

**UNIVERSIDADE FEDERAL DO PAMPA**

**ALEX WILLIAN BESSANE**

**CONSTRUÇÃO DE CLASSIFICADOR DE ROCHAS EM UM AFLORAMENTO DA  
BACIA LUSITÂNICA POR MEIO DE APRENDIZAGEM DE MÁQUINA**

**Caçapava do sul**

**2021**

**ALEX WILLIAN BESSANE**

**CONSTRUÇÃO DE CLASSIFICADOR DE ROCHAS EM UM AFLORAMENTO DA  
BACIA LUSITÂNICA POR MEIO DE APRENDIZAGEM DE MÁQUINA**

Trabalho de Conclusão de Curso II  
apresentado no Curso de Graduação em  
Geologia da Universidade Federal do  
Pampa, requisito parcial para obtenção do  
título de Bacharel em Geologia.

Orientador: Prof. Dr. Ítalo Gomes Gonçalves

Coorientador: Prof. Dr. Felipe Guadagnin

**Caçapava do Sul  
2022**

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) .

B557c Bessane, Alex Willian  
Construção de Classificar 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.  
"Orientação: Italo Gomes Gonçalves Gonçalves".  
  
1. Aprendizagem de Máquina. 2. aeronaves remotamente  
pilotadas. 3. Geologia. 4. Identificação. 5. Classificação. I.  
Título.

**ALEX WILLIAN BESSANE**

**CONSTRUÇÃO DE CLASSIFICADOR DE ROCHAS EM UM AFLORAMENTO DA  
BACIA LUSITÂNICA POR MEIO DE APRENDIZAGEM DE MÁQUINA**

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:

17 de março de 2022.

Banca examinadora:

---

Prof. Dr. Ítalo Gomes Gonçalves

Orientador

Engenheiro de Minas - UNIPAMPA

---

Prof. Dr. Felipe Caron

Oceanógrafo

UFRGS

---

MSc. Iago Costa

Geofísico

CPRM



Assinado eletronicamente por **ITALO GOMES GONCALVES, PROFESSOR DO MAGISTERIO SUPERIOR**, em 28/03/2022, às 07:42, 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](https://sei.unipampa.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0766079** e o código CRC **0A2B95E9**.

Universidade Federal do Pampa, Campus Caçapava do Sul

## AGRADECIMENTO

10 anos... É tanta coisa pra falar que uma página não bastaria pra escrever tudo o que quero aqui. Nesse tempo muitas pessoas se foram e várias outras chegaram, mas sem dúvida nenhuma todas elas de alguma forma contribuíram na minha trajetória até aqui. Agradeço aos meus melhores amigos Garrafa ESSE HOMÃO DA P....Horta Bumbum na Lua e Trelzão uma máquina no campo esse menino, que sempre me apoiaram a terminar a graduação por mais desgastante que tenha sido l. A Hanna essa mulher maravilhosa, senhor!! Extremamente ativa em tudo que fez, servindo de inspiração para muitas pessoas, inclusive eu. Agradeço ao Conselho (Dimiboy e Donzinho) AHUU! Por terem participado de cada momento dessa trajetória, sem dúvidas, por mais que me deixassem louco às vezes, foram tipo irmãos... Nem sempre os mais corretos, mas enfim, estavam lá. Mazuque que sempre me ajudou a formatar os trabalhos e várias madrugadas jogando e assistindo anime até tarde. Menina Dinossauro (Anna Paula) não tem nem como expressar tudo o que ela fez por mim aqui, além de me aturar e ter paciência pegando pela mão, quase que literalmente pra estudar as matérias exatas, sem dúvidas ela é e será uma grande cientista aqui e fora dos pais. Samuel vulgo Lindão, por sempre estar do meu lado, não importasse o B.O. Pedro por não ter explodido no role e ter terminado vivo a graduação. Xande por ter toda a paciência do mundo e me incentivar a correr atrás dessa área da programação. Miguel Carminatti que foi praticamente um pai durante a graduação e fora dela mesmo com o jeito louco dele. Victoria me ajudou a colocar nos eixos e a tomar tento na vida. Ao antigo D9 que sejam bem-sucedidos pra onde quer que vão. Dona Aglair, praticamente uma mãe, Duda, Tatá, Kalin, Maycon, Klau, Rodrigo, Vitinho Sofia e toda equipe do Galeão dourado de SC onde foi uma segunda família por um bom tempo, sempre me lembrarei dos ótimos momentos que tive por lá. Luana a garota mais esperta que conheci com a alegria de uma criança e um coração de leão. Dona Dilma e seu Pad sempre com ótimas histórias. Liara, Leila, Bruno Katiussa e toda equipe do NUDE Caçapava do Sul e secretaria acadêmica que sempre estavam dispostos e me ajudando com toda a papelada durante a graduação. Em especial Liara e Cris, pois elas literalmente me salvaram de perder a vaga no dia. Seu Chico dono do Hotel Portal que me deu a oportunidade de trabalhar na cidade quando cheguei o que me ajudou a sustentar por muito tempo aqui. A Haline, a maior monitora de

geoestatística e avaliação de depósitos que uma pessoa poderia sonhar em ter. A todos os professores da unipampa, tenho ótimas lembranças com todos eles, Caron, Hansen, Pilar, Miguel, Mario, Max, Luis Eduardo, Igor, Osmar, Baladares, Rojas, Italo enfim, não teria espaço para agradecer e colocar todas as lembranças. A professora Dani Tolfo que sem suas aulas não teria chegado tão longe no cálculo e por seu coração que não cabia nela. Dona Francisca, mãe da Garrafa e uma segunda mãe pra mim, a detentora da melhor omelete de queijo já feito no mundo. A tia Clair, Bauer Bianca Bruno que só faltaram dar na nossa cara pra virar gente. A todos os parentes em geral, pai mãe avô por manterem a fé que ia conseguir e seguir carreira por maior que fossem as dificuldades, enfim poucas páginas para muitos agradecimentos. Ao Vinicius e o Geologando que me fez crescer horrores na área e a ter cada vez mais gosto pela divulgação científica. Muito obrigado por fazerem parte de tudo isso.

-What is better

-To be Born good, or overcome your evil nature with great effort?

-Paarthunax



## RESUMO

As imagens representam uma grande e eficiente fonte de informações nos ramos da exploração, prospecção, e de pesquisa geológica. A fim de se obter sempre melhores imagens, o aperfeiçoamento das técnicas de obtenção tem se tornado cada vez mais procuradas e aplicadas em ampla escala. Nesta, a obtenção de imagens realizadas por sistemas de aeronaves remotamente pilotadas (RPAS) tem ganhado grande destaque devido seu custo-benefício. Considerando a importância econômica e acadêmica na identificação e classificação correta, para melhor analisá-las, são utilizados vários algoritmos de aprendizagem de máquina. Porém o uso de aprendizagem de máquina requer alguns fatores relevantes, dentre estes profissionais treinados na área, capacidade computacional e um extenso banco de dados sobre o alvo de interesse. O principal objetivo deste trabalho é criar modelos que interpretem sistematicamente as rochas em um afloramento da Bacia Lusitânica, Portugal a partir de imagens adquiridas com RPAS utilizando os dados dos pixels e criar um classificador com auxílio de aprendizagem de máquina utilizando o menor número possível de imagens do banco de dados reduzindo o tempo de processamento, padronizando descrições e análise das imagens automatizando a classificação das rochas em um afloramento da Bacia Lusitânica (*boundstones*, *rudstones*, *packstones* conglomerados, siltitos laminados, siltitos maciços e arenitos). Os modelos de segmentação das imagens foram criados a partir das fotos tiradas com o levantamento aéreo com RPAS, em sequência foram utilizados filtros convolucionais discretos e posteriormente, foram aplicadas redes neurais classificadoras. Finalmente, foram testadas várias configurações utilizando diferentes modelos. Ao final deste trabalho foi alcançado resultados satisfatórios de 88 a 90% de precisão utilizando um terço do banco de dados.

Palavras-Chave: Aprendizagem de Máquina, aeronaves remotamente pilotadas, Geologia, Identificação, Classificação.

## **ABSTRACT**

Imagery represents a large and efficient source of information in exploration, prospecting, and geological survey. In order to obtain better and better images, the improvement of imaging techniques has become increasingly sought after and widely applied. In this, remotely piloted aircraft systems (RPAS) imagery has gained prominence due to its cost-effectiveness. Considering the economic and academic importance of correct identification and classification, to better analyze them, various machine learning algorithms are used. However, the use of machine learning requires some relevant factors, among them trained professionals in the area, computational capacity, and an extensive database about the target of interest. The main objective of this work is to create models that systematically interpret the rocks in an outcrop of the Lusitanian Basin, Portugal from images acquired with RPAS using the pixel data and create a machine learning aided classifier using the least possible number of images from the database reducing the processing time, standardizing image descriptions and analysis automating the classification of the rocks in an outcrop of the Lusitanian Basin (boundstones, rudstones, packstones conglomerates, laminated siltstones, massive siltstones and sandstones). Image segmentation models were created from the photos taken with the aerial survey with RPAS, in sequence discrete convolutional filters were used and subsequently, classifier neural networks were applied. Finally, various configurations using different models were tested. At the end of this work, satisfactory results of 88 to 90% accuracy were achieved using one third of the database.

Keywords: Machine Learning, remotely piloted aircraft, Geology, Identification, Classification.

## LISTA DE FIGURAS

Figura 1: Rotulação de pontos em 3D utilizando técnicas de Aprendizagem Profunda para identificação da fachada de prédios.	3
Figura 2: Mapa do Arcabouço estrutural das sub-bacias da porção oeste e central da Bacia Lusitânica	6
Figura 3: Coluna estratigráfica apresentando a Bacia Lusitânica com destaque em vermelho para a formação Lourinha.	8
Figura 4: Ortofotomosaico da formação Lourinha apresentando a coluna estratigráfica e a sequência de eventos elaborada por Magalhaes et al submetido.	9
Figura 5: Ilustração de como funciona a superposição de imagens.	12
Figura 6: A figura representa graficamente os parâmetros envolvidos na visualização estereoscópica. Considerando um objeto P fotografado de duas câmeras (C1 e C2). A posição de P, nas duas fotos vai depender dos parâmetros da câmera (distância focal) e a sua orientação	14
Figura 7: Equação representando convolução de imagens onde $f(x)$ = imagem $h(x)$ = filtro $x$ = coordenada espacial (posições dos pixels) $g(x)$ = resultado ou imagem convolvida.	15
Figura 8: Esquema ilustrando como funciona uma convolução em uma imagem.	16
Figura 9: Ilustração da arquitetura de uma U-NET.	17
Figura 10: Mosaico ilustrando foto do afloramento e máscaras aplicadas para cada litologia separadamente.	18
Figura 11: exemplo de classificação para imagens do banco de dados de treino e de teste.	20
Figura 12: Foto real mostrando a separação das litologias pelas máscaras e seu grau de precisão.	21

## LISTA DE TABELAS

Tabela 1: Acurácia alcançada com os modelos.....	20
--	----

## LISTA DE ABREVIATURAS E SIGLAS

AP .....	Aprendizagem Profundo
IA.....	Inteligência Artificial
RPAS .....	Sistemas de Aeronaves Remotamente Pilotadas
MVA.....	Modelo Virtual de Afloramento
MDE.....	Modelo Digital de Elevação
NNE.....	Norte Noroeste
SSW.....	Sul Sudoeste
SfM.....	<i>Structure from Motion</i>
SfM-MVS.....	<i>Structure from Motion- Multi View Stereo</i>
3D .....	3 Dimensões
CNN.....	Rede Neural Convolucional
AM.....	Aprendizagem de Máquina

# SUMÁRIO

INTRODUÇÃO	1
2. OBJETIVOS	3
2.1. Objetivo Geral	3
2.2. Objetivos Específicos	3
2.3. Justificativa	4
3. ÁREA DE ESTUDO	4
a. Bacia Lusitânica	4
b. Contexto Geológico	5
i. Geologia Geral da Bacia Lusitânica	5
ii. Geologia Local	7
4. REVISÃO BIBLIOGRÁFICA	10
4.1 Sensoriamento Remoto	10
4.1.1 Fotogrametria	10
4.1.2 <i>Structure From Motion</i>	12
4.1.3 MVA Modelo Virtual de Afloramento	13
4.2. Aprendizagem de Máquina	14
4.2.1. CNN e U-NET	15
5. MATERIAIS E MÉTODOS	17
5.1. Banco de Dados	17
5.2. Google colab e Python	19
5.3. <i>TensorFlow</i>	19
6. RESULTADOS E DISCUSSÃO	19

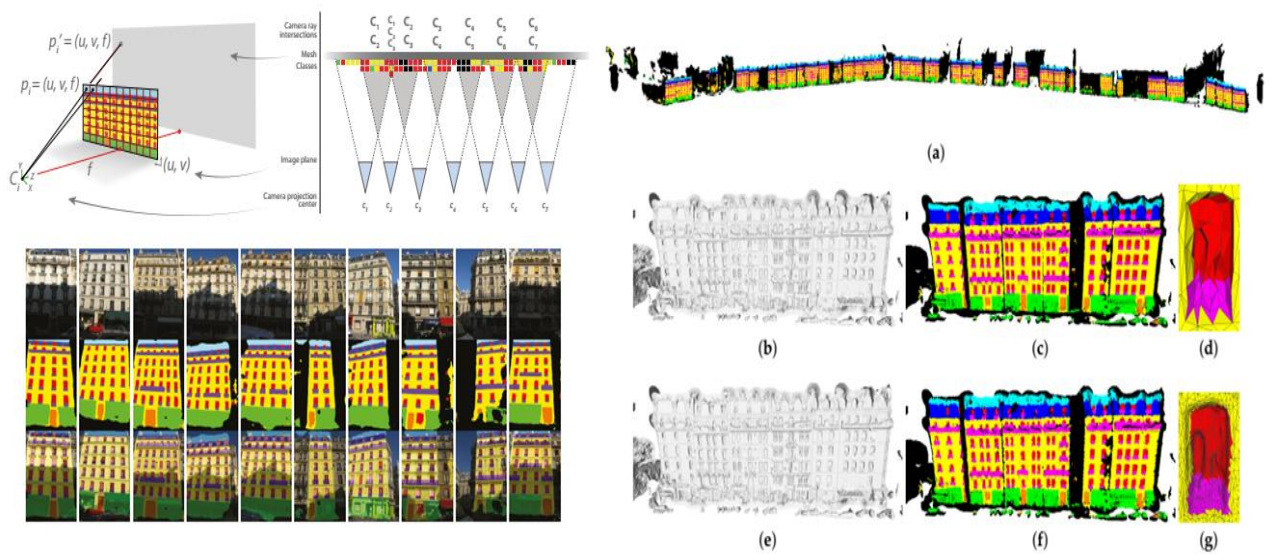
## INTRODUÇÃO

Quanto maior o conhecimento sobre a geologia de um local ou região, maior será o grau de detalhamento e acuracidade sobre as estimativas de possíveis recursos, reservas, patrimônio geológico, geofísico, estrutural, dentre outras informações, promovendo planejamento a curto, médio e longo prazo sobre o alvo de interesse. Por esses motivos, e com crescente aumento do poder computacional, o uso de imagens para obtenção de informações tem sido cada vez mais empregado na geologia (YI; PRYBUTOK, 1996; ATKINSON; TATNALL, 1997; CARPENTER et al., 1997;). No mesmo caminho, com a sofisticação e miniaturização advindos da evolução tecnológica, o uso de aeronaves remotamente pilotadas RPAS tem se mostrado uma maneira promissora para obtenção de imagens de alvos locais e regionais. Entre as várias técnicas criadas vale destacar a dos modelos virtuais de afloramento MVA devido à redução de custos quando comparado com outras, como por exemplo a de nuvem de pontos provenientes de varredura de luz LIDAR. Além disso, a possibilidade de acessos e automatização de processos já consagrados pela indústria e academia mostra um rumo proeminente na direção do uso dos MVAs como uma tecnologia viável e mais acessível (COELHO & BRITO, 2007, CARRIVICK et al., 2016, GONÇALVES, KUMAIRA., GUADAGNIN 2017., COLOMINA e MOLINA 2014). Com o progresso computacional e técnico os sistemas embarcados estão mais estáveis e precisos (ARAYA-POLO et al., 2017; HUANG et al., 2017) com maior autonomia, câmeras, baterias e módulos de comunicação e com a vantagem de uma programação computacional mais sofisticada evitando assim interações indesejadas nas RPAS durante o voo (DORN et al 2016 e PERONI, 2016). Porém, ligado a essa situação, a quantidade de informações adquiridas pelas imagens costuma ser muitas vezes maior do que a capacidade de processamento e interpretação do usuário (YI; PRYBUTOK, 1996; ATKINSON; TATNALL, 1997; CARPENTER et al., 1997), e em virtude disto, a importância de modelos de aprendizagem de máquina (AM) e aprendizagem profunda (AP) vem crescendo muito, sendo empregadas para interpretação, classificação e previsões geológicas e geofísicas (ARAYA-POLO et al., 2017; HUANG et al., 2017; WALDELAND; SOLBERG, 2017; DRAMSCH e LUTHJE, 2018;

SHI et al., 2018 ). O AM é um caminho para uma abordagem eficaz tanto para a regressão e/ou classificação (supervisionada ou não) de sistemas não lineares, sendo ideal para automatizar uma tarefa, para o qual temos muitos dados, tendo se mostrado útil para um grande número de aplicações em muitas partes do sistema terrestre valendo ressaltar o crescimento na área de interpretação de imagens por meio de técnicas de visão computacional (AP) (YI e PRYOUTOK, 1996; ATKINSON e TANALL, 1997; CARPENTER et al., 1997). Contudo quanto maior a quantidade de dados a se analisar, maior será o custo computacional e tempo envolvido para o processamento dos mesmos. Seguindo as premissas apresentadas, este trabalho propõem a construção de um classificador de rochas utilizando as imagens em um afloramento da Bacia Lusitânica - Portugal, usando o menor número possível das imagens do banco de dados visando uma redução do custo e tempo computacional exigido para a realização de tais tarefas, tendo como uma das principais metas ao final deste trabalho, a uma construção de uma nuvem de pontos em 3D com a classificação das rochas, semelhante ao trabalho de Lotte (2018) que pode ser observado na figura 1 (Fig 1) onde a mesma técnica foi utilizada para a identificação e classificação da fachada de prédios, apresentando de uma maneira simples os processos de AP na geologia onde a) é a vista dos prédios da rua, b) detalhes da geometria da fachada dos prédios por uma nuvem esparsa de pontos c) são etiquetadas após a análise d) aproximação das janelas das imagens em 3D e e),f) a geometria das fachadas por uma densa nuvem de pontos já etiquetada g) análise das etiquetas feitas em 3D na nuvem de pontos.



Figura 1: Rotulação de pontos em 3D utilizando técnicas de Aprendizagem Profunda para identificação da fachada de prédios.



Modificado de Lotte (2018)

## 2. OBJETIVOS

### 2.1. Objetivo Geral

Utilizar o banco de dados adquiridos por Guadagnin e Magalhaes (2018) mais os relatórios de estágio dos ex-alunos (MARINS 2018, COSTA 2018 e NEVES 2018) para elaborar um classificador com a utilização de técnicas de AP visando semi automatizar a rotulação das imagens em um afloramento da bacia Lusitânica

Após rotuladas, foram comparados com grau de precisão versus quantidade de imagens utilizadas para obtenção dos resultados buscando distinguir quais ou qual é o modelo ideal para a situação apresentada.

### 2.2. Objetivos Específicos

- Utilizar serviços gratuitos de hospedagem e processamento dos dados demonstrando a viabilidade do projeto;
- Identificar rochas em um afloramento por meio de técnicas de AP;
- Classificar as rochas com grau de precisão superior a 80%;
- Obter uma nuvem de pontos classificada.

### **2.3. Justificativa**

A otimização de tempo no processo de identificação e categorização das rochas em afloramentos, significa economizar dinheiro além de poder auxiliar a arquitetar formas mais adequadas de tomada de decisões de determinadas áreas proporcionando informações que colaborem com a generalização da região como um todo.

Este trabalho é a continuação de um projeto elaborado na Bacia Lusitânica mais precisamente dentro da formação Lourinha. Juntamente, os dados já foram coletados, descritos pelo Dr Guadagnin, Dr Magalhães A.J.C após levantamento de voo realizado com RPAS no ano de 2018, e ligado a isso, parte dos dados já foram previamente categorizados pelos acadêmicos (MARINS 2018, COSTA. 2018, e NEVES .2018) durante seus relatórios de estágio na Unipampa Caçapava do Sul. Assim sendo, o trabalho final será a compilação dos dados e criação de um classificador.

## **3. ÁREA DE ESTUDO**

### **a. Bacia Lusitânica**

A Bacia Lusitânica possui espessura máxima de mais de 5.000 m, acumulada ao longo de mais de 150 milhões de anos com espessura aproximada de 5 quilômetros (TAYLOR et al. 2014). A uma deformação tectônica intensa associada à inversão e perfuração do diapirismo das bacias Cretáceas e Terciárias tardias. Desenvolveu-se durante o Mesozóico sobre substratos pré-cambrianos e paleozóicos. Foi submetida a uma extensa recarga sedimentar que mais tarde resultou em bacias terciárias em alguns setores. De norte a sul, a área compreende um conjunto de falésias localizadas ao sul da Praia dos Frades (Costões), a Praia de Vale de Pombas e o Forte Nsa. Sra. Dos Anjos de Paimogo. Os afloramentos correspondem a rochas sedimentares mesozóicas, da Formação Lourinhã, pertencente a Sub-bacia Consolação, inserida na Bacia Lusitânica (TAYLOR et al. 2014). Segue a figura 2 (Fig 2) com o mapa da extensão da bacia lusitânica.

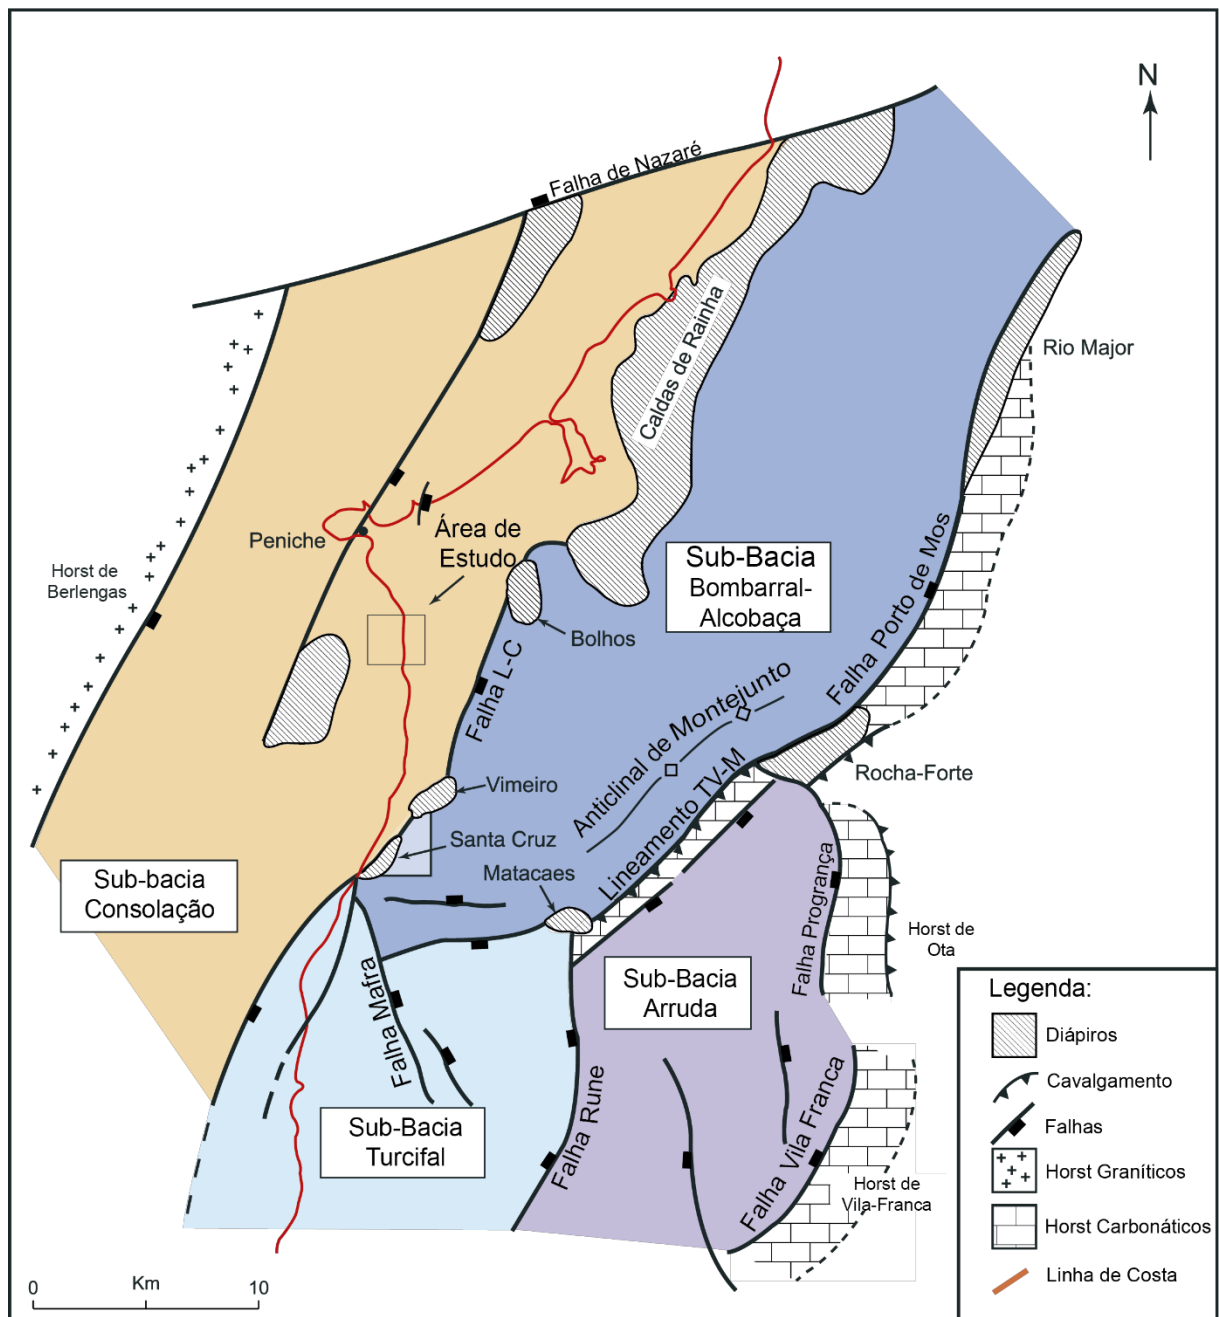
## **b. Contexto Geológico**

### **i. Geologia Geral da Bacia Lusitânica**

A Bacia Lusitânica é a maior bacia sedimentar de Portugal. Está localizada na margem Ibérica do Atlântico Norte ocupando uma área com cerca de 22.000 km<sup>2</sup> em porções offshore e onshore (MARTINIUS; GOWNLAND, 2011). Essa bacia possui sedimentos predominantemente mesozóicos, com alguns depósitos Cenozóicos, (KROTH 2018). A Bacia Lusitânica tem sua formação e evolução a partir da abertura do Oceano Atlântico Norte, sendo considerada como uma bacia do tipo rifte e a partir do triássico superior evoluindo para uma bacia *pull-apart* no final do Jurássico, sendo delimitada ao Norte pela falha de Aveiro e ao Sul pela Cadeia de Arrábida 50km ao sul de Lisboa; (RASMUSSEN et al. 1998). A Bacia Lusitânica está subdividida entre três setores delimitados por falhas rotacionadas formadas durante a orogênese Variscana, entre os continentes Gondwana e Laurásia formando o supercontinente Pangeia (ALVES et al., 2002) sendo esses os setores Norte, Sul e Central. O embasamento dessa bacia é formado por rochas Pré-Cambrianas e Paleozoicas do Maciço Iberico. O preenchimento da bacia aponta uma fase principal de espalhamento do fundo oceânico e quatro episódios de *riftiamento* entre o fim do Triássico e o Cretáceo (MARTINIUS; GOWNLAND, 2011 ; TAYLOR et al., 2014). A primeira fase rifte ocorreu no Triássico Superior, quando a região era dominada por um sistema deposicional de canais entrelaçados e leques aluviais, que evoluíram para um ambiente marinho raso, com deposição de evaporitos e dolomitos (RASMUSSEN et al., 1998). A segunda fase rifte ocorreu em Idade Sinemuriano, no Jurássico Inferior, associada à deposição de rochas carbonáticas, a sul da Falha de Nazaré (ALVES et al., 2002). O fim dessa fase é marcado por um soerguimento da bacia e pela regressão, causando um período de erosão e um hiato temporal no registro sedimentar ao longo do Calloviano (ALVES et al. 2002). A terceira fase rift teve seu início ao final do Oxfordiano (Jurássico Superior), quando a atividade tectônica atingiu seu ponto culminante, levando a uma nova subsidência que subdividiu a bacia em diversas outras sub-bacias (ALVES et al. 2002; TAYLOR et al. 2014). Nessa fase houve um aumento no aporte de sedimentos detríticos, que se depositaram em ambiente fluvio-marinho na Formação Alcobaça e

predominantemente fluviais na Formação Lourinhã (ALVES et al., 2002; RASMUSSEN et al. 1998). A quarta fase rift ocorreu no Cretáceo Inferior, na qual houve um novo fluxo de sedimentos na porção central da bacia e o soerguimento das porções costeiras (ALVES et al., 2002). Por fim, as orogêneses Pireneana e Alpina durante o Cenozoico controlaram a evolução do oeste da Ibéria, causando a inversão da bacia (ALVES et al., 2002) (Fig. 3).

Figura 2: Mapa do Arcabouço estrutural das sub-bacias da porção oeste e central da Bacia Lusitânica

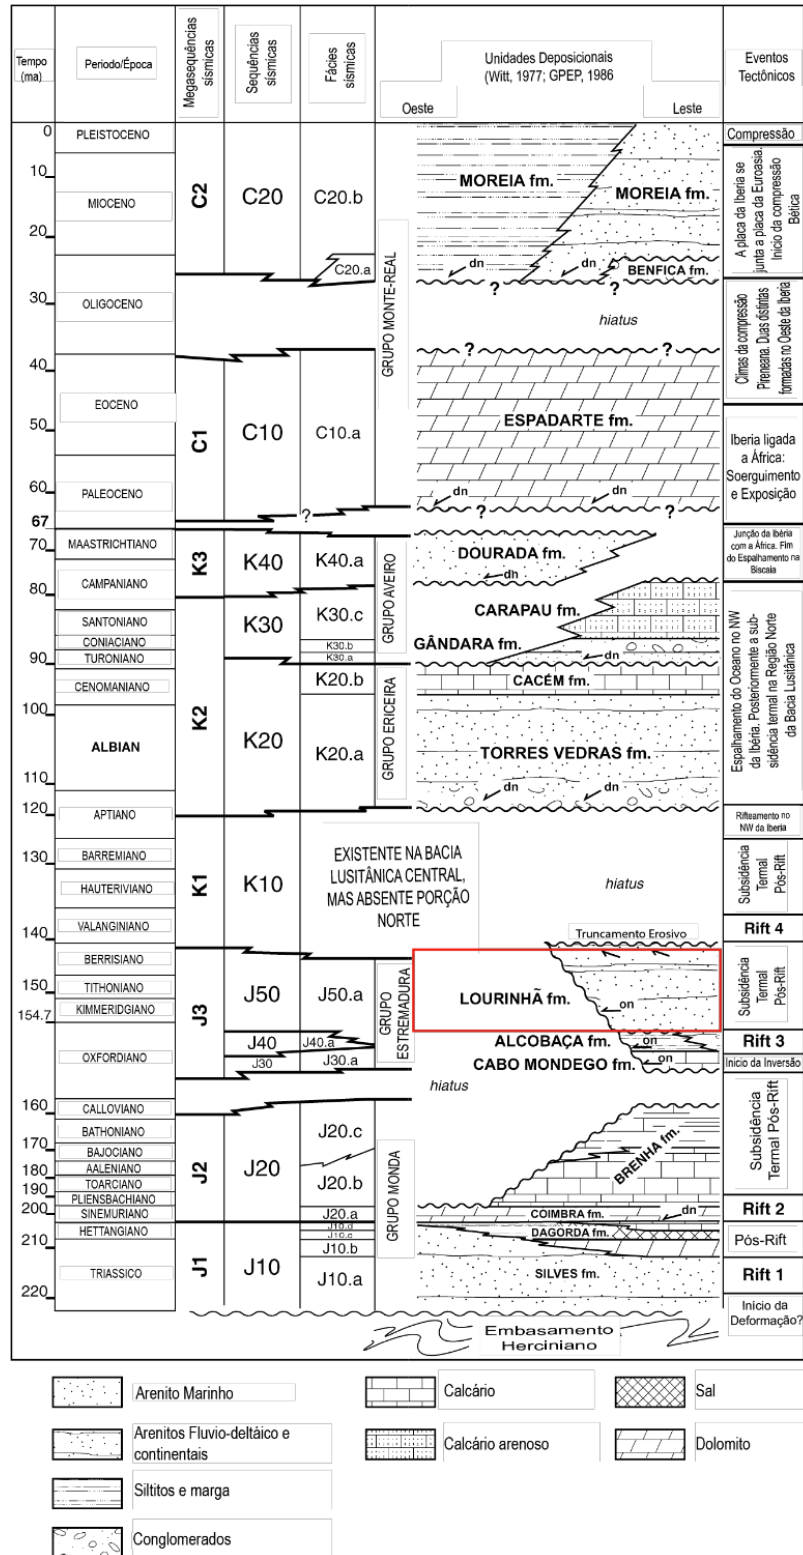


Fonte: Modificado de Taylor et al. 2004

## ii. Geologia Local


Este trabalho irá trabalhar com um afloramento inserido na formação Lourinhã, na Sub-Bacia de Consolação. Esta formação apresenta uma sucessão de sedimentos siliciclásticos que se depositaram entre o Kimmeridgiano ao Berriasiano (TAYLOR et al., 2014). A espessura de sedimentos varia entre 200 e 1100 metros, depositados principalmente em ambiente marinho raso e fluvial. A Formação Lourinhã está subdividida, da base para o topo, nos Membros São Bernardino, Porto de Barças, Areia Branca e Ferrel. O Membro São Bernardino possui espessura de aproximadamente 340 metros, com depósitos de canais fluviais intercalados com lamas de planície de inundação (TAYLOR et al., 2014). Os canais desta formação são interpretados principalmente como de rios meandrantos, com barras de pontal bem preservadas. O membro do Porto de Barças tem espessura de aproximadamente 110 metros. Esse membro é caracterizado pela presença de três concheiros, lateralmente rastreáveis, depositados em lamas associadas a planícies de inundação. O Membro Areia Branca apresenta entre 123m e 167 metros de espessura. Esse membro compreende depósitos subaéreos de planícies costeiras, com diversos canais fluviais de rios meandrantos e planícies de inundação. Por fim, o Membro Ferrel, tem uma espessura de pelo menos 75m com áreas que podem passar os 200 metros, possuindo uma alta razão de areia. Este membro corresponde a depósitos de canais fluviais, com granulometria grossa e geometria do tipo lençol, refletindo canais fluviais entrelaçados. (TAYLOR et al., 2014). A figura 4 e 5 (Fig 4 e 5) representam a coluna estratigráfica da bacia toda e o ortofotomosaico ilustrando a geologia do afloramento em questão que foi estudado e aplicada as técnicas deste trabalho.

Figura 3: Coluna estratigráfica apresentando a Bacia Lusitânica com destaque em vermelho para a formação Lourinha.



Fonte: Extraído de Taylor (2018)

Figura 4: Ortofotomosaico da formação Lourinha apresentando a coluna estratigráfica e a sequência de eventos elaborada por Magalhães et al submetido.



Fonte: Magalhães et al submetido

## **4. REVISÃO BIBLIOGRÁFICA**

Este trabalho envolve a interface entre disciplinas de fotografia, sensoriamento remoto, visão computacional e aprendizagem de máquina. A metodologia que será aplicada para a rotulação se baseia em algoritmos de visão computacional, que estão gradualmente sendo aplicados nas Geociências. (PIRES DE LIMA et al. 2020).

### **4.1 Sensoriamento Remoto**

O sensoriamento remoto é definido como obtenção de informações de uma área objeto ou fenômeno sem o contato direto com ele (COELHO & BRITO, 2007; HANSEN et al 2019.). A aquisição desses dados pode ser realizada por sensores embarcados em satélites, veículos tripulados ou não tripulados RPAS. Os sensores remotos registram sinais referentes às propriedades físicas do objeto na superfície terrestre e a partir dessas informações geram imagens. Estes sensores remotos são divididos entre passivos e ativos, o primeiro corresponde a imagens que registram sinais referentes às propriedades físicas do objeto, sem qualquer emissão de energia externa. Já os sensores ativos carregam uma fonte de energia que é emitida sobre o alvo, e posteriormente a energia refletida por ele é analisada. A câmera fotográfica é considerada o primeiro sensor remoto de obtenção e com os avanços tecnológicos várias técnicas foram sendo desenvolvidas dentre elas a aerofotogrametria será a utilizada neste trabalho.

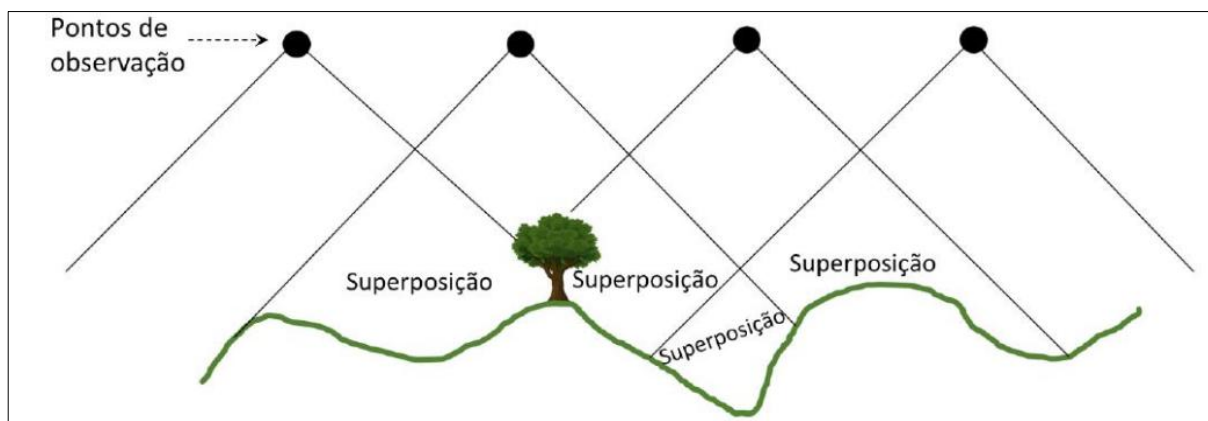
#### **4.1.1 Fotogrametria**

A fotogrametria é uma técnica onde são executadas medições através de fotografias (do grego: *photon* [luz], *graphos* [escrita] e *metron* [medições]). A fotogrametria está inserida no contexto global do sensoriamento remoto, e pode ser definida como ciência e tecnologia de aquisição de informação sobre um objeto sem contato direto entre este e o sensor. (HANSEN, et al 2019. COELHO & BRITO 2007). Dentre os objetivos da fotogrametria podemos citar alguns como reduzir o trabalho de campo no levantamento de coordenadas e altitudes de um ou vários objetos, reduzir o tempo de obtenção e coleta de dados, reduzir os riscos de obter esses dados, aumentar o número de dados obtidos por tempo, etc., porém, o principal objetivo da fotogrametria pode ser descrito como a visualização de um



espaço tridimensional a partir de um conjunto de imagens bidimensionais (COELHO & BRITO 2007, CARRIVICK et al.,2016). Isto só é possível graças ao fenômeno da paralaxe estereoscópica, que permite uma visão 3D em fotografias com até 60% de sobreposição. A paralaxe estereoscópica é como o deslocamento aparente na posição de um objeto, em relação a um ponto de referência, causado pela mudança na posição de observação (COELHO & BRITO 2007). Com o avanço da tecnologia, novas técnicas foram alcançadas e com isso o surgimento da aerofotogrametria digital surgiu nos anos 80, tendo como grande inovação a utilização de imagens digitais como fonte primária de dados. Mas apenas nos anos 90 esse ramo da fotogrametria realmente pôde ser usado de maneira ampla com o desenvolvimento softwares e hardwares com capacidade suficiente para o processamento de imagens digitais (COELHO & BRITO, 2007; CARRIVICK et al.,2016). A fotogrametria digital preocupa-se em automatizar a fotogrametria, possibilitando o rápido processamento do montante de dados que surgem em consequência desses processos. Atualmente, pode-se dizer que o estado-da-arte em fotogrametria digital é o mapeamento semiautomático, ou seja, os processos implementados tentam ser automáticos, mas ainda exigem a supervisão e eventual intervenção humana nos mesmos (COELHO & BRITO, 2007, GONÇALVES, .KUMAIRA, .GUADAGNIN, 2017). Um esquema simplificado de como funciona a técnica da aerofotogrametria pode ser ilustrado na Figura 5 onde temos e a área de superposição que é afetada conforme o ponto de observação se desloca no esquema.

Figura 5: Ilustração de como funciona a superposição de imagens.



Fonte: Extraído de Beretta et. al., (2018).

#### 4.1.2 Structure From Motion


De acordo com Carrivick et al (2016) a *Structure from Motion* (SfM) ou *Structure from Motion - Multi View Stereo* (SfM-MVS) não é uma técnica ou ferramenta isolada em si, mas sim um fluxo de trabalho seguido por etapas bem definidas que utiliza de múltiplas imagens sobrepostas de um objeto ou superfície, obtidas por meio de uma câmera fotográfica a partir de vários pontos de vistas para reconstruir a geometria 3D do objeto ou superfície. A geometria, as posições e a orientação da câmera são recuperadas simultaneamente pelo (SfM-VMS). Para isso se faz necessário um conjunto de fotografias com alto grau de sobreposição que capturem a tridimensionalidade do objeto de interesse, sendo este visto de uma série de posições e aspectos circundantes, ou seja imagens derivadas de um sensor de movimento (CARRIVICK et al 2016, GONÇALVES, .KUMAIRA, .GUADAGNIN, 2017). Em contraponto da fotogrametria tradicional, o SfM utiliza algoritmos para identificação de recursos equivalentes em um grupo de imagens digitais sobrepostas (CARRIVICK et al 2016). O método SfM baseia-se na detecção e descrição de características comuns ou texturas em imagens sobrepostas. Depois da detecção dos recursos correspondentes, eles recebem coordenadas 3D e, gradativamente, o software constrói automaticamente uma rede de pontos equivalentes ou de ligação. Depois da confecção da rede de pontos unindo os pontos com as coordenadas 3D, uma nuvem densa é gerada preenchendo os espaços entre os pontos de ligação, utilizando um algoritmo Multi View Stereo. Este algoritmo age procurando as redes de pixels nas imagens, separando as melhores correspondentes gerando pontos no

espaço tridimensional. A exatidão atingível estimada das coordenadas dos pontos estimados pelo SfM é moderada pelos seguintes parâmetros: (1) número de imagens sobrepostas nas quais a característica de interesse aparece; (2) distância média da câmera ao alvo; (3) distância entre centros de câmara em relação ao objeto de interesse, isto é, o ângulo de convergência da imagem na cena; (4) distância principal da câmera, uma medida similar à distância focal; e (5) a precisão das medidas de imagem e parâmetros de reconstrução (CAWOOD et al., 2017).

#### **4.1.3 MVA Modelo Virtual de Afloramento**

MVAs são representações digitais de uma superfície topográfica, em um ambiente virtual tridimensional (TAVANI et al., 2014). Eles podem ser mostrados de duas formas: nuvem de pontos ou malhas tridimensionais texturizadas. Com o surgimento da metodologia *Structure from Motion* SfM a construção de modelos digitais tridimensionais 3D tornaram-se democratizados em conta de apresentar custos mais baixos, menor tempo de processamento quando comparadas a técnicas conhecidas como o LIDAR, além de não requisitar conhecimento especializado em processamento por parte do usuário para a construção do MVA (CARRIVICK et al., 2016). Esta metodologia, fornece a capacidade de usar imagens digitais sobrepostas de uma superfície ou objeto de interesse por meio do fenômeno de paralaxe, desta forma gerando semiautomaticamente um modelo 3D. Atualmente a construção de MVA utilizando RPAS com o auxílio de algoritmos de AM visando a minimização de erros de identificação e classificação gerado pelo viés humano pode ser considerado o atual estado da arte (BERETTA et al 2017; BERETTA et al 2018; FLACH, 2012; GONÇALVES, .KUMAIRA, .GUADAGNIN, 2017). A figura 6 (Fig. 6) representa graficamente os parâmetros envolvidos na visualização estereoscópica. Considerando um objeto P fotografado de duas câmeras (C1 e C2). A posição de P, nas duas fotos vai depender dos parâmetros da câmera (distância focal) e a sua orientação.

Figura 6: A figura representa graficamente os parâmetros envolvidos na visualização estereoscópica. Considerando um objeto P fotografado de duas câmeras (C1 e C2). A posição de P, nas duas fotos vai depender dos parâmetros da câmera (distância focal) e a sua orientação



Fonte: Modificado de Tavani et al (2014)

## 4.2. Aprendizagem de Máquina

A Aprendizagem de Máquina (AP) é uma área da inteligência artificial (IA) onde a máquina tem a capacidade de aprender com as respostas esperadas por meio de associações de diferentes dados, ou seja, a aprendizagem de máquina envolve o reconhecimento de padrões em um conjunto de dados estes podendo ser imagens, números ou qualquer informação que possa ser identificada. Dentre os principais métodos encontram-se os supervisionados e não supervisionados. Os métodos supervisionados trabalham a partir de um rótulo ou classificação, isto é, se faz necessário uma pessoa ou sistema para identificação e classificação, rotulando os dados e os dispondo em forma de tabela ou planilha, desta forma auxiliando a inteligência artificial (IA) em seu processo de aprendizagem contínua. Já os métodos não supervisionados buscam detectar padrões em um conjunto de dados não rotulados (FLACH, 2012). Na AP supervisionado, um conjunto abrangente de exemplos de 'dados de treinamento' é construído cobrindo o máximo de espaço de parâmetros do sistema possível. Normalmente, um subconjunto aleatório dos dados é separado para uma validação completamente independente. Nas técnicas atuais, a porcentagem de separação de conjuntos e subconjuntos fica em torno de 70/30, isto é, 70% do banco de dados é utilizado para treinamento do algoritmo enquanto

os 30% restantes são utilizados para validação e previsão. Existem muitos algoritmos de aprendizado de máquina, cada um projetado para analisar dados com características diferentes (WITTEN e FRANK, 2005; HASTIE et al., 2009) Eles podem ser mais simples, exigindo custos computacionais, mais baixos, ou mais complexos, exigindo computação de alto desempenho Rubo (2019).

#### 4.2.1. CNN e U-NET

Redes neurais artificiais são modelos matemáticos baseados na estrutura neural de organismos inteligentes, especificamente, do cérebro humano (HASTIE et al.,2009;). Sua principal qualidade está na capacidade de aprendizagem, generalização e abstração que obtém por meio da busca de relações, construção automática de modelos e correção com base em experiências passadas a fim de reduzir o seu próprio erro. A concepção de neurônio artificial foi utilizada pela primeira vez por (MCCULLOCH e PITTS 1943). O nome "rede neural convolucional" indica que a rede emprega uma operação matemática chamada "convolução". A convolução é um tipo especializado de operação linear. As redes convolucionais são simplesmente redes neurais que utilizam a convolução em vez da multiplicação geral da matriz em pelo menos uma das suas camadas como pode se observar na equação. Na sua forma mais geral, a convolução é uma operação sobre duas funções de um argumento de valor real (RUBO 2019).

Segundo (RUBO 2019) o objetivo de aplicar convoluções em uma imagem é extrair características por meio de operações matemáticas entre funções representadas pela equação (Fig. 7) .

Figura 7: Equação representando convolução de imagens onde  $f(x)$  = imagem  $h(x)$  = filtro  $x$  = coordenada espacial (posições dos pixels)  $g(x)$  = resultado ou imagem convolvida.


$$g(x) = f(x) * h(x) = \int_{-\infty}^{\infty} f(s)h(x - s)ds$$

Fonte: Rubo 2019

As operações convolucionais também podem ser expressas através de matrizes, com a imagem original e o filtro representados em forma de matriz. No

caso de uma imagem contendo os canais R, (red) G (green) e B (blue), esta multiplicação é feita em blocos, sendo um bloco por canal. O filtro pode ser tanto pré-definido como aprendido ao longo do treinamento de um modelo. A aplicação de diversos filtros é capaz de extrair informações de uma imagem, destacando diferentes características como feições e bordas e as relações entre os pixels vizinhos (KHAN et al., 2018; RUBO, 2019).

Figura 8: Esquema ilustrando como funciona uma convolução em uma imagem.




Fonte: o autor.

Uma Rede Neural Convolutiva (CNN) é um algoritmo de Aprendizado Profundo que pode captar uma imagem de entrada, atribuir importância (pesos e vieses que podem ser aprendidos) a vários aspectos /objetos da imagem e ser capaz de diferenciar um do outro. Enquanto nos métodos de aprendizagem não profunda os filtros são feitos à mão, com treinamento suficiente, as CNN têm a capacidade de aprender esses filtros/características. A arquitetura de uma CNN é análoga àquela do padrão de conectividade de neurônios no cérebro humano e foi inspirada na organização do Visual Cortex. Os neurônios individuais respondem a estímulos apenas em uma região restrita do campo visual conhecida como Campo Receptivo. Uma coleção desses campos se sobrepõe para cobrir toda a área visual. Em contrapartida a U-Net é uma baseada em uma rede totalmente convolutiva pois sua arquitetura é modificada e estendida para trabalhar com menos imagens de treinamento e gerar segmentações mais precisas. Explicando de maneira simples, na U-NET a cada nível que descemos diminuímos o tamanho da imagem de forma que cada camada posterior vai analisando uma área maior correspondente da imagem original, ou seja, cada pixel fica correspondente a uma área maior para analisar. Em seguida quando voltamos com o processo inverso, cada pixel agora terá um valor de probabilidade desta forma tendo uma maior precisão na

identificação de cada ponto da imagem como é possível observar na figura 8 (Fig. 8).

Figura 9: Ilustração da arquitetura de uma U-NET.



Fonte: <[https://nchlis.github.io/2019\\_10\\_30/page.html](https://nchlis.github.io/2019_10_30/page.html)>

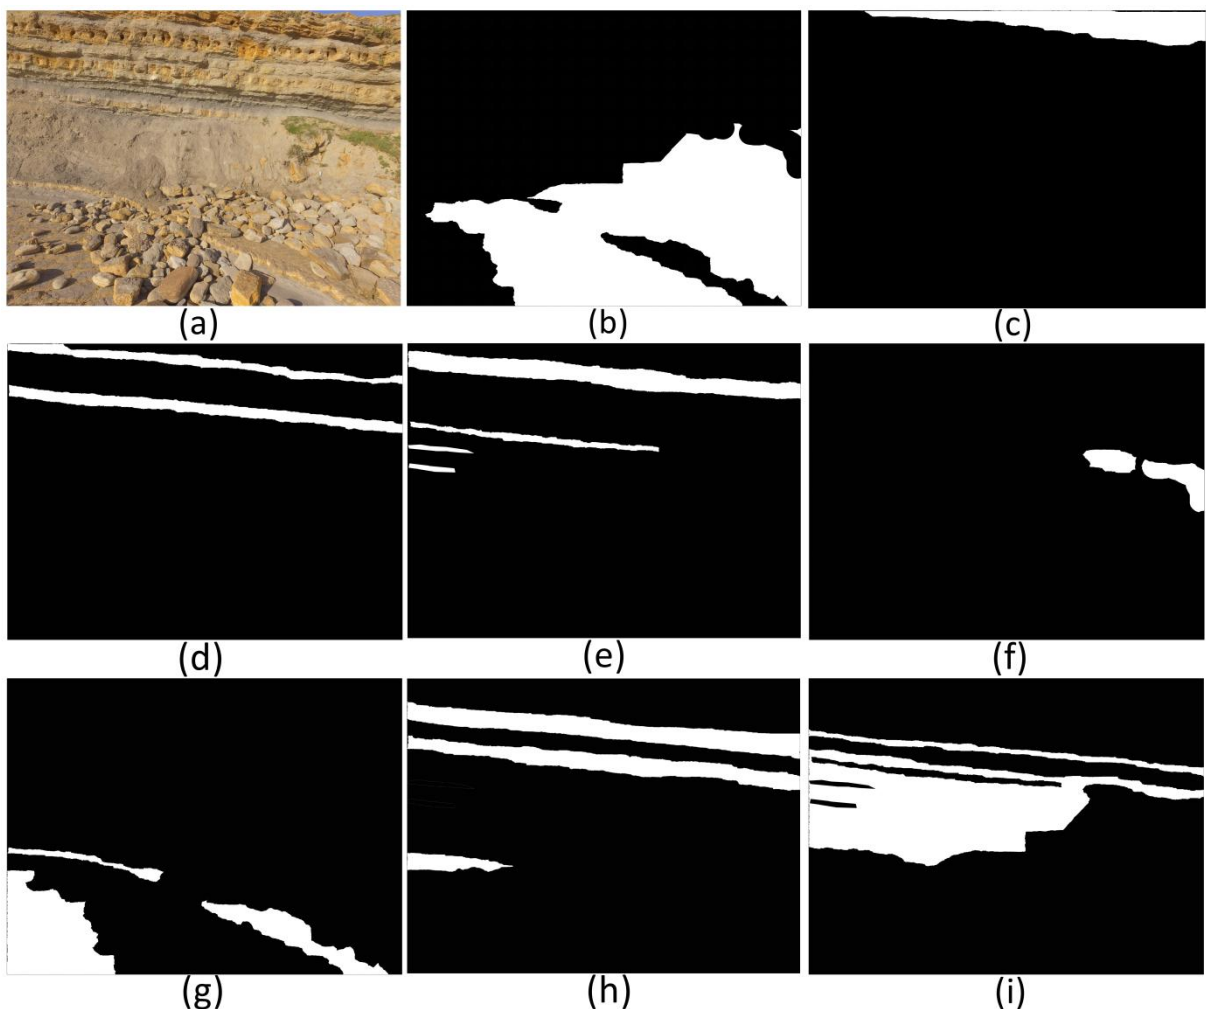
## 5. MATERIAIS E MÉTODOS

### 5.1. Banco de Dados

As imagens aéreas foram coletadas utilizando uma RPAS da marca DJI modelo Phantom IV, este modelo possui câmera acoplada, com sensores do tipo Complementary Metal-Oxide Semiconductor (CMOS), de cerca de 11 mm, o que permite fotos em uma resolução de 12 megapixels (4000 x 3000) e tamanho de pixel de 1.55 x 1.55  $\mu\text{m}$ . Possui lentes de 20 mm, equivalentes ao formato 35mm, distância focal de 3,61mm e um campo de visão de 94° (KROTH 2018). As imagens foram cedidas pelo professor Dr Guadagnin, e as correlações entre as imagens 2D originais e os MVA com as litofácies foram realizadas em campo pela análise faciológica por Magalhães et al. (submetido). Posteriormente, as imagens 2D foram rotuladas por estagiários do Laboratório de Modelagem Geológica (MARINS 2018, COSTA 2018 e NEVES 2018). As imagens estão no formato jpg, possuem a resolução de 3000x4000 pixels, tendo em média 5MB de tamanho cada. O banco de dados conta com 112 fotos no total. Foram realizadas 728 'máscaras' no total, tendo uma média de 8 máscaras para cada imagem sendo que delas 7 para a litologia (boundstones, rudstones, packstones conglomerados, siltitos laminados, siltitos maciços e arenitos) e 1 uma máscara para uma categoria extra denominada como "outros", que contempla céu vegetação e material desagregado. Desta forma quando

os filtros foram aplicados, as máscaras serão inseridas juntamente assim buscando uma assinatura da imagem de cada litologia separadamente. Também foi utilizada a *Scikit-Learn*, uma biblioteca de aprendizado de máquina online de código aberto para programação em python para trabalhar com AM e o *GitHub*, uma plataforma de hospedagem de código fonte e arquivos com controle de versão usando o Git. Conforme podemos observar no exemplo da figura 9 (Fig. 9) DJI824, na imagem (a) temos a foto de um afloramento total, em (b) temos a máscara para o sedimento inconsolidado, em (c) e (g) temos os arenitos, em (d) (e) e (h) temos siltitos laminados, em (f) temos vegetação e em (i) temos packstones.

Figura 10: Mosaico ilustrando foto do afloramento e máscaras aplicadas para cada litologia separadamente.



Fonte: Modificado de Marins 2018 Costa 2018 e Neves 2018



## 5.2. Google colab e Python

Foi utilizada a plataforma *Google Colaboratory*, esta plataforma é um ambiente onde é possível a criação de um notebook, ou seja, um espaço virtual em que é possível realizar o upload das informações diretamente do drive e processá-las. A linguagem computacional escolhida para a realização deste trabalho foi a Python, por ser uma linguagem *open source* de alto nível de propósito geral, bastante utilizada em *data science* e AP, sendo eficiente para fazer protótipos, altamente escalável e moldável.

## 5.3. *TensorFlow*

Segundo (ABADI et al 2015) o *TensorFlow* é uma biblioteca de software para cálculos numéricos de código aberto especialmente adequada e ajustada para o aprendizado de máquina em larga escala. Cálculos no *TensorFlow* são expressos como grafos de fluxo de dados mantendo um estado. O nome *TensorFlow* deriva das operações que tais redes neurais realizam em arranjos de dados multidimensionais. Estas matrizes são chamadas de "tensores".

## 6. RESULTADOS E DISCUSSÃO

Como resultado deste trabalho foi elaborado uma tabela com os percentuais alcançados para cada configuração utilizada durante as convoluções. Para a realização e obtenção desses resultados foi seguido o seguinte processo. Inicialmente foi reduzido a resolução das imagens para caber na memória da GPU, e considerando que cada camada da U-NET é dividida por dois, considerando que o tamanho da imagem vai sendo dividido por 2, é necessário que o tamanho da camada anterior seja par. Durante este processo foram variados os seguintes parâmetros: percentual de *dropout*, que envolve apagar aleatoriamente um certo percentual dos pixels de forma a estimular o modelo a descobrir redundâncias a fim de se obter um modelo mais robusto; o número de canais, este parâmetro melhora a precisão dos resultados, desde que haja imagens suficientes para isso. Possui o contra de aumentar o custo computacional exigindo mais memória da GPU; o número de blocos, esse parâmetro interfere no número de níveis ou o quão profunda a rede U-NET. Não foi possível a realização de convoluções utilizando *dropout*

maiores que 0.4 (40%) e mais do que 32 canais por motivo de alcançar o limite da GPU gratuita ofertada pela plataforma Colab. Após encontrado um modelo ideal este com a configuração de 32 canais, 4 blocos e um percentual de *dropout* de 0.2 ou 20% foram alterados o número de fotos utilizadas para o treinamento da U-NET com objetivo de alcançar um melhor resultado nas predições. O banco de dados contava com o total de 112 imagens e no início foi ofertada para U-NET 28 imagens para treino, depois 37 e em seguida 56. Como resultado teve-se uma melhora esperada na precisão das imagens, porém o ganho para o aumento não foi muito maior, cerca de 2% a mais (86%, 88%, 90% respectivamente) indicando uma melhora no detalhamento da imagem. Pode ser possível obter um desempenho melhor com um número diferente de épocas de treinamento, tanto maior como menor. O fenômeno de overfitting (sobre treinamento) não foi avaliado neste caso.

Tabela 1: Acurácia alcançada com os modelos

	Configuração Ideal	Número de Imagens		
		28	37	56
Canais	32	86%	88%	90%
Blocos	4			
Dropout	0,2			

Figura 11: exemplo de classificação para imagens do banco de dados de treino e de teste.

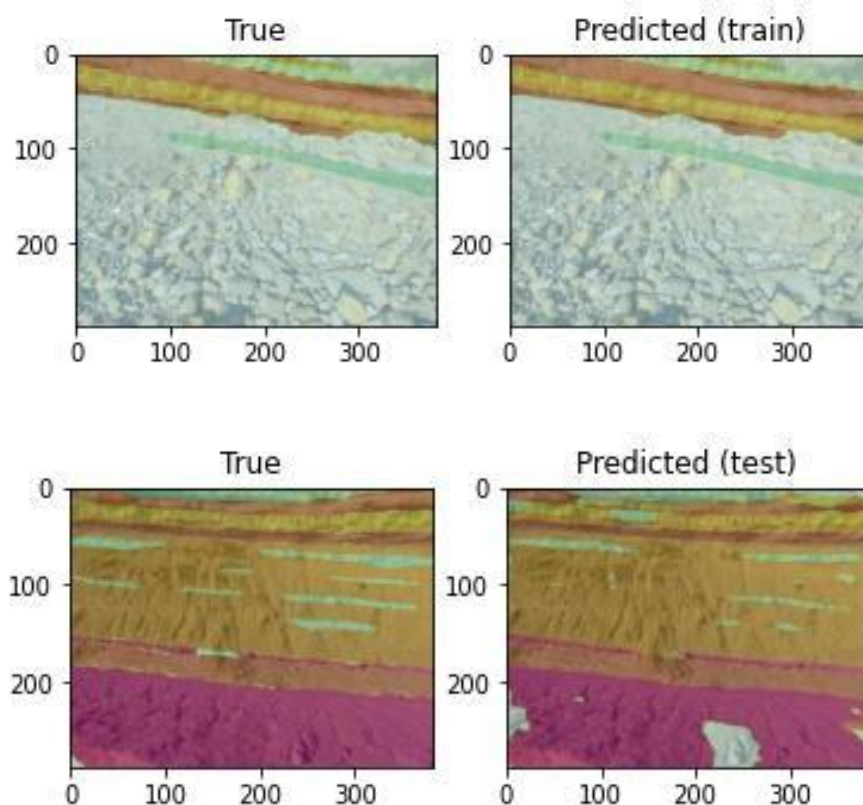



Figura 12: Foto real mostrando a separação das litologias pelas máscaras e seu grau de precisão.



Fonte: autor

## 7. CONCLUSÃO

Observando os resultados pode-se concluir que a técnica utilizada durante esse trabalho foi promissora alcançando os resultados propostos inicialmente. Mesmo não possuindo acurácia semelhante a um profissional, já é possível economizar tempo no processo partindo de uma imagem pré interpretada. Alguns fatores interessantes foram observados, como quando comparado a variação de assertividade versus a quantidade de fotos utilizadas em cada convolução, o resultado varia entre (86%-88%-90%). Observando as imagens do mesmo ponto vemos que a maior dificuldade está na distinção de detalhes nas litologias principalmente entre seus contatos quando esses são muito difusos ou quando temos camadas muito finas. Esse efeito provavelmente ocorre devido a resolução das imagens estarem muito baixas e provavelmente ter alcançado o limite de precisão dentro desta resolução. Sugere-se para trabalhos futuros a utilização de maior resolução nas imagens e a possibilidade de trabalho com a plataforma *Colab*

de maneira paga, assim aumentando o limite de memória disponibilizada para os cálculos com a GPU. Também sugere-se realizar técnicas de validação do banco de dados, e avaliar o número ideal de épocas de treinamento.

## 8. REFERÊNCIAS

ABADI, M *et al.* **TensorFlow: Large-scale machine learning on heterogeneous systems**. 2. ed. Arxiv. 2016.

ABBUD, V. T.; PERONI, R. L. **Mapeamento e modelagem de terreno com uso de VANTs em áreas de mineração**. SIC - XXIX Salão de iniciação científica da UFRGS DE INICIAÇÃO CIENTÍFICA DA UFRGS, LPM - Departamento de Engenharia de Minas. Porto Alegre. 2017.

AGISOFT LLC. **Agisoft PhotoScan User Manual Professional Edition**. 1.4. ed. 127 p. St. Petersburg, Rússia. 2018.

ALVES, T. M. *et al.* **Jurassic tectono-sedimentary evolution of the Northern Lusitanian Basin (offshore Portugal)**. Marine and Petroleum Geology, 19. ed. p. 727-754. Alfragide, PT. Elsevier, 2002.

ATKINSON, P. M.; TATNALL, A. R. L. **Introduction Neural networks in remote sensing**. 18. ed. International Journal of Remote Sensing, 699-709. Londres. Taylor & Francis. 1997.

ARAYA-POLO, *et al.* **Automated fault detection without seismic processing**. Special Section: Data analytics and machine learning, 36(3). ed. p. 208-214. The Leading Edge, 2017.

BERETTA, F. *et al.* **Uso De Vant Para Automatização De Classificação Litológica Em Frente De Lavra A Céu Aberto**. Congresso Brasileiro de Minas a Céu Aberto e Minas Subterrâneas 9. Belo Horizonte, 2018.

BIHANI, A. *et al.* (2022). **MudrockNet: Semantic segmentation of mudrock SEM images through deep learning**. 158. ed. Computers and Geosciences. Austin. Elsevier. 2022.

BREIMAN, L. *et al.* **Classification and Regression Trees**. 1rd ed. Nova York. Routledge. 1984.

CARPENTER, G. A. *et al.* **ART Neural Networks for Remote Sensing: Vegetation Classification from Landsat TM and Terrain Data**. 35. ed. Boston. IEEE. 1997.

CARRIVICK, J. L.; SMITH, M. W.; QUINCEY, D. J. **Structure from Motion in the Geosciences**. 1rd ed. Londres. John Wiley & Sons. 2016.

CAWOOD, A. J. *et al.* **LiDAR, UAV or compass-clinometer? Accuracy, coverage and the effects on structural models**. 98 ed. P67-82. Aberdeen. Journal of Structural Geology. 2017.

BRITO, J. L. N. S.; COELHO FILHO, L. C. T. **Fotogrametria digital**. 1ª Ed. Rio de Janeiro. EdUERJ, 2007

COLOMINA, I.; MOLINA, P. **Unmanned aerial system for photogrammetry and remote sensing: a review**, ISPRS Journal of Photogrammetry and Remote Sensing, v. 92, p. 79-97. Elsevier. 2014.

DI, H.; WANG, Z.; ALREGIB, G. **Real-time seismic image interpretation via deconvolutional neural network**. 1rd ed. Georgia, EUA. SEG Technical Program Expanded Abstracts 2018: Society of Exploration Geophysicists. 2018.

DORN, M., LESJAK, R., WIESER, M., **Improvement of the standard GNSS/IMU solution for UAVs using already existing redundant navigation sensors**. Anais da Conferência Europeia de Navegação (ENC), Helsinki. 2016.

DRAMSCH, J. S.; LÜTHJE, M. **Deep learning seismic facies on state-of-the-art CNN architectures, in SEG Technical Program**. SEG Technical Program Expanded Abstracts 2018. Kongens Lyngby. Society of Exploration Geophysicists, 2018.

FLACH, P. **Machine Learning: The Art and Science of Algorithms that Make Sense of Data**. 1rd ed. Cambridge. Cambridge University Press. 2012.

GONÇALVES, I. G.; KUMAIRA, S.; GUADAGNIN, F. **A machine learning approach to the potential-field method for implicit modeling of geological structures**. Ed. 107, Computers & Geosciences, p. 173–182. Caçapava do Sul. Elsevier. 2017.

HANSEN, M.A.F. *et al.* **Sensoriamento remoto e Geologia na região de Bojuru, porção média da planície costeira do RS, Brasil**. II Simpósio Brasileiro de Geologia e Geofísica Marinha (II SBGGM). Caçapava do Sul. 2019,

- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. 2009. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. 2. ed. Springer. 2019.
- HUANG, L.; DONG, X.; CLEE T. E. **A scalable deep learning platform for identifying geologic features from seismic attributes**. 36. ed. 249-256. Prairie View. The Leading Edge. 2017.
- HUGENHOLTZ, C. H. *et al.* (2013), **Geomorphological mapping with a small unmanned aircraft system (sUAS): feature detection and accuracy assessment of a photogrammetrically-derived digital terrain model**. 194. ed. Lethbridge Elsevier: Geomorphology, 16–24. 2013.
- KHAN, S., *et al.* **A Guide to Convolutional Neural Networks for Computer Vision**. 8. ed. Synthesis lectures on computer vision. Morgan & Claypool. 2018.
- KROTH, M. **Modelos virtuais de afloramento aplicados à estratigrafia de sequências e modelagem de análogos de reservatório fluvial na Bacia Lusitânica**. Trabalho de conclusão de curso. Caçapava do Sul. Universidade Federal do Pampa. 2018.
- LIMA, R. P. *et al.* **Petrographic microfacies classification with deep convolutional neural networks**. 142. ed. Computers & Geosciences. Norman, OK. Elsevier. 2020.
- LOTE, R. G. *et al.* **3D Façade Labeling over Complex Scenarios: A Case Study Using Convolutional Neural Network and Structure-From-Motion**. 10. ed. Remote sensing, 1435. São José dos Campos. MDPI. 2018.
- MAGALHÃES, A. J. *et al.* **Integrated methodological approach to identify multi-scale cycles in a clastic shelf**. O artigo foi submetido on-line com sucesso e está sendo considerado atualmente para publicação no The Depositional Record.
- MARTINIUS, A.W.; GOWNLAND, S. **Tide-influenced fluvial bedforms and tidal bore deposits (Late Jurassic Lourinhã Formation, Lusitanian Basin, Western Portugal)**. 58. ed. Sedimentology, p. 285-324. The journal of the international association of sedimentologists. 2011.

- MAUCEC, M. *et al.* **Multivariate analysis and data Mining of Well-Stimulation Data by use of classification-and-regression tree with enhanced interpretation and prediction capabilities.** 7. ed. Houston. SPE Economics and Management, 60–71. 2015.
- RASMUSSEN, E.S.; LOMHOLT, S.; ANDERSEN, C.; VEJBAEK, O.V. **Aspects of the structural evolution of the Lusitanian Basin in Portugal and the shelf and slope área offshore Portugal.** ed. 300, Tectonophysics, p. 199-225. Elsevier. 1998.
- RUBO, R. A.; CARNEIRO, C. C.; MICHELON, M. F.; GIORIA, R. S. **Digital petrography: Mineralogy and porosity identification using machine learning algorithms in petrographic thin section images.** 183. ed. Santos, SP. Elsevier. 2019.
- SABAH, M. *et al.* **A machine learning approach to predict drilling rate using petrophysical and mud logging data.** 12. ed. Earth Science Informatics, 1–21. Rasht St. Springer Nature. 2019.
- SALVINI, R. *et al.* **Use of a remotely piloted aircraft system for hazard assessment in a rocky mining area (Lucca, Italy).** 18. ed. Natural hazards and earth system sciences, p. 4409-4416. Siena. EGU General Assembly. 2018.
- SHI, Y.; WU, X.; FOMEL, S. **Automatic salt-body classification using a deep convolutional neural network.** 88. ed. SEG Technical Program Expanded Abstracts, 1971–1975. Austin. Society of Exploration Geophysicists. 2018.
- SILVA, C. *et al.* **Avaliação da acurácia do cálculo de volume de pilhas de rejeito utilizando VANT, GNSS e LiDAR.** 22. ed. Fortaleza. Boletim de Ciências Geodésicas, p. 73 – 94. 2016.
- TAVANI, S. *et al.* **Building a virtual outcrop, extracting geological information from it, and sharing the results in Google Earth via OpenPlot and Photoscan: An example from the Khaviz Anticline (Iran).** 63. ed. Computers & Geosciences, p. 44-53. Nápoles. Elsevier. 2014.



TAYLOR, A.M. *et al.* **Stratigraphical correlation of the Late Jurassic Lourinhã Formation in the Consolação Sub-basin (Lusitanian Basin), Portugal.** ed. 49, Geological Journal, p. 143,164. Northwich. Geological. 2014.

VOLLGGER, S.A., CRUDEN, A.R., AILLERES, L., COWAN, E.J. **Regional dome evolution and its control on ore-grade distribution: Insights from 3D implicit modelling of the Navachab gold deposit, Namibia.** 69. ed. Ore Geology Reviews, p.268–284. Melbourne. Elsevier. 2015.

WALDELAND, A.; SOLBERG, A. **Salt classification using deep learning.** 79th EAGE Conference & Exhibition. Oslo. European Association of Geoscientists & Engineers. 2017.

XU, Z. *et al.* **Deep learning of rock images for intelligent lithology identification.** 154. ed. Computers and Geosciences, 104799. Jinan. Elsevier. 2021.

YI, J.; PRYBUTOK, V. R. **A neural network model forecasting for prediction of daily maximum ozone concentration in an industrialized urban area.** 92. ed. Denton. Elsevier. 1996.