metade das imagens rotuladas foi utilizada para o treinamento da rede neural e metade das imagens para o teste da acurácia da classificação; a acurácia total foi de 85%. A acurácia por elemento arquitetural, foi de 69% para lobos-interlobos e de 74% para franja dos lobos. A arquitetura da rede neural utilizada foi U-net, utilizada como estrutura principal do modelo de segmentação. Após esse primeiro teste, a rede neural foi utilizada para classificar as 719 imagens e obter rótulos para todo o conjunto de dados. Para visualização da assertividade das predições, foram elaborados mapas estatísticos de entropia nas imagens e testes de validação dos dados. Para a geração da nuvem de pontos classificada por elementos arquiteturais, as 719 imagens foram

processadas pelo fluxo de trabalho SfM-MVS. Todas as imagens foram alinhadas em conjunto e foram construídas 3 nuvens de pontos: (i) com todas as imagens; (ii) somente com as partes das imagens rotuladas como lobos-interlobos; e (iii) somente com as partes das imagens rotuladas como franja dos lobos. Da nuvem de pontos com todas as imagens, 5,24% dos pontos foram classificados como lobos-interlobos e 17,78% dos pontos como franja dos lobos. A obtenção da nuvem de pontos classificada por associações de fácies foi realizada e os resultados obtidos neste estudo demonstram a efetividade do emprego de técnicas de *deep learning* para a interpretação em geociências.

Palavras-Chave: Redes Neurais Convolucionais, Modelos 3D de Afloramento, Classificação Supervisionada, Estratigrafia, Turbiditos.

ABSTRACT

The manual interpretation of 3D models in geosciences is highly interpreter-dependent, time-consuming, non-reproducible, and does not allow the calculation of associated uncertainties. The La Jardinera outcrop, Neuquén Basin, Argentina, exposes sedimentary rocks deposited in turbiditic depositional systems and has been widely studied by several authors. All published works on the sedimentology and stratigraphy of La Jardinera strata were carried out analogically and manually, following traditional methods of faciological field surveys. Within the scope of the project "Virtual Outcrop Models: Construction, Extraction, and Integration of Stratigraphic, Sedimentological, Diagenetic, and Structural Information in 3D", 719 images were acquired in the field with a remotely piloted aerial system for the construction of a 3D model of the La Gardener. The manual interpretation of 3D outcrop models is inherent to the same difficulties and limitations of interpreting 3D models in geosciences. To automate the extraction of stratigraphic information from the 3D model of the La Jardinera outcrop and contribute to the methodological development, a convolutional neural network was used, a supervised classification technique within the scope of artificial intelligence tools (deep learning). The general objective is to obtain the point cloud classified by facies associations of the turbiditic deposits of the La Jardineira outcrop. Of the 719 images captured in the field, 69 were interpreted by facies association. The labeling consists of generating polygons in each image and assigning a class to each polygon, among the two facies associations that occur in the 3D model, lobes-interlobes and lobe fringe. Polygons were generated with guided tools (magic wand or polygonal lasso) available in Photoshop software. After generating the labels, half of the labeled images were used for neural network training and half of the images for the classification accuracy test; the overall accuracy was 85%. The accuracy per architectural element was 69% for interlobe lobes and 74% for lobe fringe. The architecture of the neural network used was U-net, used as the main structure of the segmentation model. After this first test, the neural network was used to classify the 719 images and obtain labels for the entire dataset. Statistical maps of entropy in the images and data validation tests were prepared to visualize the assertiveness of the predictions. The 719 images were processed by the SfM-MVS workflow to generate the point cloud classified by architectural elements. All images were aligned together, and 3-point clouds were constructed: (i) with all images; (ii) only with the parts of the images labeled as lobes-interlobes; and (iii) only with the parts of

the images labeled as lobe fringe. From the point cloud with all images, 5.24% of the points were classified as lobe-interlobes and 17.78% as lobe fringe. Obtaining the point cloud classified by facies associations was carried out, and the results obtained in this study demonstrate the effectiveness of using deep learning techniques for interpretation in geosciences.

Keywords: CNNs, MVA, Supervised automatic classification, Stratigraphy.

SUMÁRIO

1. INTRODUÇÃO	13
2. REDES NEURAS CONVOLUCIONAIS APLICADAS A CLASSIFICAÇÃO SUPERVISIONADA DE DADOS DE AFLORAMENTO	16
3. MATERIAIS E MÉTODOS	23
a. Compilação e processamento de dados	23
i. Imagens	23
ii. Associações de fácies	26
iii. Processamento das imagens para a construção de nuvem de pontos, malha triangulada texturizada, ortofotomosaicos,	28
iv. Correlação Logs x modelo 3D e ortofotomosaicos e Mapeamento das superfícies estratigráficas	28
b. Redes Neurais Convolucionais (CNNs) – <i>Deep Learning</i>	30
c. Construção e interpretação das nuvens de pontos por associação de fácies	34
4. RESULTADOS	35
a. Processamento de imagens	35
b. Processamento de Modelos Virtuais de afloramento e ortofotomosaicos	36
c. Integração de dados em 3D e 2D e delimitação de elementos arquiteturais	36
d. Treinamento da CNN	39
e. Construção e interpretação das nuvens de pontos por associação de fácies	42
REFERÊNCIAS	45

LISTA DE FIGURAS

Figura 1 - Em A, Localização do Afloramento La Jardineira. Em B, coluna estratigráfica da Formação Los Molles.....	15
Figura 2 - Organograma ilustrando os conceitos principais abordados no trabalho.....	17
Figura 3 - Imagem mostrando a arquitetura da U-net utilizado no trabalho	19
Figura 4 – Ilustração do fluxo de trabalho para a obtenção da nuvem de pontos classificada por elementos arquiteturais dos turbiditos de La Jardineira.....	24
Figura 5 – Exemplo das fotos adquiridas no afloramento La Jardineira, sem o processamento de ajuste do histograma de tons	25
Figura 6 - Imagem panorâmica de parte do afloramento La Jardineira integrado com logs de fácies medidos em campo, indicação das sequências J1 e J2 e superfície limítrofe no limite entre as duas as sequências (SB-J2).....	29
Figura 7 – Exemplos de produtos das rotulações de elementos arquiteturais nas imagens, para o treinamento da Rede Neural. Em laranja as máscaras criadas para FA1b e em amarelo para FA2.....	31
Figura 8 - Exemplo de uma imagem para correção dos parâmetros de tons. A e B estão sem correções. C e D estão com o histograma de tons corrigidas	35
Figura 9 - A imagem demonstra o MVA de La Jardineira construído no software Agisoft Metashape, importado no software MOVE e sobreposto ao log de fácies extraído de Gonçalves et al. (2022).....	37
Figura 10 – MVA do afloramento La Jardineira interpretado por sequências deposicionais	38
Figura 11 – Exemplo de resultado da predição de elementos arquiteturais na foto 477	39
Figura 12 – Exemplo de resultado da predição de elementos arquiteturais na foto 484.....	40
Figura 13 - Gráfico obtido na fase de validação	41
Figura 14 – Nuvens de pontos colorida por RGB sem classificação (em A), classificada como lobo e interlobo (em “b”) e classificada como franja dos lobos (em “c”)	43

1. INTRODUÇÃO

Modelos virtuais 3D de afloramentos (MVAs) são projeções fotorealistas georreferenciadas da superfície de afloramentos rochosos, usualmente com resolução maior do que 1 cm/pixel (e.g., Cawood et al. 2017; Corradetti et al. 2017; Marques Jr., 2020). Sobre essas projeções, é possível extrair e integrar informações 1D, 2D e 3D e construir modelos geológicos, com aplicação em diversas áreas das geociências (e.g., Marques Jr., 2020). Duas técnicas são utilizadas para a construção de modelos 3D de afloramentos, LiDAR e Fotogrametria Digital, sendo a segunda, a mais versátil e com menor custo de aquisição e processamento (e.g., Cawood et al. 2017).

A fotogrametria e o sensoriamento remoto auxiliaram a pesquisa geológica, no descobrimento e exploração de depósitos minerais, petróleo e gás. Os modelos geológicos e a capacidade de construir facilmente modelos de terreno fotorealistas de alta resolução podem auxiliar na visualização de campo, permitindo um mapeamento de alta precisão de encostas íngremes e penhascos (Pavlis, Mason, 2017). O fluxo de trabalho da Fotogrametria Digital, também chamada de *Structure from Motion-Multi View Stereo* (SfM-MVS), permite a construção de modelos 3D de afloramentos de forma rápida e com menor custo (Westoby et al. 2012), popularizando as visualizações e interpretações geológicas de alta resolução (decimétrica a centimétrica).

Em um projeto de pesquisa é comum se obter grandes quantidades de dados, como fotografias de afloramentos para a construção de modelos 3D utilizando Fotogrametria Digital. É desejável fazer uma interpretação faciológica e de elementos arquiteturais (EA) nos produtos da fotogrametria, quando se trata da análise estratigráfica de afloramentos; como no afloramento La Jardinera, onde ocorrem depósitos formados em ambiente marinho profundo, com depósitos de turbiditos distais (Paim et., 2008; Gonçalves et al. 2022). Porém, em alguns casos o processo de realizar a interpretação manual é lento e exaustivo, devido ao volume de dados.

A Inteligência Artificial tem auxiliado intérpretes humanos a realizar processos que antes eram essencialmente manuais. De acordo com Khan et al. 2020, as Redes Neurais Convolucionais (CNN – *Convolutional Neural Networks*) são amplamente utilizadas em visão computacional, permitiram avanços sem precedentes no campo aprendizado de máquina (*Machine Learning - ML*) e aprendizado profundo (*Deep Learning - DL*). Para tarefas de reconhecimento visual, como classificação, localização e detecção de imagens e até mesmo para reconhecimento de padrões de

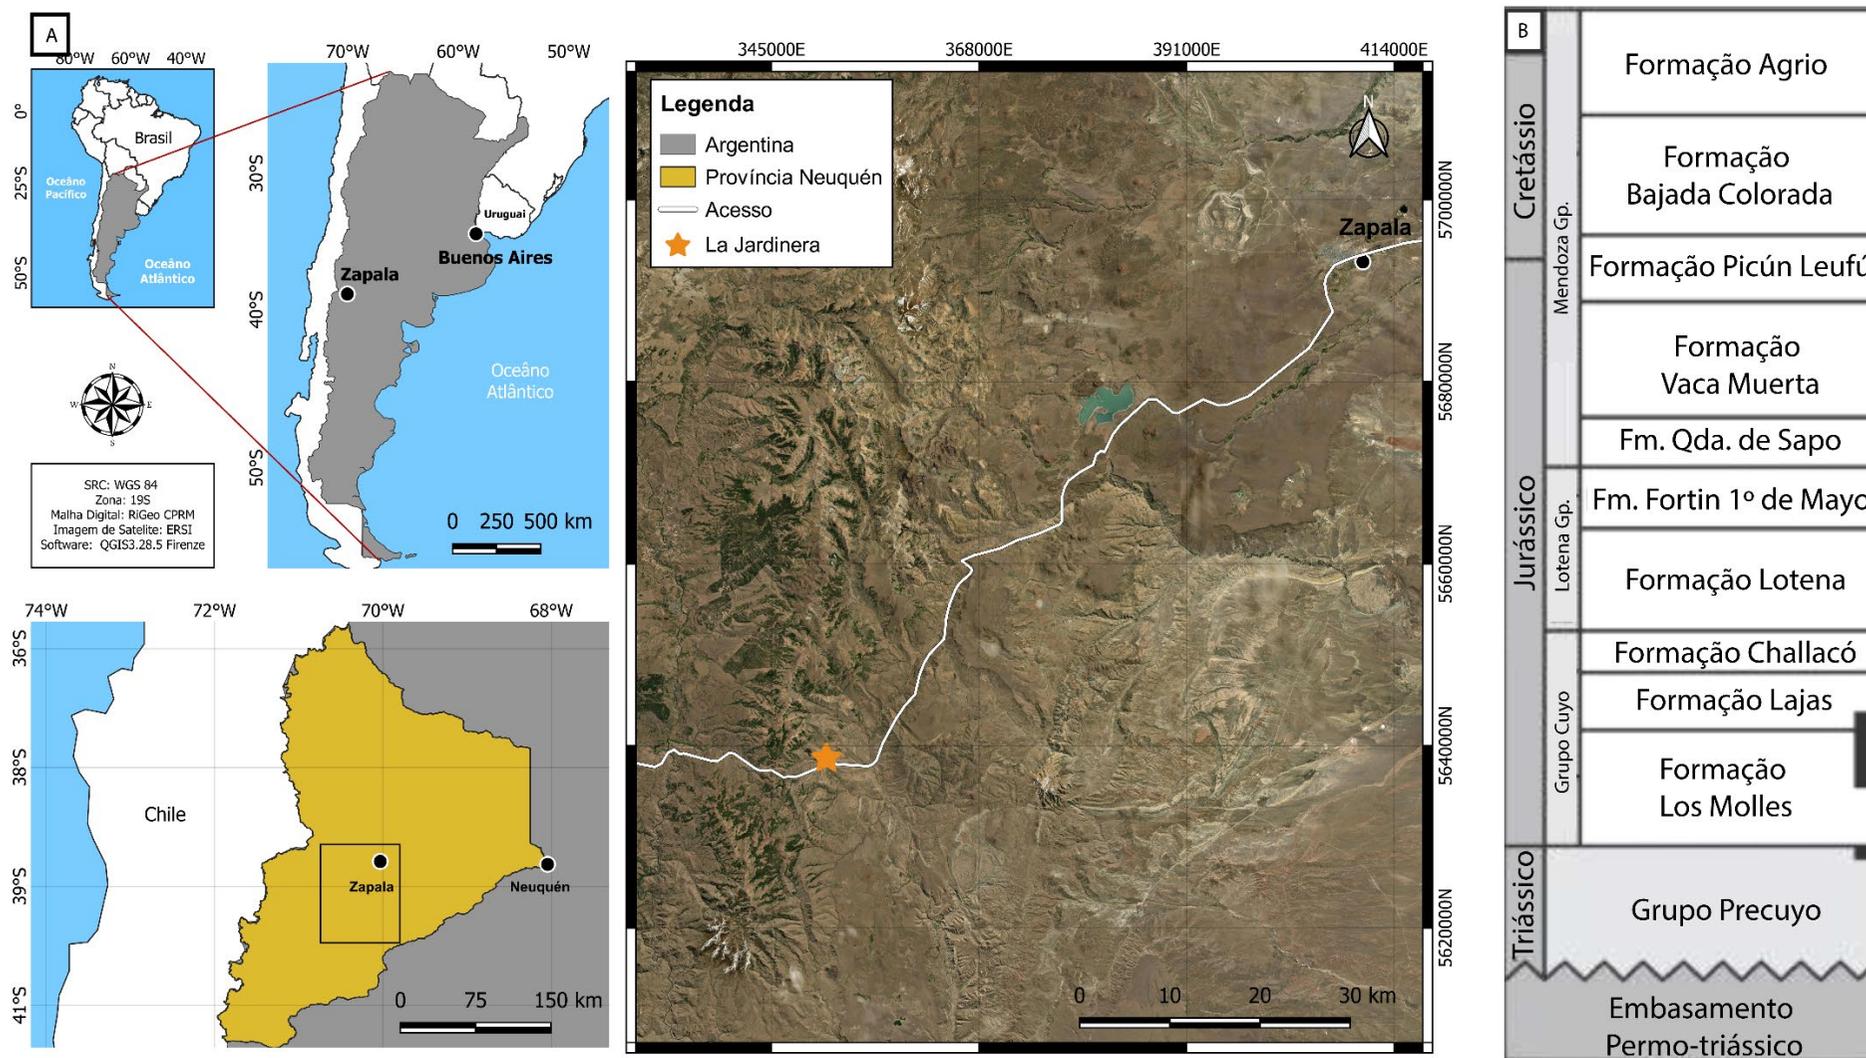
voz, as CNNs tem se mostrado uma ferramenta altamente eficaz, diminuindo o tempo de processamento e a taxa de erro associado, aumentando a precisão dos modelos (Deng, 2014).

O afloramento La Jardinera está localizado na província de Neuquén, Argentina e expõe rochas sedimentares depositadas no jurássico superior e jurássico médio (Figura 1) (Paim et al. 2008; Gonçalves et al. 2022). Esses estratos pertencem a Formação Los Molles, Grupo Cuyo (Gulisano; Gutiérrez Pleimling, 1994). No afloramento ocorrem, ao menos, dois EA visualmente distintos entre si, lobos e franjas turbidíticos (Gonçalves et al. 2022).

Ao longo do desenvolvimento do projeto “Modelos Virtuais de Afloramento: Construção, Extração e Integração de Informações Estratigráficas, Sedimentológicas, Diagenéticas e Estruturais em 3D”, foram adquiridas 716 imagens com um Sistema de Aeronave Remotamente Pilotada (*Remotely Piloted Aerial System* - RPAS ou drone) para a construção do modelo 3D do afloramento La Jardinera. Esse modelo 3D possui cerca de 674 metros de extensão lateral e 70 metros máximos de extensão vertical.

Com o intuito de otimizar a interpretação humana do afloramento e desenvolver a metodologia de classificação supervisionada, a aplicação de CNN para realizar a classificação supervisionada dos EA nos turbiditos de La Jardinera é apresentada. O mapeamento dos elementos arquiteturais foi executado com base em dados da literatura.

Figura 1 – Em A, Localização do Afloramento La Jardineira. Em B, coluna estratigráfica da Formação Los Molles.



2. REDES NEURAIAS CONVOLUCIONAIS APLICADAS A CLASSIFICAÇÃO SUPERVISIONADA DE DADOS DE AFLORAMENTO

De acordo com Khan et al. (2018), os expressivos avanços tecnológicos, tanto no aumento de poder de processamento de computadores, quanto na criação de *softwares* potentes e interativos, permitiram avanços exponenciais no campo de aprendizado de máquina (*Machine Learning - ML*) e aprendizado profundo (*Deep Learning - DL*).

Tarefas para o reconhecimento visual como classificação, localização e detecção de objetos em imagens, são os principais blocos de construção de muitos softwares e aplicativos e, desenvolvimentos recentes em redes neurais convolucionais (CNNs), que são inspiradas no funcionamento do córtex cerebral em mamíferos, levaram a um excelente desempenho nessas tarefas de reconhecimento visual de última geração. Os sistemas auxiliam e aceleram o monitoramento e reconhecimento inteligente de imagens em diversos campos como biomedicina, robótica, astrofísica, drones entre outros. (KHAN et al. 2018).

De forma sucinta, visão computacional é a capacidade que permite sistemas computacionais definir, diferenciar e classificar objetos, similarmente ao sistema de reconhecimento biológico dos seres vivos. Porém, ao invés do complexo sistema biológico humano, algoritmos são utilizados para aplicar filtros em imagens, pixel a pixel, para a extração de feições, que são características que possam ser reconhecidas na imagem, como faces humanas, bordas, recursos numéricos de cor, gradiente, média, variância e feições de geometrias, entre outras. (KHAN et al. 2018).

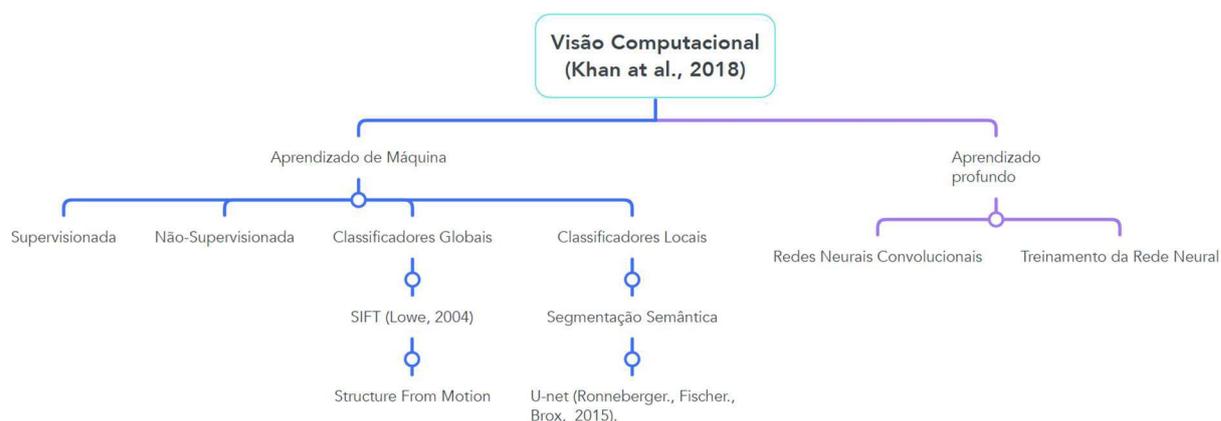
Combinações de feições são feitas para criar os chamados vetores de feições. Cada objeto terá vetores de feições similares, definindo categorias de objetos. Os filtros são aplicados para os classificadores definirem "objeto" e "não objeto" através dos vetores de feições. (KHAN et al. 2018). Por exemplo, em uma imagem de um carro os filtros são aplicados, extraíndo as feições e combinando-as, para criar os vetores de feições e definindo categorias de rodas, janelas, portas etc. Por fim, os classificadores indicam o que é carro e o que não é, através da combinação de categorias de objetos. (KHAN et al. 2018).

Há diversos tipos de classificadores, definidos como globais e locais. Os descritores globais são aplicados para um reconhecimento geral na imagem, sem

eficiência para extração de formas e feições detalhadas. Já os locais utilizam métodos para segmentação ser eficiente no reconhecimento e extração de formas e feições. (KHAN et al. 2018).

O algoritmo Transformação de Imagens Invariante de Escala (Scale Invariant Feature Transform - SIFT) é um exemplo de classificador global e que faz parte do fluxo de trabalho SfM-MVS utilizado no processamento dos modelos virtuais 3D. Esse algoritmo realiza a segmentação, utilizando funções diferenciais gaussianas (DoG), encontrando e correlacionando pontos chaves nas imagens, que são independentes de fatores de escala, rotação ou tamanho das imagens. (LOWE, 2004). A Figura 2 ilustra um resumo dos conceitos abordados nesse.

Figura 2 - Organograma ilustrando os conceitos principais abordados no trabalho.



Fonte: autor.

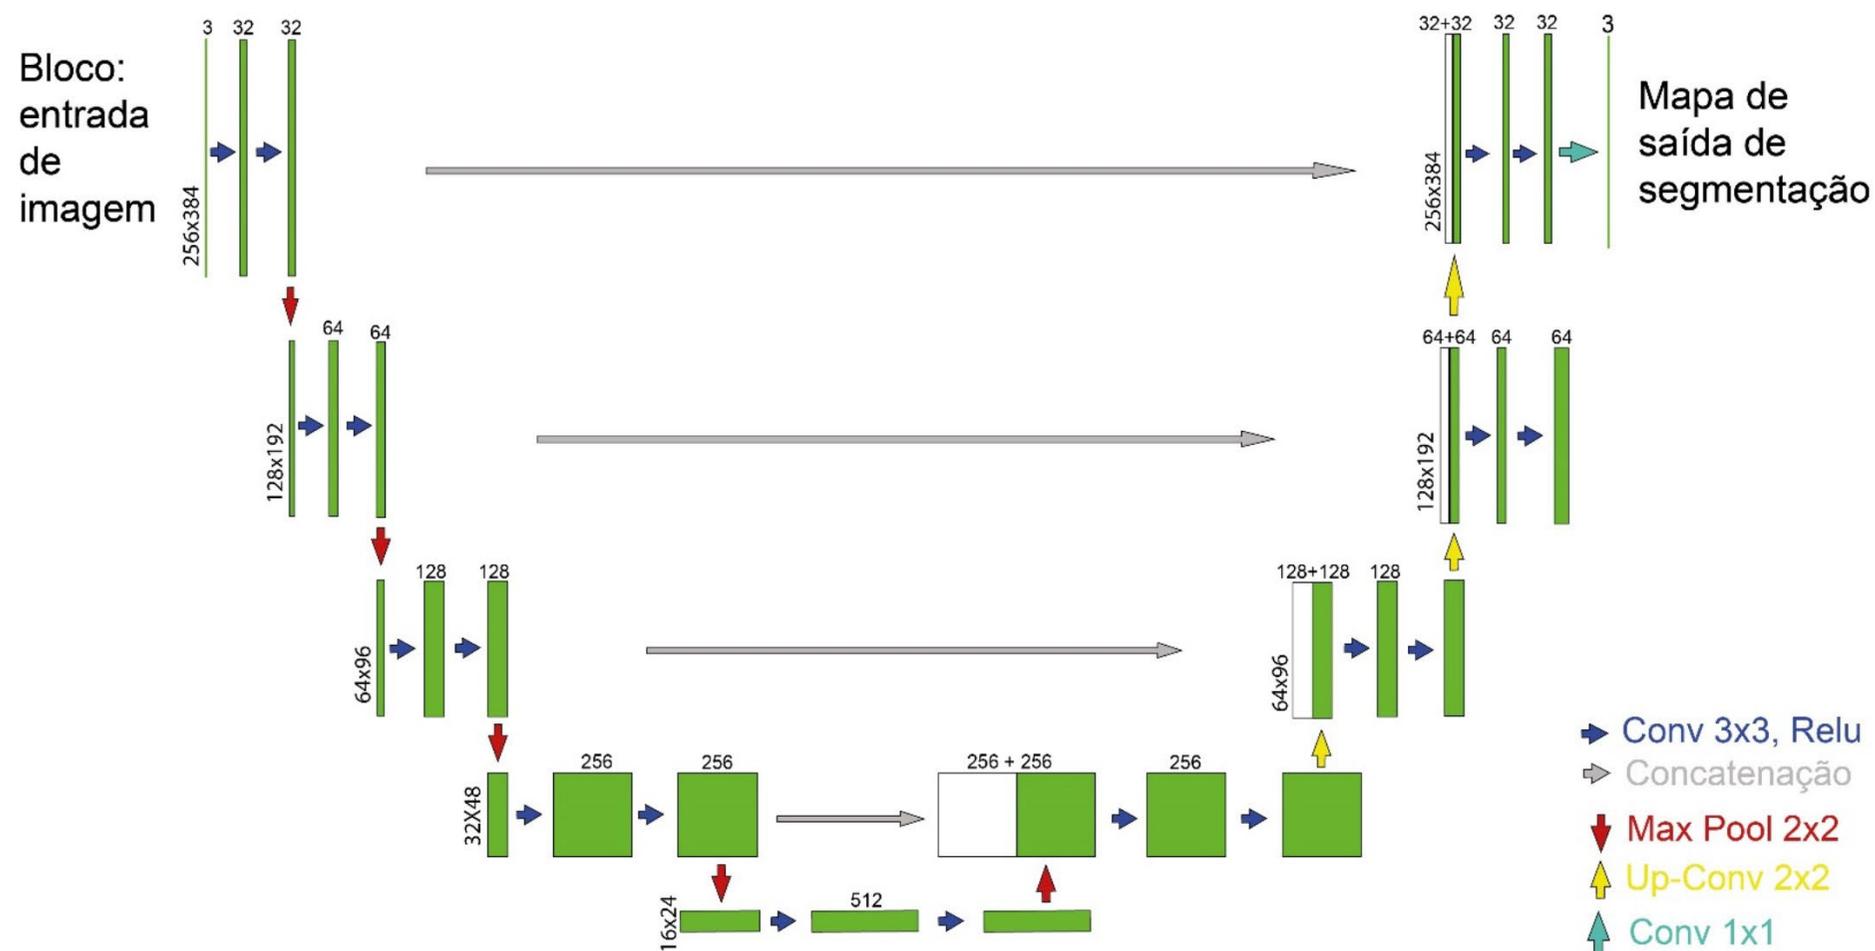
Um exemplo de aplicação de CNNs no campo da astrofísica, é a previsão de densidade em coordenadas $Rx\theta xt$ de buracos negros, utilizando redes convolucionais neurais não supervisionadas, inspirados no algoritmo U-Net. (BUSTILLO et al. 2020).

O U-net é um algoritmo que utiliza CNNs e foi proposto, a priori, para segmentação e reconhecimento de padrões em dados de lâminas na biomedicina, por Ronneberger., Fischer., Brox (2015). Basicamente consiste em dois passos, o de contração (lado esquerdo) e o de expansão (lado direito) e possui o nome U-net por sua arquitetura lembrar a letra U. O caminho de contração (*encoder*) é responsável por reduzir progressivamente o tamanho dos pixels, por meio de camadas convolucionais, seguidas pela aplicação da função de ativação, que é responsável por

filtrar a informação. Posteriormente extrai características de baixo nível, agregando pixels vizinhos e reduzindo o tamanho da imagem (função *Max pooling*). (RONNEBERGER., FISCHER., BROX, 2015).

O caminho de expansão (*decoder*) tem como objetivo reconstruir a imagem segmentada para o tamanho original, incorporando informações de recursos extraídas na etapa anterior. Isso é realizado por meio de camadas convolucionais transpostas (*up-convolutions*) e concatenação com as características correspondentes no caminho de contração. (RONNEBERGER., FISCHER., BROX, (2015). A figura 3 esquematiza a arquitetura da U-net utilizada nesse trabalho.

Figura 3 - Imagem mostrando a arquitetura da U-net utilizado no trabalho.



Fonte: Adaptado de RONNEBERGER., FISCHER., BROX (2015)

Avanços exponenciais no que tange a fotogrametria digital permitiram ganhos também nas áreas de geologia. A extração de diversos dados geológicos, estruturais e estratigráficos, através de fotos adquiridas em campo, são hoje uma realidade. (PASETTO et al. 2020). *Softwares* completos como o Move (Petroleum Experts, 2022), utilizam dados extraídos de modelos virtuais de afloramento, ortofotomosaicos, logs geofísicos, entre outros, para gerarem interpretações e modelagens geológicas complexas, muito utilizados na indústria do petróleo e na academia. Porém, Gonçalves et al. 2017 demonstrou que na década passada, diversos autores nas amplas áreas de geologia utilizam ML para acelerar e aprimorar interpretações de dados geológicas.

Há uma crescente utilização de técnicas de ML e DL aplicando visão computacional para o reconhecimento e classificação automática de dados geológicos, como por exemplo CNNs, que utilizam de dados como fotos obtidas em campo, fotos de lâmina delgada analisadas com o microscópio ótico, fotos de testemunho de sondagem, entre outros. (MALIK et al. 2022).

Por exemplo, Malik et al. (2022) realizaram trabalhos de classificação para o reconhecimento de fotofácies de arenitos e pelitos em imagens de afloramento, através de CNNs, de forma supervisionada, utilizando de algoritmos como o U-net. Com um conjunto de 102 imagens, os autores separaram 15% para a fase de treino e 15% a fase de teste. Para as fases de treino, chegaram a valores de acurácia máximos de 93,93%, 80,64%, 83,31%, para arenito, lamito e outros (fundo), respectivamente. Já para a fase de testes os valores foram de 88,73%, 77,26%, 80,03%, para os mesmos objetos.

Os autores também realizaram uma revisão bibliográfica de trabalhos relacionados a predições de dados geológicos utilizando-se de técnicas de ML e DL, salientando que os diversos autores aplicaram diferentes técnicas de ML e DL utilizando de imagens como de Microscópio eletrônica de varredura (MEV), Microtomografia (CT), câmera fotográfica digital, microscopia de luz polarizada, entre outros; chegando em diferentes valores de acurácia. A compilação dos dados levantados por Malik et al. (2022) está compilada na tabela 1. Também são pontuadas algumas características dos modelos de predição, por exemplo, se somente um ou

mais tipos de rocha foram imageadas e utilizadas para o treinamento do modelo e se no processo foi utilizado segmentação semântica ou não. (MALIK et al. 2022).

O trabalho de Bessane (2022) utiliza CNNs para identificação e classificação de dados geológicos de forma automática supervisionada, tendo como alvo o afloramento do da costa Leste da bacia lusitânica, Portugal. O objetivo principal do trabalho foi identificar e classificar camadas de fotofacés areníticas, pelíticas, e outros objetos, como vegetação e sedimentos inconsolidados.

Dessa forma, o autor realiza fases de treino e de teste para o computador classificar esses objetos, através de camadas pré-rotuladas, utilizando o algoritmo U-net escrito em Python. Com um banco de dados de um total de 112 imagens, foram ofertadas para treino 28, 37, 56 imagens. Como resultado obteve-se uma melhora esperada na acurácia do modelo (86%, 88%, 90% respectivamente).

Finalmente, Sahithya et al. 2023 publicaram o estudo mais recente sobre classificação de dados geológicos, utilizando-se de técnicas de ML e DL. Neste estudo, os autores utilizam segmentação semântica em imagens de tomográfica, especificamente a microscopia de raios-X. Essa abordagem permitiu a diferenciação mineralógica fundamental, para prever padrões de granulometria e microestrutura mineral, além de comparar e analisar a eficácia de diferentes redes profundas de classificação de um modelo para o modelo segmentação semântica.

Tabela 1 – Trabalhos relacionados a predições de dados geológicos utilizando técnicas de ML e DL.

Referência	Tipo de imagens	Classificação de tipos de rochas singulares (S) ou múltiplas (M)	Técnica	Aplicou Segmentação semântica
Ran et al. (2019)	Câmera fotográfica digital	S	CNN	Não
Liu et al. (2020)	Câmera fotográfica digital	M	faster R-CNN, simplificado VGG16	Não
Ringer and Yoon. (2020)	Microscópio eletrônica de varredura, Microtomografia	S	U-Net, U-VGG16, U-Resnet	Sim
Alfarisi et al. (2021)	Microscopia eletrônica de varredura, Microtomografia imagem de ressonância magnética	S	ML, CNN	Sim
Xu et al. (2022)	Microscópio de Luz Polarização	S	Inception_Resnetv2, Inceptionv3	Não
Pascual et al. (2019)	Câmera fotográfica digital	S	3 camadas de CNN, Transfer Learning	Não
Cheng and Guo (2017)	Microscópio de luz polarizada	S	CNN	Não
Liang et al. (2021)	Câmera fotográfica digital	S	EfficientNetB0	Não
Niu et al. (2020)	μMicrotomografia, Microscópio eletrônica de varredura	S	LeNet5	Não
Bessane (2022)	Câmera fotográfica digital embarcado em RPAS	M	U-Net	Sim
Outros	Câmera fotográfica digital	M	U-Net, LinkNet, Transfer learning, Aprendizagem em Conjunto	Não

Fonte: modificado de Malik et al. (2022). Traduzido e modificado pelo autor.

3. MATERIAIS E MÉTODOS

Este trabalho foi realizado a partir das etapas de (i) compilação e processamento de dados; (ii) aplicação da classificação supervisionada utilizando redes neurais convolucionais; e (iii) construção e interpretação das nuvens de pontos por associação de fácies. A **Figura 4** ilustra o fluxo do trabalho realizado.

a. Compilação e processamento de dados

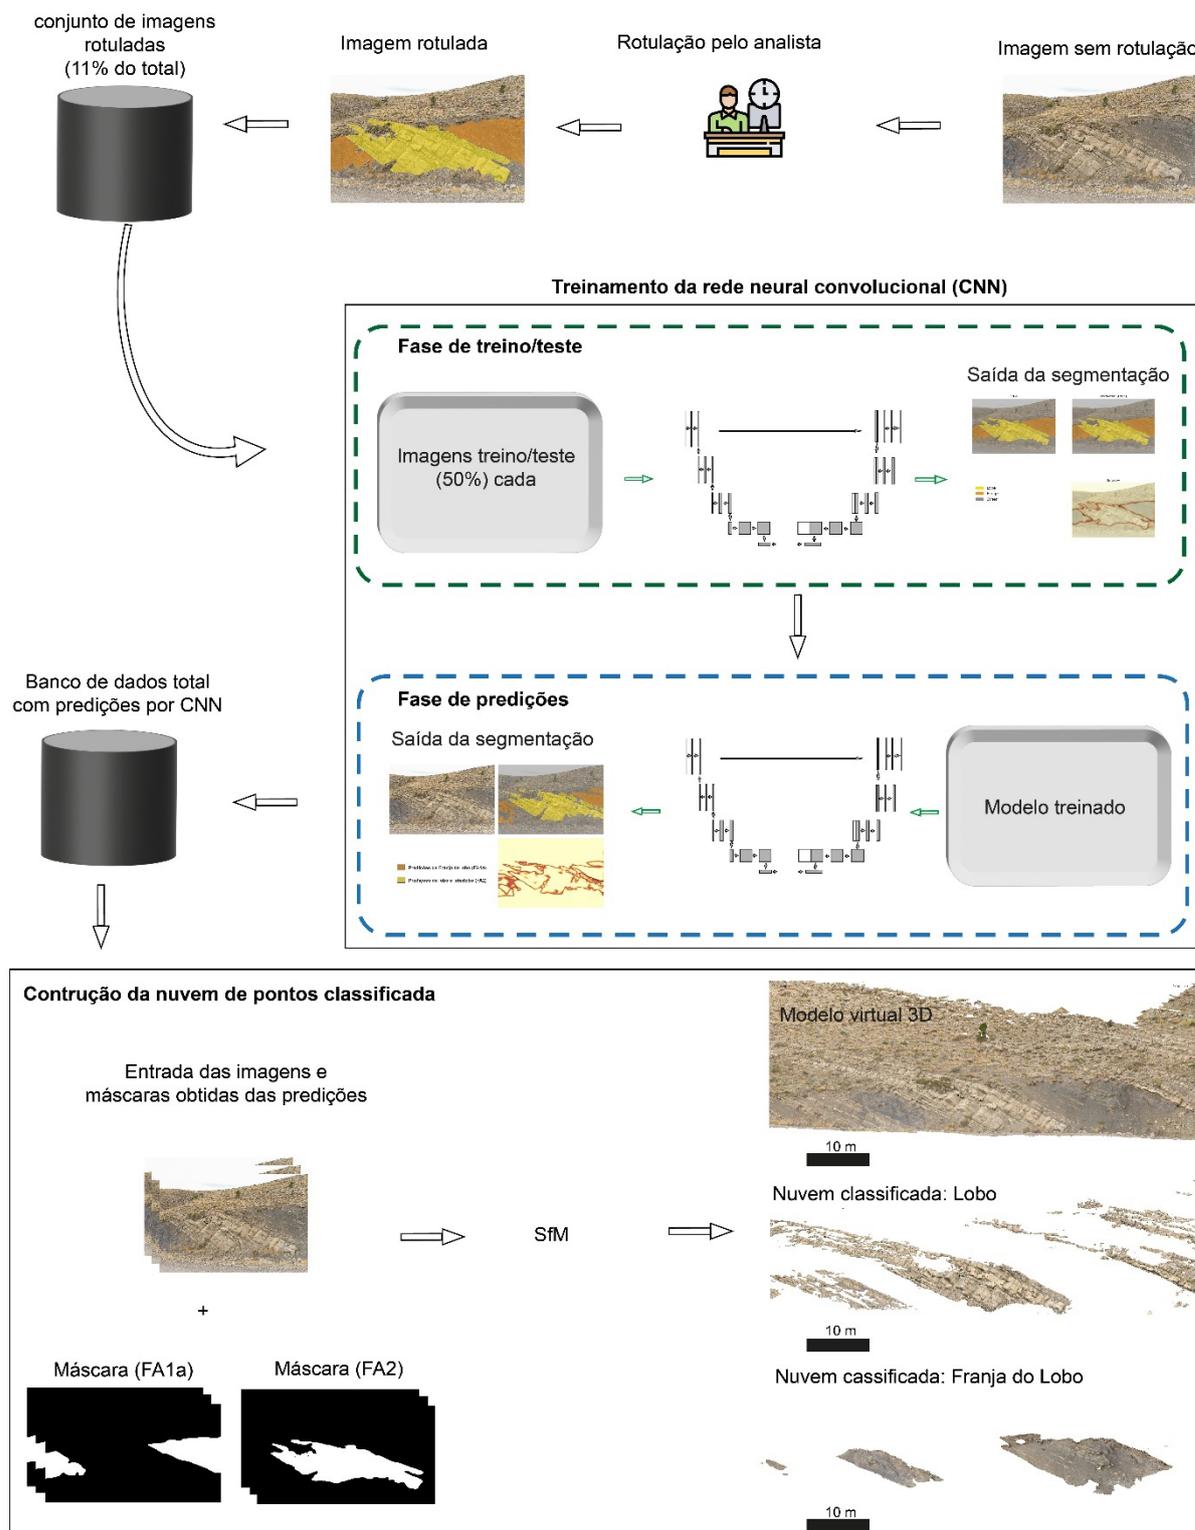
Os dados utilizados para a construção do modelo 3D do afloramento classificado por associações de fácies incluem as imagens obtidas em campo e o levantamento faciológico disponível na literatura. As imagens foram processadas para a construção do modelo 3D do afloramento e os logs de fácies foram amarrados ao modelo 3D para, posteriormente, executar o mapeamento das superfícies estratigráficas em 3D. Abaixo estão descritos os procedimentos realizados e os materiais utilizados na etapa de compilação e processamento de dados.

i. Imagens

Foram adquiridas em campo, 719 imagens, utilizando uma câmera com sensor *CMOS (Complementary Metal-Oxide Semiconductor)* de 1" e 20 MP, que produz fotografias com Largura do Sensor de 13,2×8,8 mm; imagem de 5472×3648 pixels; e f de 3,61 mm¹, embarcada em aeronave pilotada de forma remota (*Remotely Piloted Aircraft System – RPAS*) modelo Phantom 4 Pro. A obtenção das imagens ocorreu no dia 07 de março de 2023, por membros da equipe do projeto. A aquisição foi feita de forma manual, controlando a distância entre a câmera e o afloramento através do sistema anticolisão do RPAS e a sobreposição lateral e vertical entre as imagens através da grade do controle da aeronave. A figura 5 amostra exemplos das fotografias capturadas em campo sem processamento.

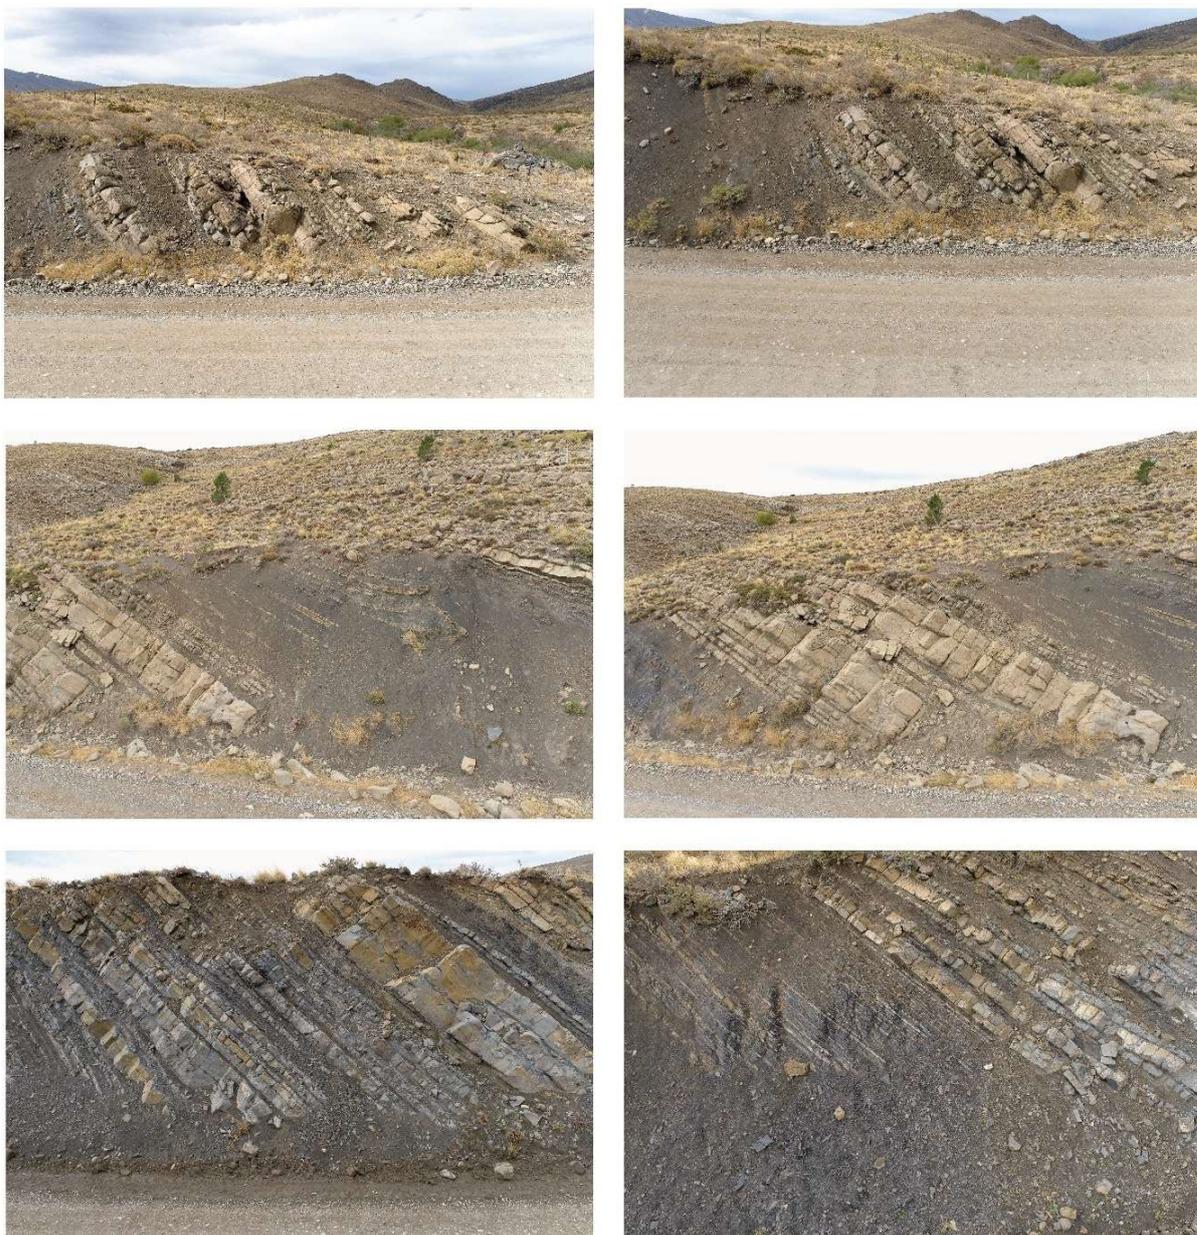
¹ (disponível em: <https://www.dji.com/br/phantom-4-pro/info#specs>)

Figura 4 – Ilustração do fluxo de trabalho para a obtenção da nuvem de pontos classificada por elementos arquiteturais dos turbiditos de La Jardineira.



Fonte: Adaptado de Malik et al. (2022). Adicionado pelo autor a construção de nuvem de pontos classificada.

Figura 5 – Exemplo das fotos adquiridas no afloramento La Jardinera, sem o processamento de ajuste do histograma de tons.



Fonte: autor.

ii. Associações de fácies

Para o mapeamento de fácies e EA nas imagens, MVA e ortofotomosaico do afloramento La Jardinera, foram utilizados os dados apresentados no trabalho de Gonçalves et al. (2022). Os dados utilizados nesse trabalho para o reconhecimento dos elementos arquiteturais são:

- Descrições detalhadas das fácies e associações de fácies;
- Informações compiladas em tabelas;
- Imagens de satélites e do afloramento interpretadas;
- Seções com associações de fácies;
- Superfícies estratigráficas de 4ª ordem e;
- Painéis panorâmicos amarrados às seções.

Sendo interpretados como depósitos turbidíticos de ambiente marinho profundo, FA1b é descrito principalmente como fácies pelitos (PI) negros e cinzas, intercalados com fácies areia maciça fina (Smf) e é interpretado como as franjas dos lobos, turbiditos de camada fina (TBTs) e depósitos hiperpicnal de corrente de turbidez. (Paim et al. 2008). Já FA2 é descrito como fácies Sg, Smg, Smm, Smf, Sr e PI; interpretados como lobos e interlobos, que são depósitos de correntes de turbidez provenientes dos canais escavados no talude e depositados no sopé do talude e planície abissal. (Paim, et al. 2008).

Três tratos de sistemas foram considerados por Gonçalves et al. (2022) para o mapeamento das superfícies e delimitação de uma sequência deposicional de 4ª ordem. (I) Trato de sistema de estágio de queda, (II) Trato de sistema de mar baixo e (III) Trato de sistema transgressivo.

O trato (I) representa uma queda do nível relativo do mar, que em depósitos turbidíticos é definido por um aumento abrupto na granulometria dos depósitos (areia grossa, arenito conglomerático e conglomerado), e é marcado pela Superfície Basal de Regressão Forçada (BSFR), que foi definida pelo autor como Limite de Sequência (SB). O final desse trato é marcado por uma superfície de conformidade correlativa (CC). (GONÇALVES ET AL. 2022).

O seguinte trato (II), representando uma regressão normal dos padrões de empilhamentos, e é delimitado por uma CC na base e uma superfície de regressão máxima (SRM) no topo. (GONÇALVES ET AL. 2022).

Por fim, o trato III representa uma retrogradação no padrão de empilhamento e é delimitado na base por uma SRM e no topo por BSFR, que representa o início da sequência deposicional seguinte. Gonçalves et al. (2022) mapeou quatro sequências deposicionais (J1, J2, J3 e J4) de 4ª ordem e 4 superfícies limítrofes (SB-1, SB-2, SB-3 e SB-4), utilizando de conceitos de estratigrafia de sequências de alta resolução de depósitos turbidíticos.

As informações aqui descritas auxiliaram na rotulação de elementos arquiteturais nas imagens, treinamento da CNN e, posteriormente, classificação automática da nuvem de pontos.

iii. Processamento das imagens para a construção de nuvem de pontos, malha triangulada texturizada, ortofotomosaicos,

As imagens foram processadas utilizando o Software Lightroom versão 10.0.22621 (ADOBE SYSTEMS INCORPORATED, 2023) com o objetivo de corrigir e padronizar o histograma de tons. As alterações foram feitas nos parâmetros das imagens, tais como contraste, exposição, entre outros.

De início, utilizou-se a opção de correção automática dos parâmetros, fornecida pelo programa. Posteriormente, foram realizadas correções nos parâmetros de forma manual, para realçar e aprimorar características da visualização dos afloramentos rochosos. As correções foram inicialmente aplicadas em uma imagem representativa e, em seguida, foram automaticamente aplicadas em todas as imagens.

iv. Correlação Logs x modelo 3D e ortofotomosaicos e Mapeamento das superfícies estratigráficas

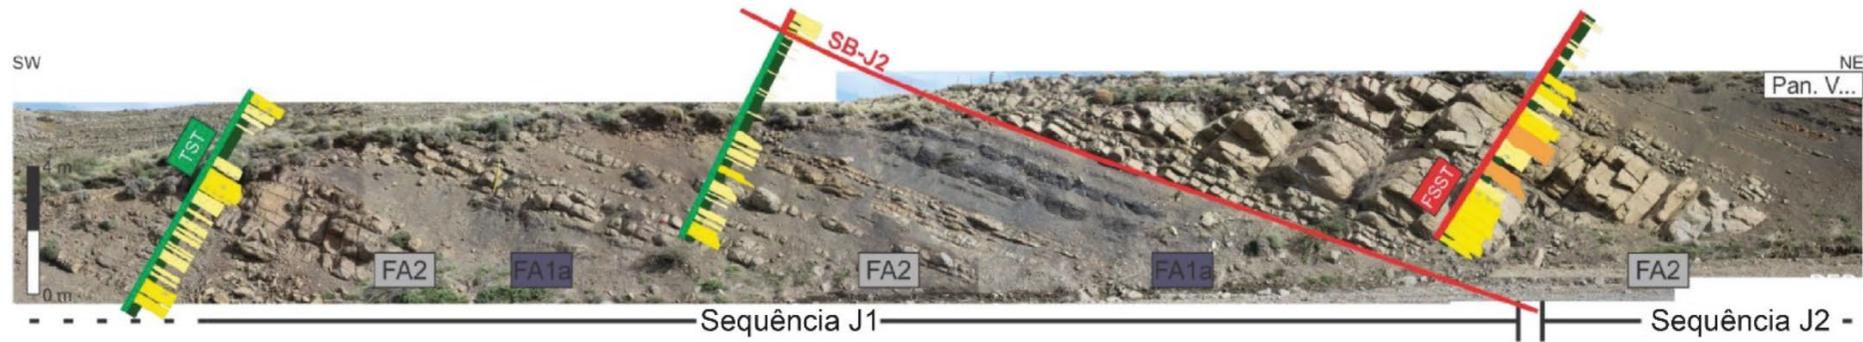
A correta identificação e classificação dos elementos arquiteturais é de suma importância para o trabalho, já que rotulações errôneas causam retardamentos no fluxo de trabalho, sendo que o analista responsável tenha que revisar as rotulações.

Para evitar tal fato, foram utilizados os produtos do levantamento feito em campo, MVAs e ortofotomosaico; importadas no *Software MOVE, Structural Geology Modelling* Versão 1.0.472. 2022 (*PETROLEUM EXPERTS*) para correlação e identificação das fácies e associação de fácies, utilizando como base os painéis panorâmicos encontrados no trabalho de Gonçalves et al. (2022), exemplo da Figura 6. Para realizar as atividades no *Software* foram utilizadas ferramentas do programa como:

- *Advance*, que permite mover, escalar ou rotacionar objetos;
- *Line*, para criar linhas;
- *Surface*, para criar superfícies;
- *To section*, para transferir objetos para seção de análise;
- *Mensure*, para mensurar o tamanho dos objetos.

Sendo assim, foi possível realizar a integração de dados em 3D e 2D, sobrepondo o perfil estratigráfico retirado do artigo de Gonçalves et al. (2022) e traçando as superfícies limítrofes SB-J2, SB-J3 e SB-J

Figura 6 - Imagem panorâmica de parte do afloramento La Jardinera integrado com Logs de fácies medidos em campo, indicação das sequências J1 e J2 e superfície limítrofe no limite entre as duas as sequências (SB-J2).



Fonte: Gonçalves et al. (2022). Traduzido pelo autor.

b. Redes Neurais Convolucionais (CNNs) – Deep Learning

Para o treinamento do modelo de segmentação, foram realizadas rotulações (máscaras) dos respectivos elementos arquiteturais em aproximadamente 11% (69 fotos) do conjunto de imagens original, em formato JPG, com o histograma de tons corrigido.

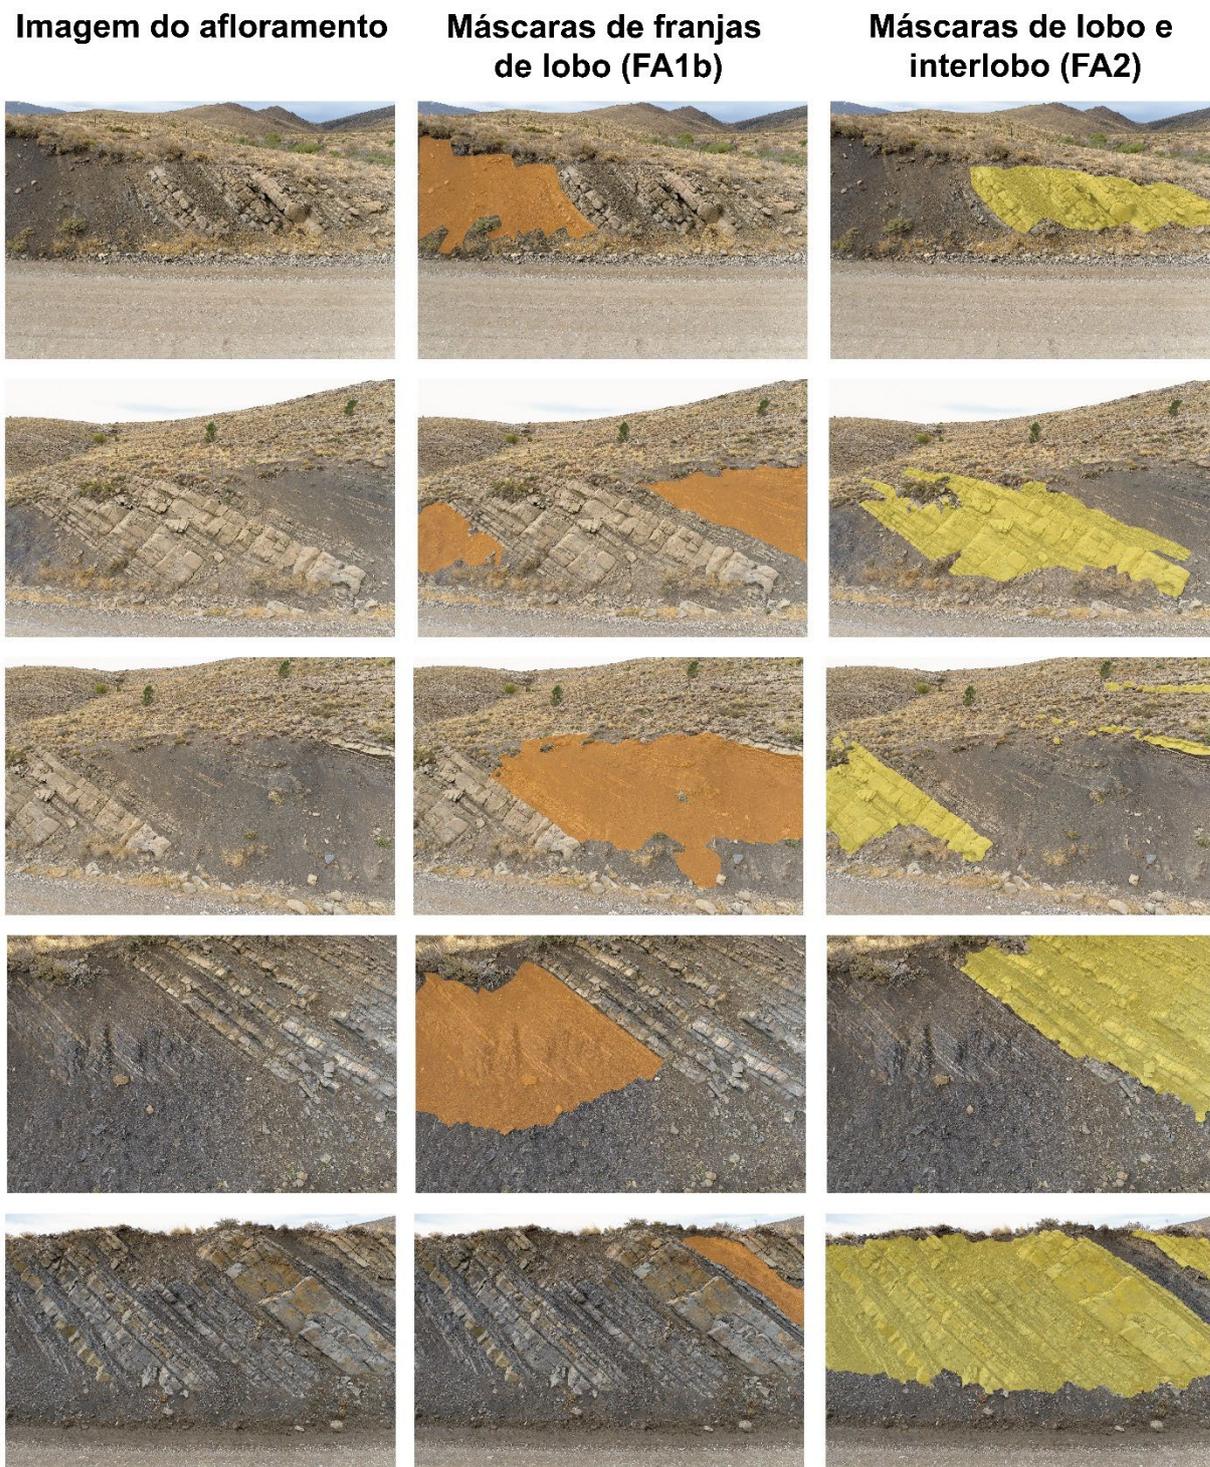
As máscaras foram criadas no *software* Adobe Photoshop (*ADOBE SYSTEMS INCORPORATED* Versão 23.5.5. 2023). Utilizando ferramentas do programa como laço poligonal, varinha mágica, balde de tinta e gerenciador de máscaras, foi possível exportar as máscaras separadas, em formato PNG, dos EA identificadas em cada foto pelo analista. (Figura 7).

Qualquer objeto encontrado nas imagens do afloramento que não possuem características fotogramétricas e texturais de rocha aflorante, como o céu, vegetação, o chão da rodovia, sedimentos inconsolidados, entre outros; não foram rotulados. No afloramento em questão a dificuldade principal foi em não rotular vegetação, que mesmo rasteira, cobre porcentagem considerável do afloramento; e sedimentos inconsolidados que, devido ao pelito ser muito friável, é facilmente possível confundir o que rocha exposta do que é sedimentos da própria rocha.

Posteriormente, no código descritos a seguir, esses objetos foram incluídos na classe “outros”, para predições de rochas (elementos arquiteturais) e “não rocha”. O treinamento da CNN foi realizado a partir de um código escrito em linguagem Python, usando a biblioteca especializada *TensorFlow*, em uma máquina equipada com um Intel Core I7 12ª geração e placa de vídeo NVIDIA GeForce RTX A5500 com 24 GB de memória dedicada e 16 GB de memória compartilhada.

O código, que tem como algoritmo principal uma adaptação do algoritmo U-net, foi executado no *Software* SPYDER IDE. Versão 5.4.3. Desenvolvido por *SPYDER Community*, onde foram realizados *Downloads* de bibliotecas específicas do *Python*, como o próprio pacote do U-net.

Figura 7 – Exemplos de produtos das rotulações de elementos arquiteturas nas imagens, para o treinamento da Rede Neural. Em laranja as máscaras criadas para FA1b e em amarelo para FA2.



Fonte: autor.

Antes do modelo de segmentação ser iniciado, foram aplicados pré-processamentos através do código *Python* com objetivo de acelerar e otimizar o processo de segmentação como:

- Aplicação de *Data Augmentation* (Shorten., Khoshgoftaar, 2019), que engloba um conjunto de técnicas que aumentam o tamanho e a qualidade dos conjuntos de dados de treinamento.
- Redução da resolução das imagens, de 5.472x3.648 para 256x384
- Divisão do processo em treino e teste do modelo, descritos a seguir.

O modelo de segmentação está separado em quatro fases principais (I) treino, (II) teste, (III) predições, e (IV) validações. As três primeiras fases são muito similares, onde é aplicado o U-net para a segmentação semântica supervisionada, dividindo os pixels em pixels menores e extraíndo informações de padrões RGB através das camadas convolucionais.

Parâmetros importantes que podem ser alterados no modelo, e consequentemente alteram os resultados da segmentação, são:

- Tamanho do bloco, que determina quantos níveis de convolucionais que U-net irá descer;
- Tamanho do lote, que é quantidade de fotos que serão analisadas por vez;
- O número de épocas, que é o número de passagens completas pelo conjunto de dados de treinamento;
- Quantidade de canais convolucionais e;
- E porcentagens das fotos usadas em cada fase.

Em todas as fases foram usados o mesmo tamanho de blocos, o mesmo número de épocas e o mesmo tamanho de canais convolucionais 4, 50 e 32, respectivamente.

Foram empregados lotes de 10 nas fases I e II, de 8 na fase III e 4 na fase IV. A mudança de lote é necessária para não exaurir a memória da GPU durante o processamento dos dados. A fase de treino consiste no modelo reconhecer os padrões nas imagens originais, através de segmentação de padrões de cor (RGB),

recorrendo as rotulações das máscaras feitas pelo analista. Em outras palavras, o código aprende a reconhecer tais características RGB dos EA, Lobo e Interlobo ou Franja dos Lobos.

Os padrões aprendidos são aplicados na fase seguinte (II), realizando a segmentação para reconhecer os mesmos padrões, dessa vez em 50% das imagens não usadas na fase de treino, possibilitado pela sobreposição das imagens.

Na fase III, os padrões RGB aprendidos nas fases I e II são aplicados ao banco de dados original (719 fotos). Dessa forma, é possível extrair máscaras de elementos arquiteturais de todas as imagens. Só que neste caso, resultado das predições por aprendizado profundo, ao invés de trabalho totalmente humano.

Uma ferramenta estatística aplicada nas fases de treino e teste, para verificar e melhorar a acurácia que o modelo possui em identificar os EA nas imagens, é o conceito de entropia, que pode ser utilizado para medir o grau de incerteza de uma predição probabilística. Onde a entropia da distribuição p é dado por:

$$H = -\sum p * [\text{Log } p].$$

Nas fases I e II do treinamento do modelo, a entropia foi calculada, com o objetivo de otimização do modelo e, a partir da geração de mapas de entropia, verificação visual dos locais onde a entropia eram maiores ou menores, indicando a precisão do modelo de predizer os padrões de EA. Por fim, na fase IV é aplicado um código modificado do usado nas fases I e II, onde de forma sequencial os testes são feitos com 7%, 14%, 21%, 28%, 42% e 49% das fotos rotuladas.

Como o objetivo de validação dos dados e do modelo de segmentação para esse conjunto de imagens, é possível vislumbrar a acurácia do modelo de acordo com a porcentagem de fotos usadas (50%) e qual a quantidade mínima de fotos rotuladas para que o modelo seja treinado obtendo acurácia satisfatória.

c. Construção e interpretação das nuvens de pontos por associação de fácies

O processamento para a construção da nuvem de pontos 3D classifica por tipo de rocha, nesse caso por associação de fácies; é muito similar à construção padrão de MVAs e consiste na aplicação do conjunto de algoritmo SfM, utilizando o *Software Agisoft Metashape*.

Porém, para que a nuvem de pontos seja classificada a partir dos resultados das predições, é necessário:

- (I) Criar pastas de trabalhos (*Chunks*) diferentes para cada classificação, nesse caso foram criados um para FA1b e outro para FA2;
- (II) Importar as imagens e realizar o alinhamento para construção da nuvem esparsa, em ambos os *Chunks*;
- (III) Importar as máscaras resultados das predições, em formato PNG, dentro dos *Chunks* correspondentes e;
- (IV) Realizar a construção da nuvem densa em cada *Chunk* separadamente.

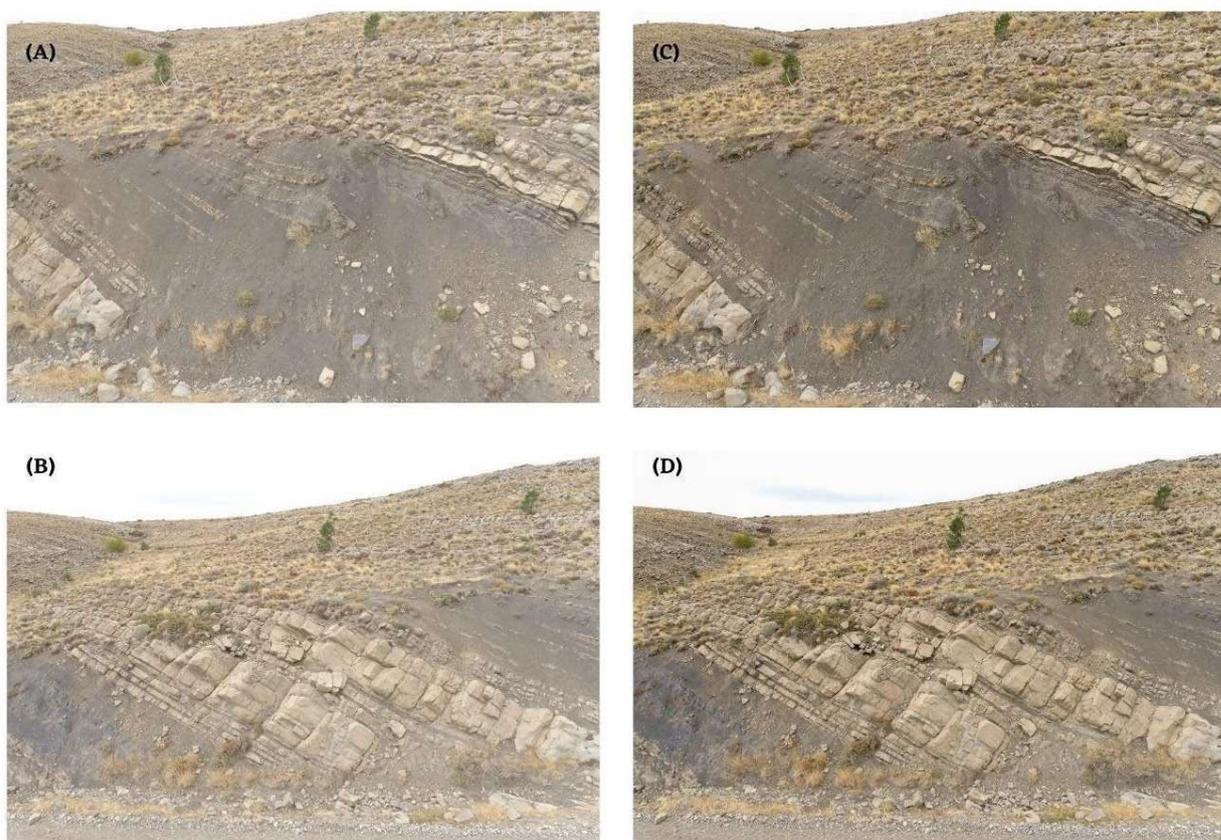
Dessa forma, pode-se obter a nuvem de pontos 3D classificada e com a finalidade de obter melhor classificação dos elementos arquiteturais, é possível deletar pontos que não estejam classificados corretamente.

4. RESULTADOS

a. Processamento de imagens

As Imagens corrigidas foram importadas para o *software Agisoft Metashape Standard* versão 2.0.1 (2023 © Agisoft), para o processamento de modelos virtuais 3D de afloramento (MVAs) e ortofotomosaicos. O programa utiliza diversos algoritmos para a construção dos modelos através do fluxo de trabalho SfM-MVS. A Figura 8 ilustra brutas, sem processamento (A e B) e com o processamento de correção do histograma de tons.

Figura 8 - Exemplo de uma imagem para correção dos parâmetros de tons. A e B estão sem correções. C e D estão com o histograma de tons corrigidas



Fonte: autor.

b. Processamento de Modelos Virtuais de afloramento e ortofotomosaicos

Com o processamento das imagens foi possível obter MVA do afloramento La Jardineira, que possui 17.467.721 facetas, com 674 metros de extensão lateral e 70 metros máximos de extensão horizontal. Foram gerados também a nuvem de pontos densa, que conta com 73.973.127 pontos e ortofotomosaicos de toda a extensão do afloramento, que possui resolução de 107525x61485 e 5,21 mm/pixel.

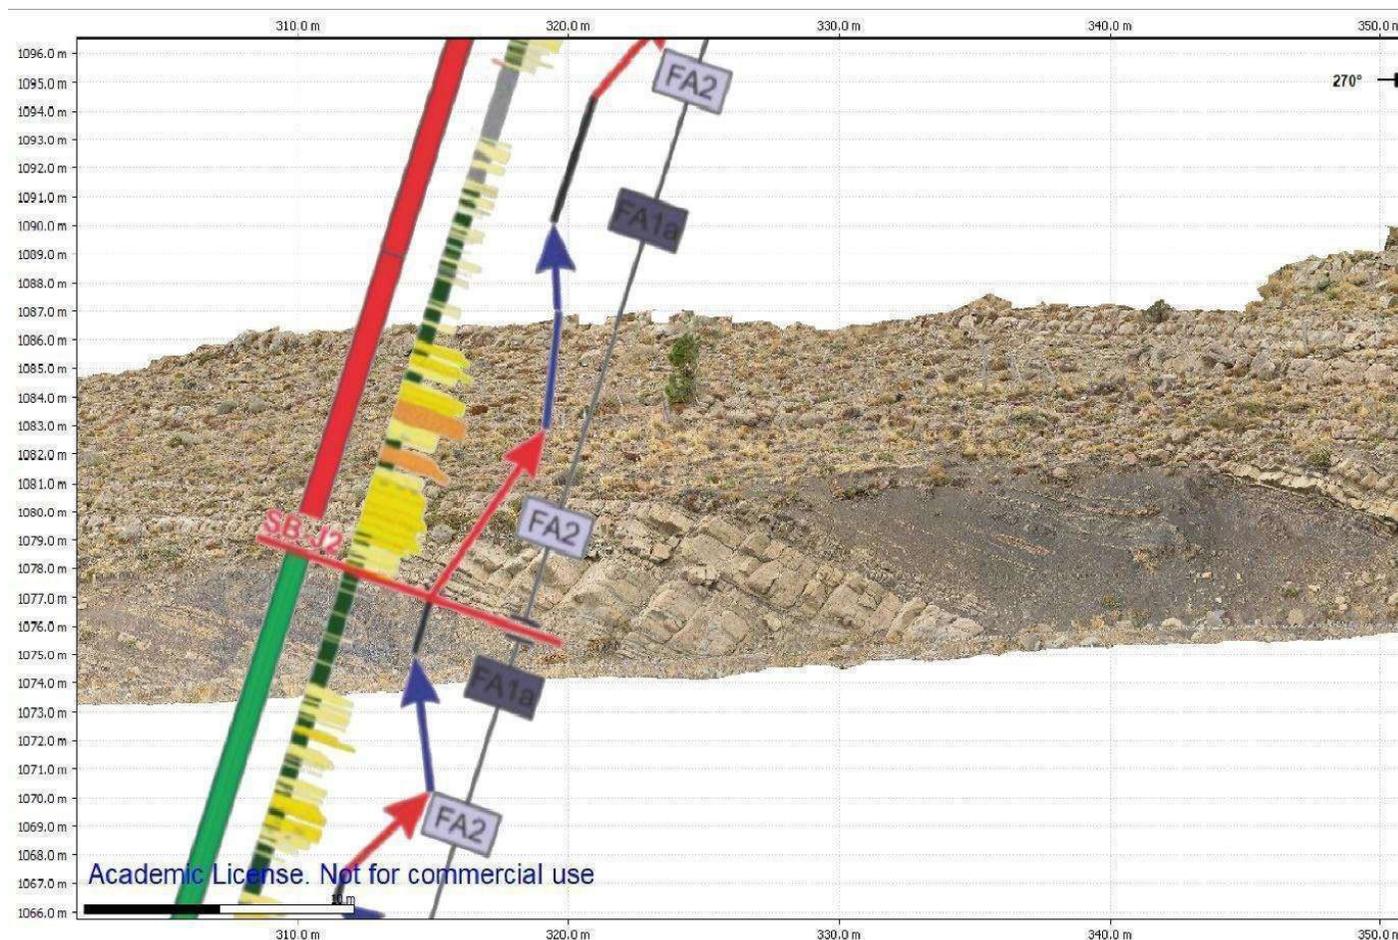
c. Integração de dados em 3D e 2D e delimitação de elementos arquiteturais

As nomenclaturas aqui utilizadas para a identificação dos elementos arquiteturais e, posteriormente, a construção das máscaras rotuladas utilizadas no processo de classificação e identificação de forma automatizada foram as usadas por Gonçalves et al. (2022); FA1b e FA2.

Para tal fim, foram utilizados os produtos do levantamento feito em campo, MVAs e ortofotomosaico, importados no MOVE. Utilizando ferramentas do programa, foi possível fazer a integração de dados em 3D e 2D, sobrepondo o perfil estratigráfico (Figura 9) extraído do artigo de Gonçalves et al. (2022) e traçando as superfícies limítrofes SB-J2, SB-J3 e SB-J4 (Figura 10). A porção descrita pelos autores como sequência deposicional J1 foi parcialmente imaginada em campo, por isso a SB-J1, que delimita o início da J1, não foi traçada.

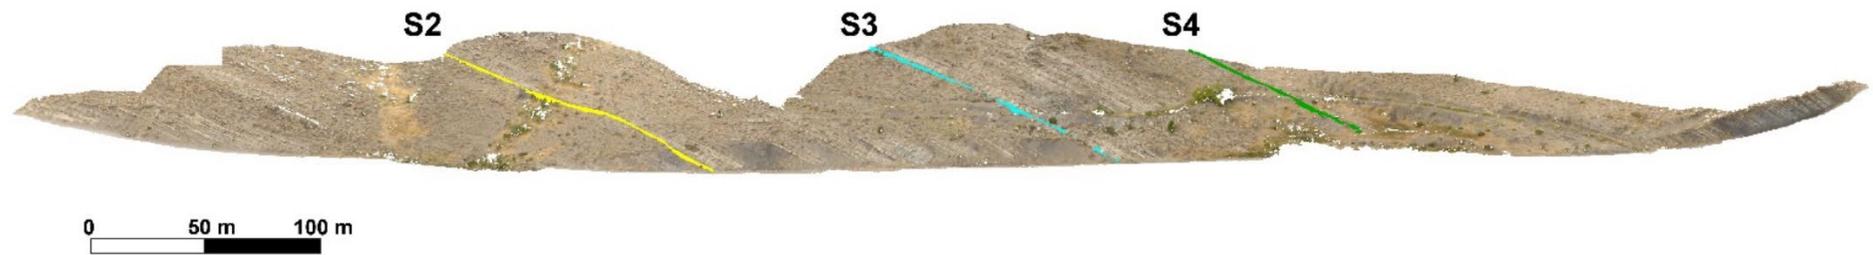
Com os perfis sobrepostos ao modelo, foi reconhecido cada mudança de elementos arquiteturais ao longo do afloramento, da J1 para a J4. Para fins de certeza de identificação e, posteriormente, rotulação dos elementos arquiteturais corretamente.

Figura 9 - A imagem demonstra o MVA de La Jardinera construído no software Agisoft Metashape, importado no software MOVE e sobreposto ao log de fácies extraído de Gonçalves et al. (2022).



Fonte: autor.

Figura 10 – MVA do afloramento La Jardinera interpretado por seqüências deposicionais.

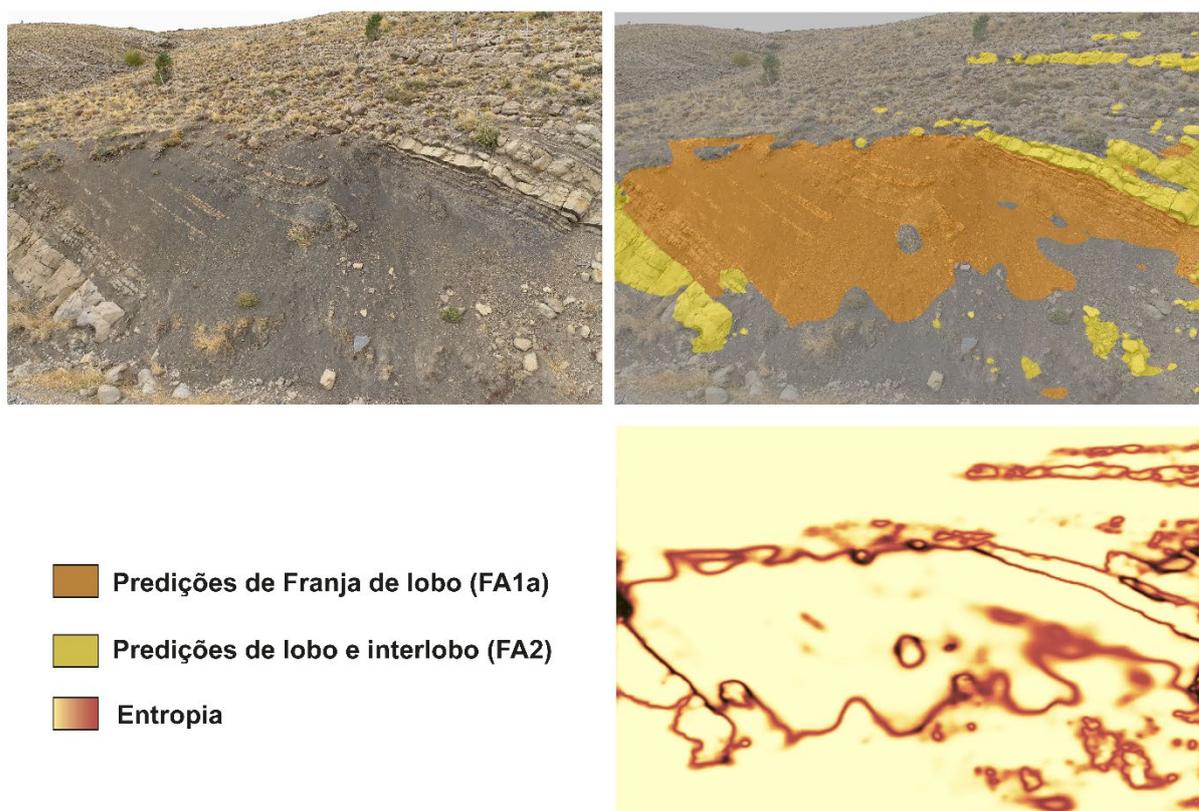


d. Treinamento da CNN

A partir do treinamento da CNN descrito anteriormente, foi possível chegar ao valor de acurácia total de 84% do modelo nas fases I e II. Isoladamente por elementos arquiteturais, o modelo atingiu cerca de 69% para FA2 e 74% para FA1b.

Para a fase III, visualizando o mapa de entropia gerado durante essa fase, é possível identificar onde o modelo teve maior assertividade ou dificuldade em prever corretamente os EA e objetos como “outros”. A seguir, exemplos dos dados visuais obtidos na fase de predições, em todas as 719 imagens:

Figura 11 – Exemplo de resultado da predição de elementos arquiteturais na foto 477.



Fonte: autor.

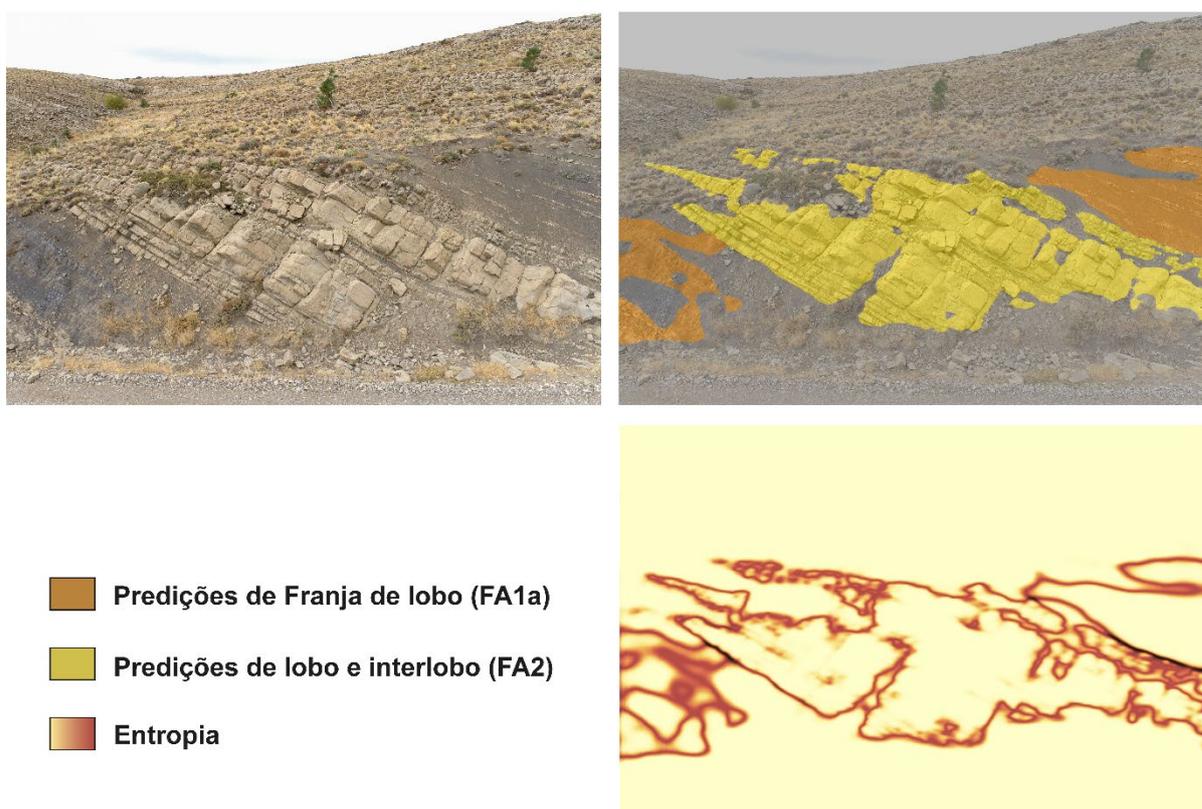
A partir dos exemplos das predições nas imagens 11 e 12 é possível verificar, pelo mapa de entropia, que a dificuldade de predição aumenta nos limites entre elementos arquiteturais. O que condiz com o fato de a probabilidade da incerteza ser maior ao passar de um EA para o outro.

Em relação a assertividade das predições, visualmente condiz com a acurácia total de 85% e com os valores de acurácia de cada EA, sendo FA1b com menor entropia, portanto melhor classificado.

Levando em consideração os resultados obtidos por Bessane (2022) e Malik et al (2022), é possível perceber que o modelo tende a reconhecer as fotofácies arenito e pelito. A foto é evidenciada na figura 11, onde é possível perceber que o modelo classificou como FA2 blocos rolados de arenito no meio dos sedimentos inconsolidados.

Já na figura 12, as previsões estão visualmente mais assertivas para FA2 do que para FA1b. Porém, comparado ao mapa de entropia, é possível verificar no canto inferior esquerdo da imagem FA1b está com problemas de assertividade. Possivelmente isso acontece devido ao local possuir muita vegetação rasteira e por ser difícil diferenciar a rocha sã dos sedimentos, o que dificulta a predição correta do modelo.

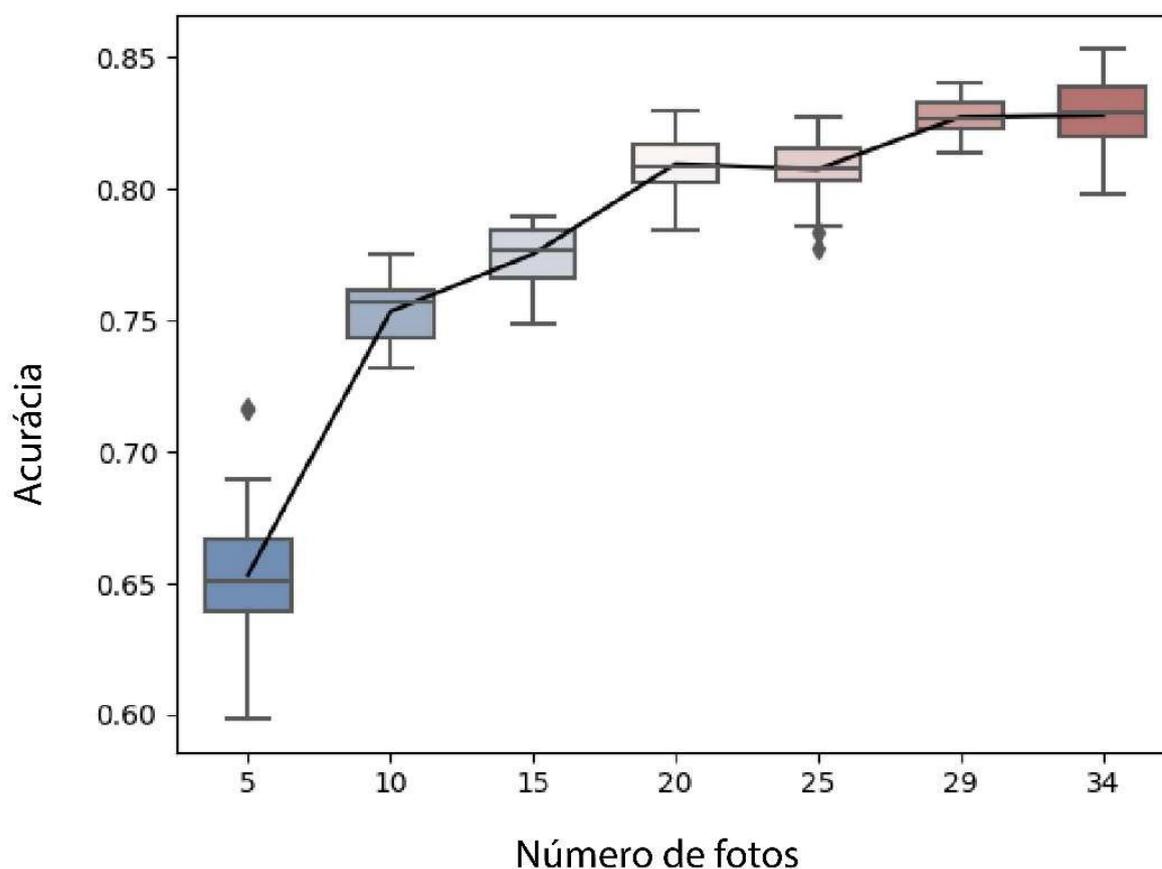
Figura 12 – Exemplo de resultado da predição de elementos arquiteturais na foto 484.



Fonte: autor.

O gráfico a seguir demonstra o resultado das validações obtidas na fase IV, mostrando os valores de acurácia de acordo com a quantidade de fotos utilizadas.

Figura 13 - Gráfico obtido na fase de validação.



Fonte: autor.

Analisando o gráfico, é possível verificar que a partir de 20 fotos a curva dos valores de acurácia começa a estabilizar. Uma interpretação para o fato é que, para esse banco de dados de imagens do afloramento La Jardinera, 20 fotos seriam necessárias para treinar o modelo e obter previsões satisfatórias. Porém não foi realizado o treinamento da Rede Neural com somente 20 fotos para verificar essa hipótese.

e. Construção e interpretação das nuvens de pontos por associação de fácies

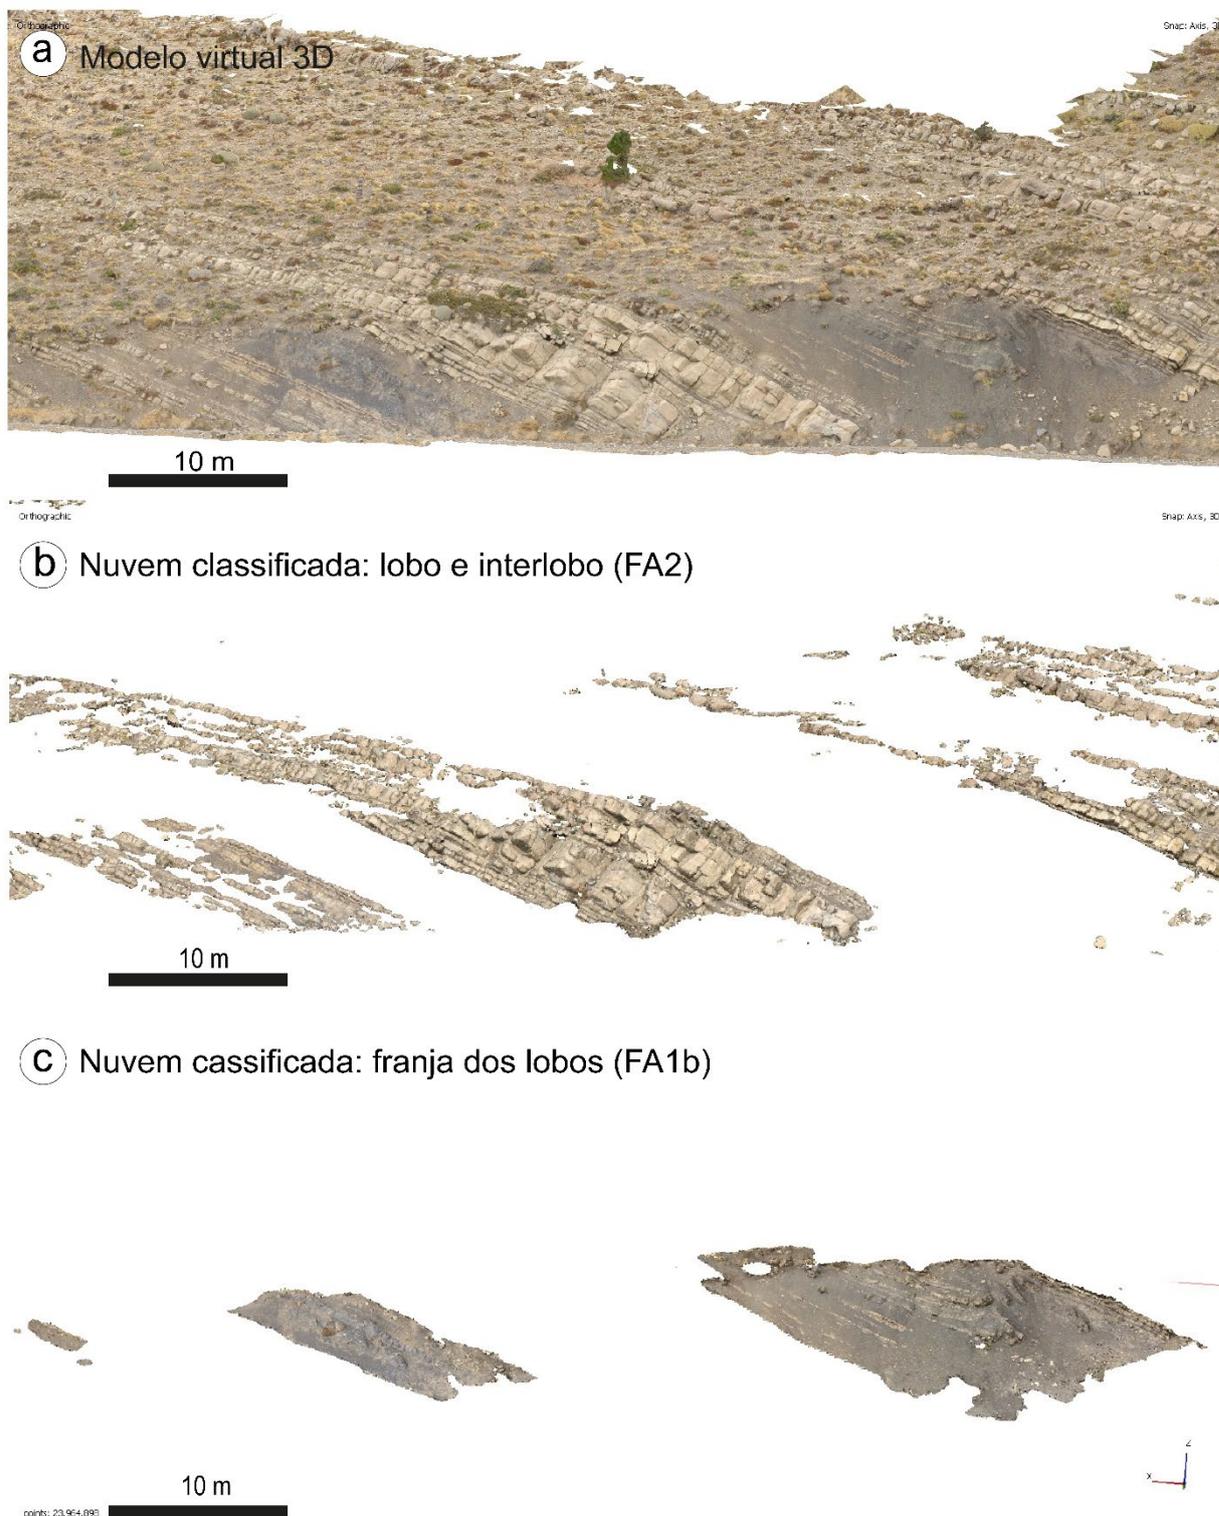
Através da obtenção de máscaras de EA das predições do modelo de segmentação para todas as 719 imagens, foi possível gerar as nuvens de pontos classificadas.

O modelo de classificação automática da nuvem de pontos 3D por elementos arquiteturais, Lobo e Interlobo (FA2) e Franja dos Lobos, dos turbiditos de La Jardinera, demonstrou robustez. As nuvens de pontos foram geradas em nível alto e contêm 457.117.390 pontos, sem classificação, enquanto as classificadas contêm 23.964.898 (5,24%) e 81.287.389 (17,78%) pontos, para FA1b e FA2, respectivamente. Dessa forma, 351.865.103 pontos da nuvem original foram excluídos automaticamente. A imagem 13 a seguir representa parte da nuvem de pontos classificada por EA obtida nesse trabalho.

Embora ocorreram classificações imprecisas em algumas áreas, os resultados obtidos possuem robustez, considerando a precisão avaliada nas etapas de treinamento e teste do modelo de segmentação. Uma hipótese para o resultado eficaz alcançado na classificação automatizada é a complementaridade entre dois algoritmos classificadores utilizados no processo, U-net e *Scale-Invariant Feature Transform (SIFT)*.

As imprecisões geradas durante o treinamento do modelo de segmentação das redes neurais convolucionais (CNNs) utilizando o U-net, foram reduzidas no processo de geração da nuvem de pontos (*Structure from Motion - SfM*) através do uso do algoritmo *SIFT*, que classificou um determinado elemento arquitetural apenas nos postos-chave onde eram encontradas as mesmas máscaras em diferentes imagens (princípio da paralaxe). A Figura 13 ilustra as nuvens de pontos obtidas no presente trabalho.

Figura 14 – Nuvens de pontos colorida por RGB sem classificação (em A), classificada como lobo e interlobo (em “b”) e classificada como franja dos lobos (em “c”).



Fonte: Autor.

5. CONSIDERAÇÕES FINAIS

A rotulação automática dos elementos arquiteturais foi realizada com sucesso, a partir de um banco de dados de 69 imagens de treinamento. Os resultados obtidos indicam que 20 imagens rotuladas teriam sido suficientes para obter valores de acurácia satisfatória do modelo.

Fatores que contribuíram para o sucesso desta metodologia foram o alto nível de redundância entre as imagens (todas pertencentes à mesma área, afloramento etc.) e a robustez do algoritmo SfM-MVS a eventuais erros de classificação. A nuvem 3D classificada pode ser usada para outros tipos de trabalho, como modelagem geológica implícita, para facilitar a extração de dados estruturais, estratigráficos.

Tarefas que não foram executadas nesse trabalho:

- Predição das máscaras a partir de um modelo treinado com somente 20 imagens;
- Estabelecimento de um nível de corte em relação à entropia, definindo as máscaras somente em regiões de baixa incerteza;
- Interação com o modelo em tempo real, corrigindo eventuais erros de classificação e treinando o modelo novamente.

Com base na análise geológica e nos resultados dos trabalhos de Bessane (2022) e Malik et al. (2022), verifica-se que o modelo de segmentação proposto obteve melhor resultados na previsão de diferentes fotofácies. Isso provavelmente se deve aos distintivos padrões RGB do arenito e dos lamitos negros.

Portanto há uma forte tendência de popularização da inteligência artificial na área de geociências, razão pela qual é muito importante que os profissionais da área se familiarizem com estas técnicas.

REFERÊNCIAS

1. ADOBE SYSTEMS INCORPORATED. **Adobe Lightroom: Software de edição e organização de fotografias**. Versão 10.0.22621. Ano de lançamento: 2023. Disponível em: 05 de maio de 2023.
2. ADOBE SYSTEMS INCORPORATED. **Adobe Photoshop: Software de edição de imagens**. Versão 23.5.5. 2023. Disponível em: . Acessado em: 05 de maio de 2023.
3. AGISOFT LLC. **Agisoft Metashape: Software para processamento de imagens fotogramétricas**. Versão 2.0.1. 2023. Disponível em: <https://www.agisoft.com/> . Acessado em: 05 maio de 2023.
4. Bessane, Alex Willian. **Construção de Classificador de rochas em afloramento da Bacia Lusitânica por meio de aprendizagem de Máquina**. / Alex Willian Bessane. 50 p. Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Pampa, Geologia, 2022.
5. BUSTILLO, J. G. et al. **Black Hole Weather Forecasting with Deep Learning: A Pilot Study**. The Astrophysical Journal Letters, v. 892, n. 2, p. L25, 2020. DOI: 10.3847/2041-8213/ab75f7.
6. CAWOOD, Adam J. et al. **LiDAR, UAV or compass-clinometer? Accuracy, coverage and the effects on structural models**. Journal of structural geology, v. 98, p. 67-82, 2017.
7. CORRADETTI, Amerigo et al. **Quantitative analysis of folds by means of orthorectified photogrammetric 3D models: a case study from Mt. Catria, Northern Apennines, Italy**. The Photogrammetric Record, v. 32, n. 160, p. 480-496, 2017.

8. DENG, Li. **A tutorial survey of architectures, algorithms, and applications for deep learning**. APSIPA transactions on Signal and Information Processing, v. 3, p. e2, 2014.
9. GONÇALVES, ARIENTI L. et al. **High-resolution sequence stratigraphy applied to turbidites: The case study of Jurassic Los Molles Formation, Neuquén Basin, Argentina**. Journal of South American Earth Sciences, v. 104, p. 102835, 2020.
10. GONÇALVES, Ítalo Gomes; KUMAIRA, Sissa; GUADAGNIN, Felipe. **A machine learning approach to the potential-field method for implicit modeling of geological structures**. Computers & Geosciences, v. 103, p. 173-182, 2017.
11. GULISANO, C. A. et al. **Esquema estratigráfico de la secuencia jurásica del oeste de la provincia del Neuquén**. In: Congreso Geológico Argentino. 1984. p. 236-259.
12. KHAN Et al. **A guide to convolutional neural networks for computer vision**. Synthesis lectures on computer vision, v. 8, n. 1, p. 1-207, 2018.
13. LOWE, David G.
14. **Distinctive image features from scale-invariant keypoints**. International journal of computer vision, v. 60, p. 91-110, 2004.
15. MALIK, Owais A.; PUASA, Idrus; LAI, Daphne Teck Ching. **Segmentation for Multi-Rock Types on Digital Outcrop Photographs Using Deep Learning Techniques**. Sensors, v. 22, n. 21, p. 8086, 2022. <https://doi.org/10.3390/s22218086>
16. MARQUES JR, Ademir et al. **Virtual and digital outcrops in the petroleum industry: A systematic review**. Earth-Science Reviews, v. 208, p. 103260, 2020.

17. PAIM, Paulo SG et al. **High resolution stratigraphy and gravity flow deposits in the Los Molles Formation (Cuyo Group, Jurassic) at La Jardinera region, Neuquén basin.** Revista de la Asociación Geológica Argentina, v. 63, n. 4, p. 728-753, 2008.
18. PASETTO, Giovanni Argenta et al. **Modelagem Geológica Implícita em Mina de Mármore no Complexo Metamórfico Passo Feio, Rio Grande do Sul, Brasil.** Anuário do Instituto de Geociências, v. 43, n. 4, p. 202-217, 2020.
19. PAVLIS, Terry L., MASON, Kelsey A. **The new world of 3D geologic mapping.** Gsa Today, v. 27, n. 9, p. 4-10, 2017.
20. PETROLEUM EXPERTS. **MOVE, Structural Geology Modelling Software.** Versão 1.0.472. 2022. Disponível em: [MOVE Structural Geology Modelling Software \(petex.com\)](https://www.petex.com). Acessado em: 19 de maio de 2022
21. RONNEBERGER, O.; FISCHER, P.; BROX, T. **U-net: Convolutional networks for biomedical image segmentation.** In: International Conference on Medical image computing and computer-assisted intervention. Cham: Springer, 2015. p. 234-241.
22. SAHITHYA, Gandu et al. **Comparison of Backbones for Semantic Segmentation of X-Ray Microtomography Images using Convolutional Deep Neural Architecture.** In: 2023 10th International Conference on Computing for Sustainable Global Development (INDIACom). IEEE, 2023. p. 1250-1256.
23. SHORTEN, Connor; KHOSHGOFTAAR, Taghi M. **A survey on image data augmentation for deep learning.** Journal of big data, v. 6, n. 1, p. 1-48, 2019.

24. TORBATI-SARRAF, Hamidreza et al. **Machine-learning-based algorithms for automated image segmentation techniques of transmission X-ray microscopy (TXM)**. JOM, v. 73, n. 7, p. 2173-2184, 2021.

25. WESTOBY, Matthew J. et al. **Structure-from-Motion'photogrammetry**: A low-cost, effective tool for geoscience applications. Geomorphology, v. 179, p. 300-314, 2012.