

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS  
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO  
DOUTORADO EM GEOLOGIA**

**Rita Fabiane Guasina de Oliveira**

**Caracterização de petrofácies e genese das rochas carbonáticas do reservatório Sapinhoá (Pré-sal, Bacia de Santos) e aplicação de aprendizagem de máquina por meio de microscopia óptica e imagens digitais a partir de atributos permo-porosos.**

**Orientador: Prof. Dr. Farid Chemale Jr.**

**Co-orientador: Prof. Dr. Sandro José Rigo**

**São Leopoldo**

**2024**

**Rita Fabiane Guasina de Oliveira**

Caracterização de petrofácies e genese das rochas carbonáticas do reservatório Sapinhoá (Pré-sal, Bacia de Santos) e aplicação de apredizagem de máquina por meio de microscopia óptica e imagens digitais a partir de atributos permo-porosos.

Tese de Doutorado apresentada como requisito para obtenção do título de doutor em Geologia, pelo Programa de Pós-graduação em Geologia da Universidade do Vale do Rio dos Sinos – UNISINOS

Orientador: Dr. Farid Chemale Jr.

Co-orientador: Dr. Sandro José Rigo

Banca Examinadora:

Profa. Dra. Joice Cagliari (UNISINOS)

Dra. Rosalia Barili da Cunha (IPR/PUC-RS)

Dra. Marcelle Marques Erthal (PETROBRAS/CENPES)

**São Leopoldo**

**2024**

O48c Oliveira, Rita Fabiane Guasina de  
Caracterização de petrofácies e genese das rochas carbonáticas do reservatório Sapinhoá (Pré-sal, Bacia de Santos) e aplicação de aprendizagem de máquina por meio de microscopia óptica e imagens digitais a partir de atributos permo-porosos / por Rita Fabiane Guasina de Oliveira. – 2024. 181 f. : il.; 30 cm.

Tese (doutorado) — Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Geologia, 2024.

Orientador: Dr. Farid Chemale Jr ; Co-orientador: Dr. Sandro José Rigo.

1. Aprendizado de máquina. 2. Porosidade e permeabilidade. 3. Atributos permo-porosos. 4. Microscopia óptica convencional. 5. Imagens digitais. I. Título.

CDU 552

Catálogo na Fonte:

Bibliotecária Vanessa Borges Nunes - CRB 10/1556

*“Nunca tenha certeza de nada. A sabedoria começa com a dúvida.”*

*Freud*

*Dedico esta tese à minha família, Guilherme, Pedro e Clara.*

## AGRADECIMENTOS

Agradeço à Universidade do Vale do Rio dos Sinos e ao Curso de Pós-Graduação em Geologia.

Ao Prof. Dr. Farid Chemale Jr. pela orientação e a oportunidade de desenvolver esta pesquisa.

Ao Prof. Dr. Sandro José Rigo pela orientação e por ter acreditado no desenvolvimento na proposta.

As doutoras Marcelle Marques Erthal, Rosalia Barili da Cunha e Joice Cagliari que destinaram seu tempo para a leitura desta tese e participação na banca de defesa.

A Petrobras pela disponibilidade do uso dos dados e a Capes pela concessão da bolsa de doutorado.

Ao Itt Oceaneon e ao Dr. Gerson Fauth pelo uso do MEV e pelo auxílio.

Aos parceiros de trabalhos Bach. C. Comp. Augusto Pasini, Dra. Karin Goldberg, Dra. Ariane Santos da Silveira, MSc. Mat. Luciano Garim e PhD. Fís. Carine Beatrici pela parceria de trabalho e contribuições.

Ao professor Dr. Victor Hugo Valiati pelas discussões e aos professores Dr. Paulo Sérgio Gomes Paim, Dra. Renata Guimarães Netto, Dr. Ernesto Lavina, Dr. Francisco Manoel Tognoli, Dr. Karlos Guilherme Diemer Kochhann pelas aulas ministradas. Ao Dr. Marcelo Kehl de Souza, Dr. Thiago Santi Bressan e Dr. Gabriel de Oliveira Ramos por fazerem parte das bancas de Qualificação e Seminário II. A Patrícia Krüger Pescke, secretária do curso de pós-graduação, pelo apoio.

Aos colegas de pós-graduação que participaram da minha trajetória durante estes anos e aos alunos de graduação Bruna Poatskievick Pierezan, Letícia Mallmann, Lucas Vinicius Oliveira, pelo auxílio.

Aos colegas do Núcleo de Excelência em Modelagem Geológica e Numérica (MGEM) pelo apoio, discussões e companheirismo.

Aos amigos Geól. Mateus Simionato, MSc. Marina L. J. Martins e Geól. Monique Bordignon Chiele, pelas infindáveis conversas geocientíficas.

Aos professores Dr. Luiz Fernando de Ros, Dr. Rogério Schiffer de Souza e MSc. Adali Spadini pelo conhecimento transmitido sobre o universo dos carbonatos.

Ao meu pai Fernando e a minha mãe Miguelina (*in memoriam*) que me ensinaram a nunca desistir e sempre que necessário recomeçar.

## RESUMO

A presente tese de doutorado tem como tema principal a caracterização de reservatórios carbonáticos do pré-sal e o desenvolvimento de uma abordagem inovadora para a predição de porosidade e permeabilidade destas rochas sem a necessidade de dados geofísicos, utilizando para isto a aprendizagem de máquina. O estudo foi dividido em três manuscritos, como segue: (I) *Petrography and Genesis of Carbonate Rocks from the Barra Velha Formation (Santos Basin, Brazil) and Associated Biogenic Structures*, (II) *Prediction of Porosity and Permeability of Carbonate Rocks Using Thin Section Data and Machine Learning Methods: A Systematic Review* e (III) *Prediction of Carbonate Rocks Poroperm Properties Using Convolutional Neural Networks*. As técnicas envolveram revisão bibliográfica conceitual e aquelas utilizadas em aprendizagem de máquina, petrografia óptica de rochas carbonáticas e redes neurais convolucionais. Na primeira parte, foram descritas petrograficamente 565 lâminas delgadas de rochas do pré-sal, obtidas de três poços localizados na Bacia de Santos, as quais foram utilizadas para identificar as principais fácies carbonáticas, definir sua gênese e adquirir o *dataset* utilizado no treinamento da rede neural. Na segunda parte, realizou-se uma revisão bibliográfica sistemática das principais técnicas utilizadas em aprendizagem de máquina com aplicação daquele *dataset* obtido na fase anterior deste estudo. O objetivo central foi obter a predição da porosidade e a permeabilidade. Por fim, na terceira parte, desenvolveu-se o treinamento e a predição da porosidade e da permeabilidade de rochas carbonáticas do pré-sal com uso do mesmo *dataset* da primeira parte. A petrografia óptica permitiu identificar as diferentes fácies carbonáticas que compõe as rochas do pré-sal, bem como as características texturais, a

mineralogia e o percentual de vazios do arcabouço da rocha, os quais constituem parte dos atributos permo-porosos que compuseram o *dataset* de treinamento. Ainda, pode-se tecer considerações sobre a gênese do pré-sal que contribuiu para avaliação da complexidade destes depósitos expressivos de óleo e gás. Por sua vez, a análise bibliográfica sistemática contribuiu para conhecer as técnicas mais usadas para o *dataset* gerado. Por fim, a fase de treinamento possibilitou que fosse desenvolvida uma arquitetura específica para o *dataset* gerado e para a finalidade de se predizer as porosidades e as permeabilidades de rochas do pré-sal sem que fosse necessário o uso de dados geofísicos complementares. A integração dos dados gerados na fase de petrografia óptica auxiliou na aquisição e seleção do *dataset* usado no treinamento bem como na análise dos dados obtidos durante o processo preditivo, tratamento e seleção do *dataset* de imagens. Além disso, a investigação de evidências hidrotermais e biogênicas fornece *insights* valiosos sobre gênese das fácies carbonáticas e seus efeitos nas propriedades porosas do reservatório. Os resultados obtidos a partir da análise petrográfica de poços na Bacia de Santos corroboram com o entendimento sobre a importância dos processos de formação na determinação das propriedades porosas das rochas. O uso de uma arquitetura de rede neural convolucional permitiu a obtenção de valores de porosidade e permeabilidade mesmo em um *dataset* heterogêneo e complexo, destacado a eficácia da arquitetura desenvolvida, indicando alta capacidade preditiva tanto para a porosidade ( $R^2 = 0,86$ ) quanto para a permeabilidade ( $R^2 = 0,96$ ), consolidando-se como uma ferramenta fundamental para a caracterização de reservatórios em ambientes carbonáticos do pré-sal. Posteriormente, novos testes serão feitos, utilizando para isto um *dataset* maior, composto por um número maior de

imagens e uma nova abordagem híbrida, onde pretende-se utilizar no treinamento imagens e rótulos obtidos na fase de petrografia óptica.



## ABSTRACT

The central focus of this doctoral thesis comprises the characterization of pre-salt carbonate reservoirs and the development of an innovative approach to predict the porosity and permeability of these rocks. This prediction method utilizes machine learning techniques, eliminating the dependency on geophysical data. The study is structured into three distinct manuscripts: (I) Petrography and Genesis of Carbonate Rocks from the Barra Velha Formation (Santos Basin, Brazil) and Associated Biogenic Structures, (II) Prediction of Porosity and Permeability of Carbonate Rocks Using Thin Section Data and Machine Learning Methods: A Systematic Review, and (III) Prediction of Carbonate Rock Porosity and Permeability Properties Using Convolutional Neural Networks. The techniques employed encompassed a conceptual literature review, as well as methodologies in machine learning, optical petrography of carbonate rocks, and convolutional neural networks. In the initial phase, 565 thin sections of pre-salt rocks were described through optical petrography, obtained from three wells within the Santos Basin. These descriptions facilitated the identification of primary carbonate facies, elucidated their genesis, and provided the dataset essential for training the neural network. Subsequently, a systematic literature review of prominent machine learning techniques was conducted, integrating the datasets obtained in the previous phase. The primary aim was to leverage these datasets for predicting porosity and permeability. Lastly, in the third phase, the training and prediction of porosity and permeability of pre-salt carbonate rocks were executed utilizing the same dataset utilized in the initial phase. Optical petrography enabled the identification of distinct carbonate facies within the pre-salt rocks, alongside their textural characteristics, mineralogy, and void percentage within the rock

matrix. These attributes collectively formed the foundational components of the training dataset for poroperm prediction. Moreover, insights can be discussed regarding the genesis of pre-salt formations, contributing to the evaluation of the complexity inherent in these substantial oil and gas reserves. Concurrently, systematic bibliographic analysis aids in comprehending the most prevalent techniques employed for dataset generation. Ultimately, the training phase facilitated the development of an specific architecture for the dataset and the particular purpose of predicting porosities and permeabilities of pre-salt rocks, without the necessity for supplementary geophysical data. The integration of data from the optical petrography phase not only facilitated the acquisition and selection of the training dataset but also played a pivotal role in analyzing the data obtained during the predictive process. This phase encompassed the treatment and selection of the image dataset. Moreover, exploration of hydrothermal and biogenic evidence yields valuable insights into the genesis of carbonate facies and their impact on reservoir porous properties. The results obtained from the petrographic analysis of wells in the Santos Basin corroborate with the understanding of the importance of formation processes in determining the porous properties of rocks. The utilization of a convolutional neural network architecture enabled the extraction of porosity and permeability values from a heterogeneous and complex dataset, underscoring the efficacy of the developed architecture. It points out high predictive capacity for both porosity ( $R^2 = 0.86$ ) and permeability ( $R^2 = 0.96$ ), establishing itself as a fundamental tool for characterizing reservoirs in pre-salt carbonate environments. Subsequently, further experimentation will be conducted employing an expanded dataset comprising a larger number of images, alongside a novel hybrid approach,

integrating images and labels obtained from the optical petrography phase for training purposes.

## SUMÁRIO

AGRADECIMENTOS .....	4
RESUMO.....	5
ABSTRACT .....	8
PREFÁCIO .....	12
CAPÍTULO 1 .....	13
Introdução .....	13
Hipótese.....	15
Objetivos .....	156
Materiais e Métodos.....	156
CAPÍTULO 2 .....	22
2.1 Contexto Geológico.....	22
2.2 Porosidade e Permeabilidade de Rochas Carbonáticas .....	33
2.3 Atributos permo-porosos .....	38
2.4 Inteligência Artificial (IA).....	39
CAPÍTULO 3 .....	57
CAPÍTULO 4 .....	97
CAPÍTULO 5 .....	119
CAPÍTULO 6 .....	147
6.1 Discussão dos Resultados.....	147
6.2 Trabalhos em Andamento.....	156
6.3 Contribuições da Tese .....	161
6.4 Considerações Finais.....	161
Referências Bibliográficas.....	163

## PREFÁCIO

Esta pesquisa realizada durante o doutorado é apresentada no formato híbrido, estando composta por seis capítulos, dois capítulos dedicados à apresentação do tema, metodologias e estado da arte, outros três aos manuscritos apresentados para periódicos científicos de prestígio e atualmente em fase de revisão, e o último capítulo contendo as discussões.

O Capítulo 1 apresenta uma introdução necessária para compreender e descrever o tema de estudo. Nele, são apresentados os objetivos, a hipótese e os materiais e métodos utilizados na pesquisa.

O Capítulo 2 apresenta o contexto geológico da área através de uma abordagem revisional da bibliografia, os conceitos quanto as características permo-porosas das rochas e como estas ocorrem em rochas carbonáticas e, assim como os principais conceitos referentes a Inteligência Artificial, Aprendizagem de Máquina e Redes Neurais Artificiais.

O Capítulo 3 apresenta o manuscrito I (em revisão na *Cretaceous Research*) intitulado “*Petrography and Genesis of Carbonate Rocks from the Barra Velha Formation (Santos Basin, Brazil) and Associated Biogenic Structures*”, que aborda a petrografia e a gênese das rochas utilizadas como conjunto de dados de treinamento. Nele são abordadas as principais características das rochas quanto a mineralogia e porosidade. Ainda com base na petrografia, foi realizado uma abordagem quanto a gênese das rochas, considerando algumas formas biogênicas inéditas, identificadas e descritas para os intervalos estudados.

O Capítulo 4 apresenta o manuscrito II (em revisão na *Petroleum*) intitulado “*Prediction of Porosity and Permeability of Carbonate Rocks Using Thin Section Data and Machine Learning Methods: A Systematic Review*” que aborda a revisão sistemática de diferentes técnicas aplicadas de aprendizagem de máquina para a predição de permeabilidade e porosidade utilizando um conjunto de dados baseado em petrografia.

O Capítulo 5 (manuscrito III), que versa sobre “*Prediction of Carbonate Rocks Poroperm Properties Using Convolutional Neural Networks*”, contém a descrição do *dataset* utilizado, a abordagem inteligente utilizada para o treinamento, a arquitetura usada e os resultados obtidos. Este manuscrito foi apresentado a revista *Computer & Geosciences* e está em fase de revisão.

O Capítulo 6 por sua vez, compõe-se das discussões, considerações finais, trabalhos em andamento e as principais referências bibliográficas utilizadas na construção dos capítulos.

## CAPÍTULO 1

### Introdução

A descoberta de imensos reservatórios de carbonato abaixo de uma espessa camada de sal em águas ultraprofundas na costa sudeste do Brasil representou um feito monumental na indústria petrolífera global, consagrando o país como um dos principais polos de produção de petróleo e gás em águas profundas (Silvestre e Dalcol 2009; Rodrigues e Sauer 2015). No entanto, esses reservatórios enfrentam desafios significativos devido à complexidade geológica que os envolve, sendo considerados hoje como depósitos não convencionais, com poucos equivalentes ao redor do mundo, e cuja estruturação e gênese ainda são pouco compreendidas em comparação com os reservatórios siliciclásticos (Nakano *et al.*, 2009).

Os carbonatos do pré-sal foram depositados em ambientes lacustres durante o desenvolvimento de bacias de rifte e sag durante a fragmentação do supercontinente Gondwana e a abertura do Oceano Atlântico Sul no Jurássico Superior/Cretáceo Inferior (Chang *et al.*, 1992; Cainelli & Mohriak, 1999; Mohriak *et al.*, 2008). Essas porções do pré-sal, geneticamente conectadas, são encontradas em ambos os lados do Atlântico Sul, incluindo as bacias brasileiras de Santos, Campos e Espírito Santo (Carminatti *et al.*, 2008; Wright & Barnett, 2015; Herlinger *et al.*, 2017), além das bacias da África Ocidental, como Namibe, Kwanza, Congo e Gabão (Brownfield e Charpentier, 2006; Saller *et al.*, 2016; Ceraldi & Green, 2016). Esses depósitos do pré-sal, tanto no Brasil quanto na África, juntamente com descobertas na China, forneceram evidências globais sobre os carbonatos lacustres continentais (Herlinger *et al.*, 2017).

Os carbonatos lacustres formam-se em ambientes frágeis, suscetível às variações climáticas, mudanças químicas na água e flutuações no aporte de fluídos e no nível da água do lago (Flügel, 2010). Essas oscilações ambientais desempenham um papel crucial em uma série de interações deposicionais, químicas e biogênicas, que influenciam diretamente a porosidade das rochas as quais formam o reservatório (Gierlowski-Kordesch, 2010). Embora a contribuição biótica seja considerada a principal gênese da fácies do reservatório do pré-sal (Moreira et al., 2007; Terra *et al.*, 2010), novos estudos sugerem uma possível origem abiótica dessas rochas relacionada a processos químicos (Wright & Barnett, 2015; Herlinger *et al.*, 2017; Lima & De Ros, 2019).

A diversidade de processos relacionados à gênese das rochas carbonáticas que compõem o reservatório, juntamente com a alta reatividade química dos minerais que as constituem, resultou em um arcabouço permo-poroso heterogêneo, cujas características texturais e mineralógicas influenciam diretamente a permeabilidade do reservatório. Enquanto alguns pesquisadores apontam que a permeabilidade das rochas carbonáticas é influenciada pela presença de porosidade primária gerada por depósitos microbianos (Rezende & Pope, 2015), outros sugerem que os processos diagenéticos são os principais influenciadores da porosidade e permeabilidade do reservatório (Herlinger *et al.*, 2017). Embora muito tenha sido feito para entender a gênese e a influência dessas questões na permeabilidade das rochas do pré-sal, a correlação entre porosidade e permeabilidade ainda não é bem compreendida. Modelos de fluxo podem ser gerados usando dados geofísicos obtidos de poços, no entanto, eles ainda carecem de dados detalhados para validação, e atualmente não existe uma metodologia que possa prever a porosidade e permeabilidade desses

reservatórios sem a combinação de dados geofísicos com petrografia e descrição petrofísica. Nesta pesquisa, adotamos uma abordagem mista que combina dados petrográficos com técnicas de inteligência artificial para prever a porosidade e permeabilidade de rochas carbonáticas.

A abordagem de aprendizado de máquina supervisionada foi empregada neste trabalho. Para o treinamento dos modelos foram utilizadas imagens micrográficas como dados de entrada e como dados de saída foram usados percentuais de porosidade e valores de permeabilidade obtidos a partir de ensaios petrofísicos de laboratório. Os dados geofísicos nessa abordagem não foram utilizados, considerando que não capturam a complexidade do arcabouço destas rochas. Desta maneira, inova-se ao gerar a predição de permeabilidade de reservatório utilizando dados de fácil aquisição, se comparados aos dados geofísicos.

Neste contexto, o objetivo deste estudo é apresentar a metodologia desenvolvida, os dados utilizados e as discussões sobre os primeiros resultados que integram a petrografia e a inteligência artificial para a previsão de porosidade e permeabilidade dos reservatórios carbonáticos lacustres da Formação Barra Velha, na Bacia de Santos, *offshore* do Brasil.

## **Hipótese**

A hipótese desta pesquisa é de que a partir de um conjunto de dados obtidos da petrografia óptica, se consiga prever quais são os valores de porosidade e permeabilidade de rochas reservatório, eliminando a necessidade



de utilizar técnicas petrofísicas ou geofísicas adotadas normalmente, as quais demandam um alto custo de obtenção.

## **Objetivos**

O principal objetivo desta pesquisa é:

- Desenvolver uma metodologia de predição de porosidade e permeabilidade de diferentes fácies carbonáticas através do uso de aprendizagem de máquina, utilizando imagens micrográficas obtidas a partir de petrografia óptica.

Como premissa técnica, pretende-se:

- Descrever petrograficamente os principais constituintes (abióticos ou bióticos) encontrados em lâmina delgada.
- Descrever a gênese do reservatório a partir dos dados petrográficos.
- Caracterizar os principais atributos permo-porosos das fácies carbonáticas com base nos dados coletados em lâmina petrográfica.

## **Materiais e Métodos**

O desenvolvimento desta pesquisa considerou quatro etapas principais:

- Etapa 1 - Revisão bibliográfica.
- Etapa 2 - Seleção de poços e de lâminas delgadas para compor o conjunto de treinamento.
- Etapa 3 - Descrições e análise petrográfica de rochas carbonáticas e aquisição de imagens 2D.

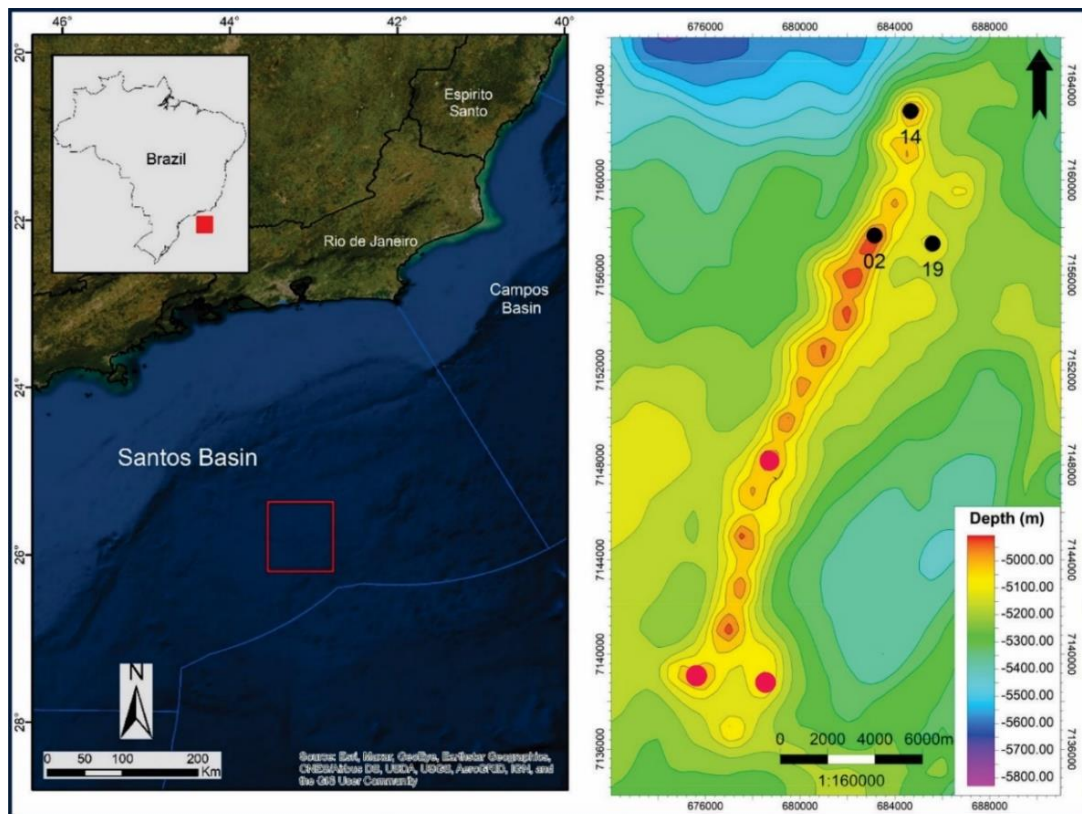
- Etapa 4 - Seleção do método de treinamento, tratamento dos dados e aplicação do método.

### **Etapa 1 – Revisão Bibliográfica**

Na etapa de revisão bibliográfica foram pesquisadas referências sobre a geologia da Bacia de Santos e da Formação Barra Velha, esta com foco na gênese das rochas carbonáticas estudadas e nas principais características permo-porosas das rochas carbonáticas. Realizou-se uma revisão bibliográfica das diferentes abordagens de aprendizagem de máquina para a predição de permeabilidade, com foco no uso de dados obtidos a partir de técnicas petrográficas.

**Etapa 2 – Seleção de poços e de lâminas delgadas para compor o conjunto de treinamento.**

Para adquirir um conjunto de dados que abrangesse todo o intervalo de rochas reservatório da Formação Barra Velha, foram selecionados três poços localizados em um campo de petróleo na Bacia de Santos (Figura 1).



**Figura 1.** Localização da área de estudo e dos poços 02, 14 e 19, no pré-sal da Bacia de Santos. As isópacas representam a base do sal.

Foram selecionados os poços 02, 14 e 19, considerando a suas representatividades em relação às rochas que compõe o reservatório e que possuísem maior número de amostras disponíveis para estudo, incluindo lâminas delgadas associadas a dados de porosidade e permeabilidade físicos obtidos em laboratório de petrofísica (disponibilizados pelo pacote de dados da ANP).

Dos poços selecionados, foram separadas para a descrição petrográfica um total de 564 lâminas delgadas de rocha provenientes de amostras de testemunho e de amostras laterais, além de 1128 dados de porosidade e permeabilidade.

### **Etapa 3 – Petrografia óptica e aquisição de imagens 2D**

Durante a etapa de petrografia ótica, as 564 lâminas delgadas foram analisadas quantitativamente, com contagem modal de 300 pontos por lâmina, totalizando 169.200 pontos quantificados.

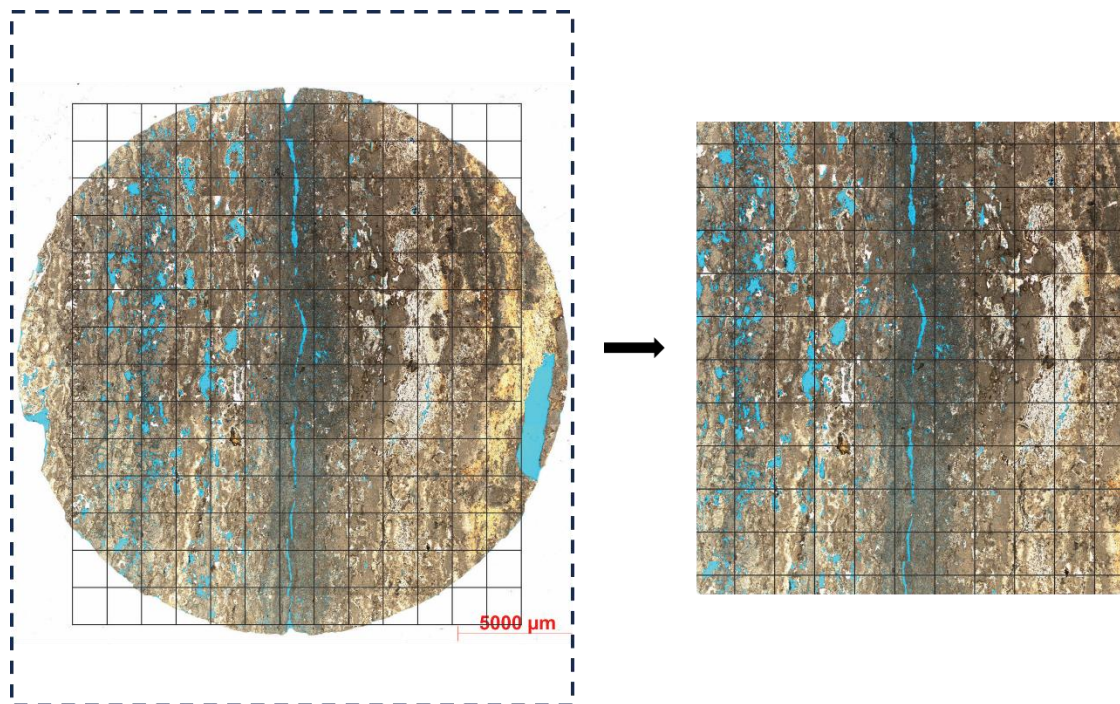
Quanto à descrição petrográfica, foram analisados e quantificados, para cada lâmina delgada descrita, a composição dos grãos do arcabouço, as principais estruturas e texturas, o conteúdo de vazios (poros) existentes, os tipos de poros (Choquette e Pray 1970) e os produtos e processos diagenéticos.

Além dos atributos descritos, durante a petrografia também foi dada especial atenção para a observação dos principais constituintes da rocha com foco na classificação das fácies carbonáticas e na gênese do reservatório (considerando uma gênese microbial ou química), além das características genéticas que podem influenciar na porosidade das rochas.

Do total de lâminas analisadas, 85 apresentaram quatro estruturas *sui generis*. Essas estruturas foram analisadas ao Microscópio Óptico de Varredura (MEV) com Espectroscopia de Energia Dispersiva (EDS), no *itt Oceaneon* (Unisinos, RS).

Foram obtidas, ao microscópio óptico em aumentos 25x, 200x e 500x, tanto à luz natural (LN) quanto à luz polarizada (LP), 1200 imagens micrográficas para registro dos diferentes constituintes do arcabouço. Destas, 186 imagens a luz natural e com aumento de 25x, foram utilizadas no treinamento da rede neural artificial. Junto dessas amostras de detalhe, foram também adquiridas 1128 imagens de conjunto (fotomosaicos), de cada uma das lâminas delgadas, em escala 1x1, obtidas com aumento de 25x, à luz natural (LN) e polarizada (LP). Os fotomosaicos foram obtidos fotografando cada lâmina delgada quadro a

quadro, de forma que os quadros gerados, quando unidos uns aos outros, formassem uma única imagem composta de uma lâmina delgada inteira (Figura 2).



**Figura 2.** Fotomosaico a luz natural, obtido a partir da fotografia quadro a quadro de uma lâmina delgada, com um aumento 2,5x.

**Etapa 4** – Seleção do método de treinamento, tratamento de dados e aplicação do método.

A partir de uma revisão bibliográfica sistemática de diferentes abordagens de redes neurais, explorando os aspectos de Aprendizagem Profunda (Kubat e Kubat 2017; Skansi 2018), verificou-se a possibilidade de testar uma arquitetura de Rede Neural Convolucional (CNN) com base nos dados de entrada utilizados (Wu *et. al.*, 2019).

Como dados de entrada da rede neural foram selecionadas imagens micrográficas 2D e como saída da rede neural (*output*) previu-se o uso dos percentuais de porosidade e os valores de permeabilidades em milidarcys (mD) obtidos a partir de ensaios físicos de laboratório (petrofísicos). A parametrização da rede foi obtida utilizando o método de gradiente descendente, através da função de erro Huber e o algoritmo de otimização Adam (Kingma e Ba, 2017) e *dropout* e *data augmentation* (Hinton *et al.*, 2012)

Como métricas a serem utilizadas, optou-se pelo Erro Quadrático Médio (MSE), Erro Médio Absoluto (MAE), Raíz Quadrática do Erro Médio (RMSE) e o Coeficiente de Determinação ( $R^2$ ) (Chai and Draxler, 2014).

## CAPÍTULO 2

### 2.1 Contexto Geológico

Todas as amostras que originaram o material petrográfico e as imagens utilizadas nesta tese têm sua origem em rochas datadas do Aptiano (Cretáceo médio), as quais correspondem às rochas da Formação Barra Velha localizadas na Bacia de Santos. O contexto geológico e genético destas rochas é abordado no texto a seguir.

#### 2.1.1 Bacia de Santos – Formação Barra Velha

A Bacia de Santos teve sua origem durante o processo de separação da porção oeste do supercontinente Gondwana durante o Neocomiano, a aproximadamente 135 milhões de anos atrás (Thiede e Vasconcelos, 2010), evento este que culminou com a abertura do oceano Atlântico Sul e à separação dos continentes sul-americano e africano estando situada na borda sul do segmento central do Atlântico Sul, a Bacia de Santos, (Moulin *et al.*, 2010) o qual encontra-se delimitado por duas zonas de falha: Ascensão ao norte, e Rio Grande ao sul.

Esse segmento caracterizada pela presença de grandes depósitos evaporíticos formados no Aptiano, incluindo a Bacia de Santos. Essa área é marcada por intensa atividade vulcânica desenvolvida na Província Ígnea Paraná-Etendeka, composta por vulcanismo basáltico toleítico anterior à fragmentação do Supercontinente Gondwana e à formação das sequências sin-rifte das margens continentais (Mizusaki *et al.*, 1992; Peate, 1997; Rosseti *et al.*, 2014).

A questão da origem dos mecanismos que desencadeiam o início do rifteamento ainda é tema de debate. De acordo com Asmus e Baisch (1983), o levantamento do manto astenosférico e a subsequente formação de um domo na crosta continental foram os principais contribuintes para o afinamento da litosfera. Por outro lado, Chang *et al.* (1992) sugerem que esse domo inicial foi resultado de um intenso processo de estiramento litosférico, com as anomalias térmicas desempenhando um papel secundário no processo de rifteamento.

Além disso, a complexa estruturação nas margens africana e sul-americana sugere que a evolução dessas margens foi mais complexa do que os modelos clássicos de sistemas extensionais responsáveis pela abertura de oceanos (Unternehrr *et al.*, 2010). Unternehrr *et al.* (2010), por meio da análise de duas seções sísmicas consideradas representativas das margens sul-americana (Bacia de Campos) e africana (margem de Angola), realizaram um estudo comparativo entre modelos de rifteamento, examinando suas implicações na distribuição de litologias e na estrutura térmica da litosfera durante o processo.

Os modelos de Cisalhamento Puro (Mckenzie, 1978) e de Cisalhamento Simples (Wernicke, 1985) demonstraram ser insuficientes para proporcionar uma explicação abrangente da história deformacional e da arquitetura final das margens em questão. No entanto, Manatschal (2006), mostrou que modelo polifásico proposto por Lavier parece ser mais congruente com as geometrias e estruturas observadas no Atlântico Sul uma vez que o referido modelo, indica que a fase inicial de rifte teria sido dominada por mecanismos de cisalhamento puro, enquanto as fases posteriores seriam seguidas por um componente de cisalhamento simples.



Chang *et al.* (1992), Torsvik *et al.* (2009) e Heine *et al.* (2013) indicam que a deformação distensional foi acomodada de diferentes maneiras ao longo de dois eixos principais entre a África e a América do Sul, com um eixo de orientação NNE, que resultando na ruptura e formação do Oceano Atlântico, estendendo-se desde o extremo sul da Argentina até a Bacia de Sergipe-Alagoas e outro eixo, ligeiramente curvo, com orientação WNW-ENE, o qual formou a margem equatorial brasileira, inclusive o limite transcorrente entre a África e o Brasil.


A Bacia de Santos, por sua vez, têm a sua evolução estrutural influenciada pelas suas heterogeneidades regionais presentes na crosta sobre a qual se formou (Macedo, 1989; Meisling *et al.*, 2001), associada ao principal eixo de abertura NNE, conhecido como "*East Brazilian Rift System*" (Chang *et al.*, 1992).

A configuração geral do rifte na Bacia de Santos é marcada por falhas normais orientadas no sentido NNE, afetadas por zonas de transferência dextral com orientação NW que gradualmente se transformam em direção E-W nas proximidades da transição entre a crosta continental e a crosta oceânica (Meisling *et al.*, 2001). Durante o processo de abertura da bacia o regime tectônico predominante foi caracterizado por uma transtensão sinistral (Macedo, 1989; Meisling *et al.*, 2001; Milani *et al.*, 2005), mas variações diferenciais na extensão da crosta continental durante a formação do Oceano Atlântico deram origem a zonas de transferência, sendo as mais significativas as Zonas de Transferência do Rio de Janeiro, de Curitiba e de Florianópolis (Pereira e Macedo, 1990).

As zonas de transferência representam importantes áreas de reativação da tectônica, com eventos vulcânicos associados, formação de semi-grabens

gerados a partir de falhas NE, sendo importantes zonas de migração de hidrocarbonetos nas áreas sedimentares (Macedo, 1989).

O padrão de zoneamento da bacia de oeste para leste, caracteriza-se por bandas espessas, representando terrenos de embasamento resistente, alternadas para bandas mais finas, estas ligadas aos terrenos de embasamento plástico, com orientação NE-SW (Zalán *et al.*, 2011). De acordo com Zalán *et al.*, (2011), essas faixas são observadas em seções como *boudins* ou afinamentos crustais (Figura 3), sendo que, a transição entre a crosta continental e a crosta oceânica é delineada pela presença de uma ampla faixa de manto exumado, estendendo-se desde a Bacia de Santos até a Bacia do Espírito Santo.



**Figura 3.** Seção geológica da Bacia de Santos obtida através de dados sísmicos e gravimétricos (Zalán *et al.*, 2011).

Por sua vez, o Platô de São Paulo, corresponde a uma elevação batimétrica que varia de 2.000 a 2.800 m de profundidade, constituído por uma crosta continental estirada recoberta pelo sal, este datado do Aptiano (Macedo, 1989; Zalán *et al.*, 2011). Já o Alto Externo de Santos, corresponde a uma elevação do embasamento, localizada na porção central do Platô de São Paulo, cuja estrutura alongada no sentido NE, possui depósitos sedimentares marinhos

menos espessos em direção ao oceano se comparados com as áreas próximas à costa (Rigoti, 2015).

Uma expressiva zona de cisalhamento sinistral conecta as bacias de Campos e Santos com orientação N-S e NE-SW, respectivamente, denominada anomalia magnética de "*Helmut*" (Dehler *et al.*, 2016).

Pereira e Feijó (1994) dividem o arcabouço estratigráfico da bacia da Bacia de Santos em três megasequências separadas por discordâncias erosivas relacionadas às principais fases da evolução tectônica da bacia, conhecidas como Rifte, Pós-Rifte (Transição) e Drifte. O ponto de transição entre estas fases evolutivas é controverso, sendo considerado por alguns como um processo gradual e diacrônico, sugerindo que durante o processo evolutivo do rifte, porções deste evoluíram de maneira diferente em relação à extensão crustal (Bueno, 2004; Zalán *et al.*, 2011; Peron-Pinvidic *et al.*, 2013).

As Supersequências Rifte e Pós-Rifte abrangem os sedimentos do Grupo Guaratiba, que inclui as Formações Camburiú, Piçarras e Itapema (Rifte), e as Formações Barra Velha e Ariri (Pós-Rifte). Enquanto isso, a Supersequência Drifte é subdividida em três Grupos estratigráficos: Camburi, Frade e Itamambuca.

Por outro lado, o embasamento da Bacia de Santos é pouco compreendido, embora suas características estruturais sugiram que seja uma extensão para leste das rochas granito-gnáissicas da Faixa Ribeira, expostas na área continental, e profundamente afetadas por falhas transcorrentes pré-cambrianas com orientação NE-SW (Pereira e Macedo, 1990). Além disso, outras heterogeneidades incluem zonas de sutura entre blocos continentais,

cinturões de dobramentos e cavalgamentos, zonas de cisalhamento e enxames de diques máficos. Essas descontinuidades influenciam o arcabouço estrutural da Bacia de Santos por meio da reativação de estruturas durante o processo de estiramento e abertura do Oceano Atlântico (Mio, 2005).

A supersequência Rifte teve início no Hauteriviano e se estendeu até o Aptiano. Durante esse período, o arcabouço estrutural dessa fase tectônica consistia em uma rede de falhas sintéticas e antitéticas predominantemente orientadas no sentido NE-SW, resultando na formação de meio-grábens e elevações internas (Cainelli e Mohriak, 1999). O espessamento significativo das camadas em relação aos planos de falha sugere que a sedimentação ocorreu simultaneamente à atividade tectônica das falhas.

Moreira *et al.* (2007) realizaram um estudo de atualização do arcabouço cronoestratigráfico da Bacia de Santos e subdividiram seu preenchimento sedimentar em sequências deposicionais, limitadas por discordâncias de caráter regional (Figura 4).

A supersequência rifte é subdivida em três sequências: K20-K34 (Formação Camboriú), K36 (Formação Piçarras) e K38 (Formação Itapema). Sua deposição se iniciou no Hauteriviano (Rio da Serra e Aratu), prolongando-se até o Aptiano (Jiquiá).

A Formação Camboriú, composta por derrames basálticos eocretáceos, que constitui o embasamento econômico da bacia, tem limite inferior discordante com as rochas do embasamento síalico e possui como limite superior a discordância com os sedimentos da Sequência K36 (Moreira *et al.*, 2007).



Já a supersequência pós-rifte ou transicional foi subdivida em três sequências: K44 (porção inferior da Formação Barra Velha), K46-48 (porção superior da Formação Barra Velha) e K50 (Formação Ariri). A sequência K44 tem seu limite inferior dado pela discordância conhecida como Pré-Alagoas e seu limite superior pela discordância de 117 Ma, que corresponde a um refletor sísmico de forte amplitude (Moreira *et al.*, 2007). Depositou-se em um ambiente transicional entre continental e marinho raso estressante. Segundo a literatura, a Formação Barra Velha é composta por calcários estromatolíticos, laminitos microbiais, microbiolitos ricos em talco e argilas magnesianas, e folhelhos carbonáticos. A porção superior da Formação Barra Velha depositada durante o Neoaptiano (andar local Alagoas superior) é constituída por calcários microbiais localmente dolomitizados. O ambiente deposicional desta sequência é semelhante ao anterior (ambiente transicional, entre continental e marinho raso estressante) (Moreira *et al.*, 2007).

Por sua vez, a sequência K50 é formada pelos evaporitos, composto principalmente de halita e anidrita, ocorrendo também outros sais mais solúveis como taquidrita, carnalita e silvinita, inseridos na Formação Ariri, depositados durante o Neoaptiano (andar local Alagoas superior). Tem seu limite inferior no contato dos carbonatos da Sequência K46-K48, enquanto seu limite superior é representado pela passagem entre os evaporitos e os sedimentos siliciclásticos/carbonáticos das Formações Florianópolis e Guarujá.

Carminatti *et al.* (2008) realizam uma análise simplificada de cunho regional dessa unidade, utilizando principalmente características sísmicas. Eles associam uma origem microbiana aos carbonatos que compõem a Formação Barra Velha, sugerindo que estes foram depositados em um ambiente marinho

raso, desenvolvendo-se preferencialmente em áreas de elevações do embasamento. Os autores subdividem a Formação Barra Velha em duas unidades: microbialitos "limpos" no topo da sequência e microbialitos ricos em argila na base da sequência. Além disso, eles interpretam variações laterais nas fácies, indicando uma transição de proximais para distais em direção à quebra da plataforma.

Terra *et al.* (2010) propuseram uma origem microbial para os carbonatos, descrevendo-os, quando ligados durante a deposição, como estromatólitos (conforme proposto por Riding, 2000) e esferulitos. Por sua vez, Wright e Barnett (2015) foram pioneiros ao publicar um estudo sedimentológico mais detalhado sobre as fácies carbonáticas da Formação Barra Velha, com descrições de testemunhos e lâminas provenientes de diversos poços da Bacia de Santos.

Contrariamente a outros autores, Wright & Barnett (2015) sugeriram um modelo predominantemente abiótico para a deposição desses carbonatos, associando seu crescimento a processos evaporativos.

Tosca & Wright (2015) concentraram-se em detalhar as condições geoquímicas necessárias para a cristalização de argilominerais magnesianos, um componente importante das rochas da Formação Barra Velha e que influencia significativamente sua qualidade de permeabilidade. Os autores também discutiram os fatores que afetam a preservação ou dissolução desses minerais, destacando a atividade de bactérias metanogênicas e a energia do ambiente como os principais responsáveis pela dissolução desses silicatos.

Falcão (2015), ao estudar os testemunhos aptianos de um poço na Bacia de Santos, identificou carbonatos com características distintas das normalmente

observadas nas rochas carbonáticas da Formação Barra Velha, sugerindo a presença de travertinos subaéreos. As fácies apresentam um bandeamento fenestral, muitas delas com alto grau de inclinação, truncamentos e a presença de estruturas do tipo *rafts*, juntamente com a presença de meniscos típicos de depósitos de travertinos.

Além das evidências faciológicas, Falcão (2015) identificou em seções sísmicas que o poço está localizado em uma elevação estrutural próxima a uma zona de falha, a qual pode ter sido uma elevação subaérea na época da deposição, com as falhas servindo como condutos para fluidos ascendentes, responsáveis pela precipitação de travertinos.

Recentemente, foram publicados trabalhos detalhados sobre seções cronocorrelatas da Formação Barra Velha, destacando-se os estudos de Herlinger Jr *et al.* (2017) e de Saller *et al.* (2016). Esses trabalhos descrevem, respectivamente, os carbonatos aptianos da Bacia de Campos (Grupo Lagoa Feia) e da Bacia de Kwanza (margem africana), fornecendo informações adicionais extremamente relevantes sobre a Formação Barra Velha, considerando a escassez de literatura disponível.

Saller *et al.* (2016) publicaram um estudo estratigráfico e sedimentológico sobre os carbonatos aptianos da Bacia de Kwanza, localizada na porção *offshore* de Angola. Essa bacia era adjacente à Bacia de Campos durante os estágios iniciais da abertura do Atlântico Sul, sendo então separadas posteriormente, na fase de drifte. Neste estudo, os autores mostraram fácies com características muito semelhantes às observadas nos carbonatos da Formação Barra Velha.



Herlinger Jr *et al.* (2017) realizaram um estudo petrográfico e petrofísico sistemático para caracterizar os principais controles na origem e evolução das fácies e do sistema poroso dos carbonatos do Grupo Lagoa Feia, na Bacia de Campos. Os autores apresentam os principais produtos diagenéticos identificados nesses carbonatos e propõem uma evolução diagenética para essas fases. Este trabalho representa a primeira caracterização petrográfica desses reservatórios carbonáticos aptianos, correlacionados aos carbonatos de mesma idade da Formação Barra Velha, fornecendo informações importantes para a caracterização diagenética da Formação Barra Velha.

Lima & De Ros (2019), a partir de análises petrográficas e geoquímicas de amostras da Formação Barra Velha na Bacia de Campos, identificaram a sequência de formação das unidades carbonáticas e indicaram uma gênese diagenética para o reservatório, bem como a influência do hidrotermalismo tardio na distribuição da porosidade daquelas rochas.

Adriano *et al.* (2022) analisando dados sísmicos (contorno estrutural e isópacas de sedimentos) do Campo de Tupi na Bacia de Santos, identificou que durante o intervalo referente a Formação Barra Velha superior ocorreu a reativação de falhas importantes as quais atingiram a base do sal. Com essa indicação, os autores propuseram que a sedimentação que corresponde a Formação Barra Velha tenha sido depositada não mais na fase de SAG, mas sim em uma fase relacionada ao rift tardio. Strugale *et al.* (2023), também usando dados sísmicos, aponta evidências de hidrotermalismo associado a gênese da Formação Barra Velha, este ligado a reativação de falhas que chegam até a base do sal.

## 2.2 Porosidade e Permeabilidade de Rochas Carbonáticas

Em geral, nas rochas sedimentares, a porosidade é medida pela proporção de vazios (poros) em relação ao conteúdo mineral, ambos expressos em valores de porcentagem (Moore & Wade, 2013). A análise dos tipos de poros, conexões, localização e distribuição do espaço poroso, bem como minerais diagenéticos que obstruem os vazios do arcabouço, são importantes atributos para a compreensão da migração e acumulação de fluidos, sejam eles petróleo, gás ou água (De Ros & Goldberg, 2007).

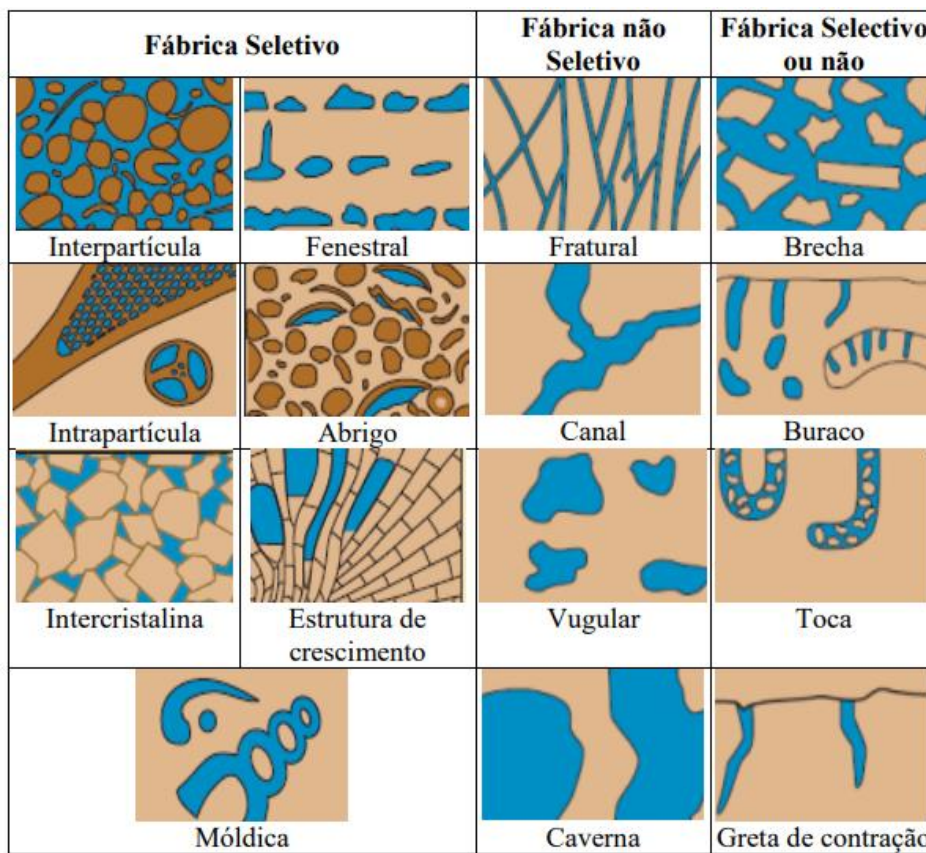
De forma genérica, a estrutura porosa ou espaço poroso (vazio) em uma rocha é dividida em poro (espaço maior de um vazio) e conexão (ou garganta), caracterizada por um vazio alongado que une dois ou mais espaços vazios conectando-os (Al-kharusi & Blunt, 2007).

A porosidade nas rochas pode ser do tipo primária, gerada durante a formação da rocha ou no final da deposição dos sedimentos, ou secundária, originada por processos pós deposicionais (dissolução, fraturamento, etc) (Berryman & Wang, 2000). Segundo Berryman & Wang (2000) em escala de reservatório os tipos de porosidade mais importantes são a porosidade da matriz e a porosidade por fratura.

A susceptibilidade dos carbonatos à dissolução, substituição e recristalização, proporciona o desenvolvimento de poros de diversos tipos e tamanhos, distribuídos heterogeneamente pelo arcabouço da rocha (Akbar *et al.*, 2001). Esta rede intrincada de poros pode se agrupar em três tipos principais de poros: a) porosidade conectada ou efetiva; b) porosidade vugular (poros

ampliados pela dissolução do material carbonáticos) ou, c) porosidade por fraturamento (processos pós-deposicionais) (Akbar *et al.*, 2001).

Choquette e Pray (1970) classificaram a porosidade das rochas carbonáticas em três grupos: fábrica seletiva; fábrica não seletiva e fábrica seletiva ou não seletiva. Scholle & Scholle (2003) fizeram uma representação esquemática dos diferentes tipos de porosidade (Figura 5) com base na classificação de Choquette e Pray (1970).



**Figura 5.** Classificação da porosidade em rochas carbonáticas (Scholle & Scholle 2003, a partir de Choquette e Pray, 1970).

No primeiro grupo, a responsabilidade pela formação do poro é o arranjo entre os grãos e cristais ou outras estruturas físicas e os poros não ultrapassam os seus limites primários. Neste grupo, inclui-se a porosidade:

- Interpartícula : poro formado pelas partículas sedimentares, com um diâmetro de poro maior que 10  $\mu\text{m}$ .
- Intrapartícula: poro formado no interior das partículas ou grãos das rochas, com um diâmetro de poro menor que 10  $\mu\text{m}$ .
- Intercristalina: poro formado pelos cristais da rocha.
- Mórdica: poro formado pela remoção seletiva ou dissolução do material sedimentar.
- Fenestral: poros maiores e mais longos que os interstícios formados pelos grãos das rochas, com diâmetros maiores que 100  $\mu\text{m}$ .
- *Shelter* (ou abrigo): as partículas cobrem a superfície da rocha em formação, deixando um espaço vazio formando o poro e evitando que seja preenchido por material mais fino.
- *Growth* – Framework (ou estrutura de crescimento): um tipo de porosidade primária criada a partir do crescimento *in situ* da estrutura da rocha carbonática.

No grupo de fábrica não seletiva, os poros podem atravessar seus limites primários, incluindo-se neste tipo os seguintes poros:

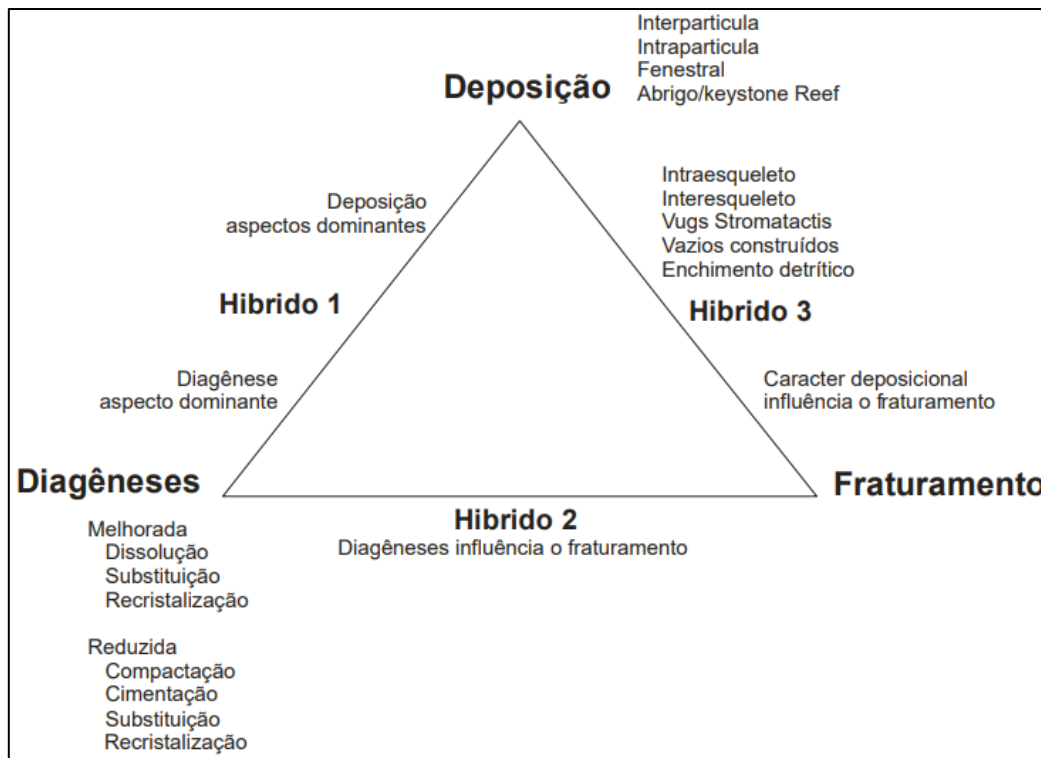
- Fratura: originada pelo faturamento da rocha, que pode induzir à formação de outros tipos de poros e aumentos significativos da permeabilidade.
- Canal: poros alongados com continuidade em uma ou duas dimensões, com comprimento 10 vezes maior que a sua seção transversal.
- Vugular: poro com diâmetro maior que 1 mm, não apresenta relação com a textura da rocha, é formado geralmente por dissolução com um baixo grau de comunicação.

- *Caverna*: porosidade originada por processos de dissolução, caracterizada por tamanhos agigantados, como grandes cavidades ou cavernas, podendo seu tamanho ser em torno de meio metro.

O último grupo, de fábrica seletivo ou não, inclui as porosidades:

- *Brecha*: identificada principalmente na zona de falha, por dissolução, com fluxo de detritos e deslizamento ou deformação tectônica.
- *Boring* (ou buraco): poros gerados por organismos em sedimentos relativamente rígidos.
- *Burrow* (ou toca): poros formados por organismos em sedimentos pouco consolidados.
- *Shrinkage* (ou gretas de contração): poros originados por processos de secagem de sedimentos finos, com tamanhos variáveis (Rodriguez, 2006).

Por sua vez, Lucia (1983,1999) faz uma classificação da porosidade enfatizada em aspectos petrofísicos, considerando a conectividade dos poros tipo vugular, a fim de estimar a porosidade intergranular e a propriedade de capilaridade e permeabilidade. Arh (2008), compreende ser esta uma classificação prática que isenta-se de ter que explicar a gênese da rocha e propõe uma classificação genética para as porosidades das rochas carbonáticas, incluindo três processos de formação (deposição, fraturamento e diagênese) e uma gênese híbrida (Figura 6).



**Figura 6.** Classificação da gênese da porosidade (Arh, 2008 *in* Chillingar *et al.*, 2011).

Já Garcia-del-Cura *et al.* (2012) sugerem o uso de macroporosidade e microporosidade para a classe de poros associados a travertinos. Segundo eles, macroporosidades seriam aquelas com tamanho maior que 100  $\mu\text{m}$  (podendo atingir até vários centímetros), enquanto microporosidades seriam poros com tamanho menor de 100  $\mu\text{m}$  (0,1 mm).

Nas rochas carbonáticas a migração de fluidos ocorre através de poros intercrystalinos (ou intergranulares) conectados, ou mesmo através de fraturas. A porosidade intercrystalina ou intergranular, pode ser primária (deposicional), ou secundária, originada por processos diagenéticos ou hidrotermais que propiciam a dissolução parcial ou total dos constituintes minerais que compõe o arcabouço da rocha (Haraugh, 1967; Moore & Wade, 2013).

Além disso, de acordo com a condutividade da rocha, a estrutura porosa pode ser dividida em espaço poroso efetivo e não efetivo, ou de armazenamento,

sendo a porosidade efetiva aquela que controla a permeabilidade. Porosidade não efetiva é definida como aquela onde a velocidade do fluxo é menor que 1% da velocidade média do fluido (Bernabé *et al.*, 2003).

A permeabilidade, por outro lado, refere-se à facilidade de passagem de líquidos ou gases através dos poros da rocha. É medido em Darcy (D), sendo 1D equivalente a 1 cm<sup>3</sup> de fluido com viscosidade de 1 cP (centipoise) fluindo através de 1 cm<sup>2</sup> de seção transversal de rocha em 1 segundo sob a pressão de 1 atm/cm. A maioria das rochas possui permeabilidade média consideravelmente menor que 1D, a medição geralmente é feita em mD (mili-Darcy) (Buryakovsky *et al.*, 2012; Yang, 2017). Nas rochas reservatório, essa permeabilidade está diretamente relacionada à porcentagem de poros conectados. Ou seja, quanto maior a porosidade, maior a permeabilidade.

Uma forma comum de medir o desempenho das rochas carbonáticas presentes em reservatórios é através de testes petrofísicos realizados em laboratório utilizando injeção de mercúrio. Esta técnica consiste em injetar mercúrio com pressão controlada em uma amostra de rocha. Então, um gráfico relacionando a quantidade de pressão necessária para o mercúrio preencher todos os espaços porosos da estrutura rochosa é gerado, permitindo a obtenção das condições ambientais necessárias para que o fluido se mova pelos poros (Harbaugh, 1967; Yang, 2017). Esta técnica é destrutiva e pode alterar e reorganizar permanentemente o espaço poroso da rocha, especialmente em rochas cujo conteúdo mineral é reativo como as rochas carbonáticas.

### **2.3 Atributos permo-porosos**

O reconhecimento de petrofácies reservatório começa com a identificação de diversos atributos em lâmina delgada os quais influenciam na porosidade e permeabilidade das rochas. Alguns atributos são identificados através de uma análise modal quantitativa, contando 300 pontos ou mais, ou diretamente por meio de uma descrição meramente qualitativa do arcabouço das rochas.

Os parâmetros podem ser primários, os quais envolvem desde estruturas sedimentares, textura e arranjo do arcabouço (tamanho dos grãos, classificação, arredondamento, empacotamento e orientação) como secundários, aqueles obtidos através do reconhecimento de elementos originados por processos de dissolução e precipitação ocorridos após a deposição e que culminam com a ampliação ou obliteração parcial ou total do espaço poroso da rocha (De Ros & Goldberg, 2007).

### **2.3. Inteligência Artificial**

A Inteligência Artificial (IA) é uma área com muitas aplicações práticas e tópicos de pesquisa ativos. Softwares inteligentes são utilizados para automatizar tarefas rotineiras, compreender falas ou imagens, fazer diagnósticos médicos e auxiliar pesquisas científicas (Goodfellow, Bengio & Courville, 2016).

De acordo com Chollet (2017), durante muito tempo acreditou-se que com um conjunto suficientemente grande e complexo de regras explícitas para gerir o conhecimento, seria possível alcançar uma IA de nível humano. Embora esta forma de programação consiga resolver problemas lógicos bem definidos, outros problemas mais complexos, como classificação de imagens, reconhecimento de fala e tradução de idiomas, são ainda um desafio.



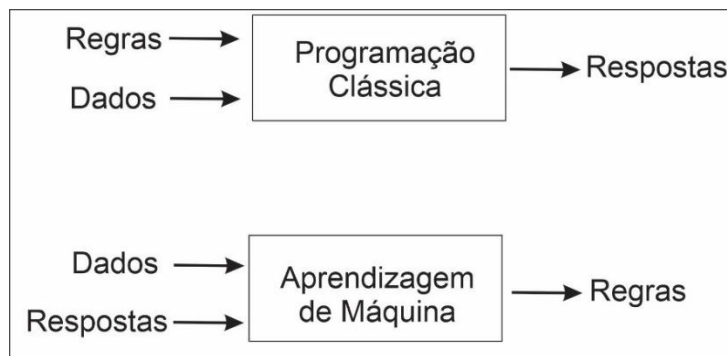
Goodfellow, Bengio & Courville (2016) afirmam que para que os computadores se comportem de forma inteligente não basta resolver problemas formais constituídos por uma sequência de regras. É necessário captar o mesmo conhecimento de mundo que o ser humano possui, um conhecimento subjetivo e intuitivo utilizado no dia a dia. Ironicamente, este conhecimento que ocorre naturalmente na mente humana é um dos maiores desafios da AI.

- **Aprendizado de Máquina**

As dificuldades enfrentadas pelos sistemas codificados com conhecimento formal e conjuntos de regras sugerem a necessidade de os sistemas de IA terem a capacidade de adquirir o seu próprio conhecimento, através da extração de padrões de dados brutos. Essa habilidade foi descrita por Goodfellow, Bengio & Courville (2016) como Machine Learning (ML). Por sua vez, Mitchell (1997) definiu Aprendizagem de Máquina da seguinte forma: "Diz-se que um programa de computador aprende com a experiência E em relação a alguma classe de tarefas T e métricas de desempenho P, se seu desempenho em tarefas em T, conforme medido por P, melhora com a experiência E."

Em Aprendizagem de Máquina, os computadores são programados para aprender com experiências anteriores. Para isso, empregam um princípio de inferência denominado indução, no qual conclusões genéricas são obtidas a partir de um determinado conjunto de exemplos. Assim, os algoritmos aprendem a induzir uma função ou hipótese capaz de resolver um problema a partir de dados que representam instâncias do problema a ser resolvido (Faceli et al., 2011).

Enquanto na programação tradicional seria elaborado um conjunto de regras para que, juntamente com um conjunto de dados, fosse realizado o processamento e obtida a resposta, na Aprendizagem de Máquina o processamento é realizado com base no conjunto de dados combinado com os resultados. A partir dessa combinação, o algoritmo é treinado compondo uma função que mapeia cada dado de entrada ao resultado. Por esse motivo, diz-se que o sistema é treinado e não explicitamente programado (Chollet, 2017). A figura 7 ilustra a diferença entre os dois paradigmas.

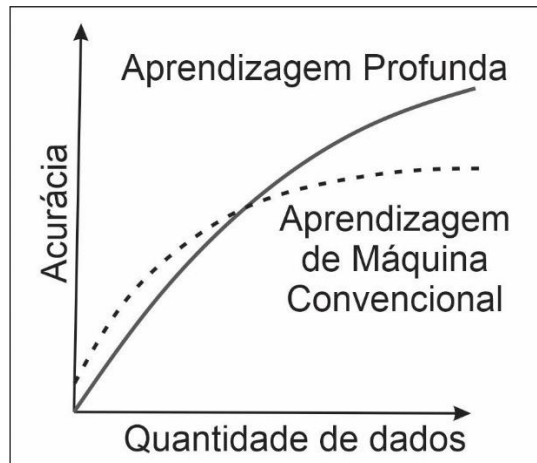


**Figura 7.** Comparativo entre programação tradicional e *Machine Learning* (Chollet, 2017).

Algoritmos treinados em vez de programados tendem a ter vantagens em problemas complexos porque não dependem de muitas regras explicitamente programadas para funcionar conforme o esperado. Outro benefício é a flexibilidade para novos exemplos. Um modelo com boa generalização não depende de alterações manuais ou regras adicionais.

Em relação a Aprendizagem de Máquina, a Aprendizagem Profunda busca resolver problemas com representações complexas que um algoritmo normal de ML não consegue resolver com eficiência. Ao aprender em camadas sucessivas de representações cada vez mais significativas, consegue transformar conceitos complexos em uma sequência de conceitos simples

(Chollet, 2017). A figura 8 representa a relação entre a precisão e a quantidade de dados para abordagens de Aprendizagem de Máquina em contraste com a Aprendizagem Profunda, mostrando a melhoria na precisão à medida que o número de dados aumenta.



**Figura 8.** Relação entre o aumento da precisão e a quantidade de dados (Aggarwal, 2018).

Assim como a aprendizagem de máquina é uma subárea da inteligência artificial, a aprendizagem profunda é uma subárea da aprendizagem de máquina. Os algoritmos de aprendizado de máquina podem ser classificados de acordo com a relação entre uma determinada entrada e o *feedback* dessa entrada, definindo três formas principais de aprendizagem por um agente inteligente (Russell e Norving, 2013):

- Aprendizado supervisionado – O agente observa pares de entrada e saída e aprende uma função que mapeia entrada para saída. Portanto, depende dos dados já estarem rotulados com suas respectivas saídas;
- Aprendizagem não supervisionada – O agente aprende padrões nas entradas sem qualquer *feedback* explícito. Os dados de entrada não são rotulados como na aprendizagem supervisionada;

- Aprendizagem por reforço - Processo sequencial de tomada de decisão, onde o agente aprende através de uma série de reforços, recompensas e punições recebidas ao interagir com o ambiente.

As tarefas de Aprendizagem de Máquina também são comumente divididas de acordo com diferentes classes de problemas que ela tenta resolver (Mohri, Rostamizadeh e Talwalkar, 2018), a saber:

- Classificação – Os dados de entrada devem ser classificados em alguma categoria numérica discreta, dentro de um conjunto finito de valores. Pode conter duas categorias (classificação binária) ou múltiplas categorias (classificação multiclasse). Exemplos: Classificação de imagens como sendo de cachorro ou gato (binário) e classificação de imagens de caracteres manuscritos (multiclasse);

- Regressão – Os dados de entrada devem ser mapeados para um valor numérico contínuo. Exemplos: Previsão do valor de uma ação em bolsa e previsão do valor de um imóvel;

- *Ranking* - Ordenação de itens de acordo com alguns critérios. Exemplo: Determinação dos documentos e páginas web mais relevantes numa pesquisa web;

- *Clustering* - Divisão de um conjunto de itens em conjuntos menores com base em semelhanças. Exemplo: identificação de características comuns entre diferentes usuários de uma loja virtual;

- Redução dimensional - Transformação de uma representação inicial de um conjunto de itens para uma representação em menos dimensões sem perder

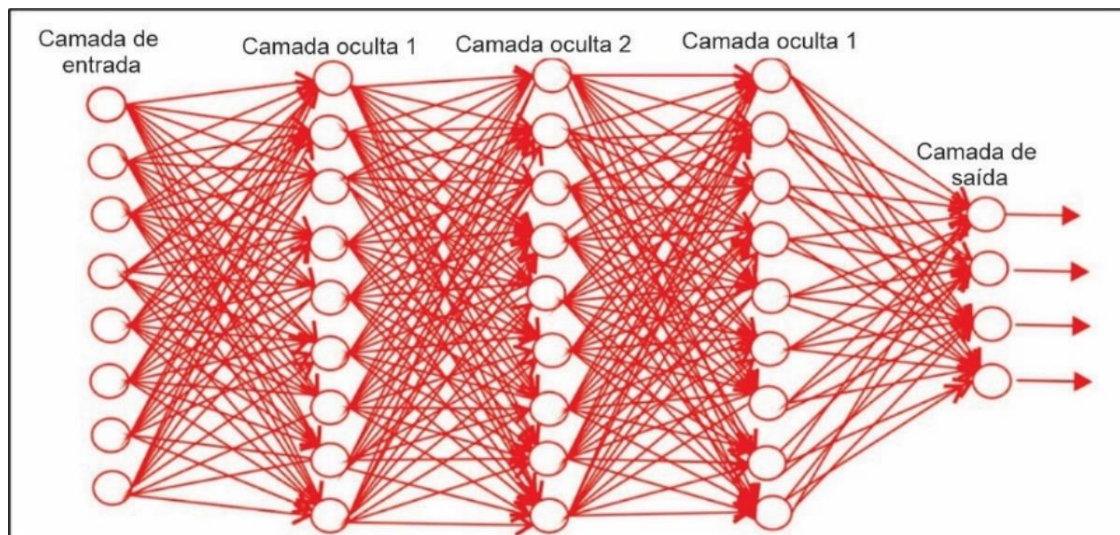
propriedades importantes. Exemplo: Pré-processamento de imagens digitais para tarefas de aprendizagem profunda mais complexas.

- Redes Neurais Artificiais (RNA)

Redes Neurais Artificiais foram desenvolvidas com base no funcionamento do cérebro humano, onde suas unidades computacionais são tratadas de forma análoga aos neurônios biológicos. Elas são teoricamente capazes de aprender qualquer função matemática a partir do treinamento em um conjunto suficiente de dados (Aggarwal, 2018).

O neurônio de uma rede neural artificial aplica uma função de ativação na soma de um conjunto de entradas multiplicada por um conjunto de pesos e adicionada a uma constante, ou polarização. O resultado é propagado e se torna uma entrada para o próximo neurônio. Esta é a forma mais simples de neurônio artificial, sendo chamada de *Perceptron* (Aggarwal, 2018).


Uma rede neural nada mais é do que um conjunto de neurônios artificiais interligados por múltiplas camadas, conforme mostra a figura 9. A primeira camada da rede é chamada de camada de entrada, a última é chamada de camada de saída e as demais camadas intermediárias são denominadas de camadas ocultas.



**Figura 9.** Rede Neural Artificial (Nielsen, 2015).

- Gradiente descendente

O gradiente descendente é um processo aplicado durante o treinamento de uma rede neural para ajustar seus pesos para encontrar um valor mínimo global para a função de erro. A partir do cálculo da derivada parcial do erro relativo a cada um dos pesos é possível determinar se o peso deve aumentar ou diminuir (Heaton, 2015). O valor de cada passo em direção ao valor mínimo é definido por uma taxa de aprendizagem. Este valor não deve ser definido muito baixo, o que poderia causar uma convergência lenta, e nem muito alto, o que poderia causar uma divergência do valor mínimo global (Géron, 2019). Em redes neurais artificiais, uma variação do algoritmo de gradiente descendente bastante utilizado é o *Stochastic Gradient Descent* (SGD). Este algoritmo utiliza pequenos conjuntos, ou lotes, de exemplos, em vez de todo o conjunto de treinamento. Isso permite uma melhoria significativa no desempenho, diminuindo o tempo de treinamento da rede (Lecun, Bengio e Hinton, 2015). A figura 10 ilustra o processo de gradiente descendente estocástico buscando o menor valor para uma função de erro.



**Figure 10.** Gradiente Descendente Estocástico (Géron, 2019).

Para aplicar retroativamente o gradiente descendente sobre todos os pesos de uma rede neural, utiliza-se a técnica *Backpropagation* (Rumelhart, Hinton e Williams, 1986). A partir do valor do erro na saída, ele pode trabalhar de forma inversa das camadas finais para as iniciais, atualizando os parâmetros com uma técnica chamada regra da cadeia (Chollet, 2017).

Dois problemas comuns relacionados ao gradiente descendente nas redes neurais são o gradiente explosivo e o gradiente evanescente, os quais ocorrem quando os gradientes se tornam extremamente grandes ou pequenos a ponto de prejudicar ou não influenciar o treinamento da rede. Ambos causam problemas durante o treinamento, tornando-o instável e muitas vezes impossibilitando a evolução da rede durante o processo (Aggarwal, 2018; Géron, 2019).

- *Overfitting and underfitting*

Os modelos de treinamento podem sofrer *overfitting*, isso ocorre quando o modelo começa a ter um bom desempenho nos dados de treinamento, mas tem um desempenho ruim nos novos dados, portanto, não pode generalizar. O

*overfitting* pode ser evitado adicionando mais dados de treinamento, aplicando técnicas de regularização ou camadas de abandono. Por outro lado, o *underfitting* ocorre quando o modelo não consegue ter um bom desempenho mesmo nos dados de treinamento, portanto não consegue otimizar o treinamento. Um dos maiores desafios ao projetar um modelo de aprendizado de máquina é encontrar o ponto ideal entre ser capaz de generalizar sobre novos dados e otimizar os dados de treinamento, evitando tanto *overfitting* quanto *underfitting* (Chollet, 2017).

- Função de perda

Uma função de perda determina quão diferente é o resultado esperado do resultado obtido pela rede neural para cada amostra de treinamento. É utilizado no cálculo da derivada para ajuste de pesos durante o treinamento. É também por meio de funções de perda que muitas das métricas de avaliação de desempenho de um modelo treinado são obtidas (Heaton, 2015). Portanto, escolher uma função de perda adequada para o problema é muito importante para obter bons resultados.

As funções de perda mais utilizadas para problemas de regressão são Erro Quadrático Médio (MSE) e o Erro Médio Absoluto (MAE). Existe também uma variação do MSE chamada Raiz Quadrada do Erro Médio (RMSE), onde uma raiz quadrada é aplicada ao resultado (Chai & Draxler, 2014). Ambos são representados pelas equações 1 e 2, sendo  $n$  o número de amostras,  $\hat{y}$  o valor esperado e  $y$  o valor calculado pelo modelo,



$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (2)$$

Enquanto a função MAE atribui o mesmo peso a todos os erros, a função MSE penaliza variações muito grandes, dando maior peso aos erros com valores absolutos maiores (Chai & Draxler, 2014). Assim, o MAE torna-se mais adequado quando os erros são distribuídos uniformemente, enquanto o MSE torna-se mais adequado para distribuição normal com a presença de alguns outliers (Chai & Draxler, 2014).

Como alternativa às duas funções, existe também a função perda de Huber indicada na equação 3. Esta função é um híbrido das duas anteriores, possibilitando o comportamento da função quadrática e da função absoluta de acordo com o parâmetro  $\delta$ . É considerada uma função mais robusta, sendo menos propensa e sensível a ruídos nos dados (Alqahtani *et al.*, 2020; Holland e Welsch, 1977).

$$L_{\delta}(a) = \begin{cases} \frac{1}{2}a^2 & |a| \leq \delta \\ \delta(|a| - \frac{1}{2}\delta) & |a| > \delta \end{cases} \quad (3)$$

- Funções de ativação

Funções de ativação são usadas em redes neurais artificiais para transformar um valor de entrada em um valor de saída que é propagado para a próxima camada. Eles são necessários para evitar que o sinal de saída tenha um formato linear e para poder mapear e treinar o modelo com problemas mais complexos (Sharma, 2020). Dependendo do tipo de problema que se tenta

resolver, diferentes funções de ativação podem ser utilizadas. Além disso, cada camada da rede neural pode usar uma função de ativação diferente.

- Sigmoide

A função não linear transforma o valor em um intervalo entre 0 e 1, garantindo um valor pequeno e positivo. Geralmente é utilizado quando o objetivo é obter a probabilidade de uma entrada pertencer a uma determinada categoria em classificações binárias (Sharma, 2020).

Esse tipo de função pode causar um problema chamado gradiente de fuga, quando o gradiente se torna tão pequeno e insignificante que acaba não atualizando os pesos, fazendo com que toda a rede fique destreinada.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

- Tangente hiperbólica (*tanh*)

Esta função é semelhante à função sigmoide, mas permite valores negativos na faixa entre -1 e 1 (Heaton, 2015) não restringindo seu gradiente a apenas uma direção (Sharma, 2020). No entanto, como a função sigmoide, ela tem o mesmo problema do gradiente evanescente.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

- Unidade Linear Retificada (ReLU)

Uma das funções mais utilizadas em redes neurais, foi proposta por Nair e Hinton (2010) e resolve o problema do gradiente evanescente. Uma de suas maiores vantagens é o fato de que nem todos os neurônios são ativados

simultaneamente, pois o neurônio estará desativado apenas quando a saída da função é zero, tornando esta função mais eficiente que outras funções (Sharma, 2020; Nwankpa *et al.*, 2018).

Um dos problemas dessa função é que os neurônios tendem a morrer durante o treino, fazendo com que os pesos não sejam atualizados e atrapalhando o treino (Nwankpa *et al.*, 2018).

Existem também duas variações simples da função ReLU: o ReLU vazado (LReLU) proposto por Mass, Hannun e NG (2013) para resolver o problema da morte de neurônios e o ReLU parametrizado (PReLU) proposto por HE *et al.* (2015). A única diferença entre eles é o valor de  $\alpha$ , que assume 0 em ReLU, 0,01 em LReLU e um valor parametrizado em PReLU.

$$ReLU(x) = \begin{cases} x & x \geq 0 \\ \alpha x & x < 0 \end{cases} \quad (6)$$

- Unidade Linear Exponencial (ELU)

Outra variação da função ReLU foi proposta por Clevert, Unterthiner e Hochreiter (2016), que também utilizam um valor parametrizado para a inclinação dos valores negativos de  $x$ , com a diferença de utilizar uma curva logarítmica (Sharma, 2020).

$$ELU(x) = \begin{cases} x & x \geq 0 \\ \alpha(\exp(x) - 1) & x < 0 \end{cases} \quad (7)$$

- Unidade Linear Exponencial de Escala (SELU)

Variação da função ELU introduzida por Klambauer *et al.* (2017) com propriedades autonormalizantes, uma vez que a média e a variância convergem

para zero. Esta função consegue evitar os problemas de desaparecimento e explosão do gradiente (Nwankpa *et al.*, 2018).

$$SELU(x) = \lambda \begin{cases} x & x \geq 0 \\ \alpha(\exp(x) - \alpha) & x < 0 \end{cases} \quad (8)$$

Sendo,  $\alpha \approx 1.6733$  e  $\lambda \approx 1.0507$ .

- *Swish*

Proposto por Ramachandran, Zoph e Le (2017), é uma combinação das funções sigmóide e ReLU. Assim como o ReLU, possui um limite superior aberto e um limite inferior fechado, mas contém uma curva suave e não é monótona. Sua suavidade faz com que a função gere melhores resultados de otimização e generalização quando utilizada em redes profundas (Ramachandran, Zoph e Le, 2017; Nwankpa *et al.*, 2018). As principais vantagens da função *swish* são sua simplicidade e alta precisão, pois não sofre com o problema do gradiente de fuga e ainda, consegue uma boa propagação da informação durante o treinamento (Ramachandran, Zoph e Le, 2017).

$$swish(x) = x \cdot \sigma(x) = \frac{x}{1 + e^{-x}} \quad (9)$$

- Métricas

Além das funções de perda, que também são utilizadas como métricas de desempenho, existem outras medidas frequentemente utilizadas em problemas de regressão para medir a precisão do modelo. Essas métricas não influenciam o treinamento e são usadas para medir o desempenho do modelo. O coeficiente

de determinação ( $R^2$ ) é uma métrica comumente usada para determinar o poder preditivo de algoritmos de regressão. Pode ser interpretado como o percentual da variância das variáveis dependentes que pode ser “explicado” pelo modelo. Quanto mais próximo de 1 (100%) o valor do  $R^2$ , melhor será a capacidade preditiva do modelo sobre as variáveis dependentes (Erofeev *et al.*, 2019). É definido pela equação 10, sendo  $\bar{y}_i$  os valores reais,  $\hat{y}_i$  os valores previstos pelo modelo e  $\bar{y}$  a média dos valores de  $y$ :


$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\hat{y}_i - \bar{y})^2}, \quad (10)$$

- Rede Neural Convolutacional (CNN)

Redes Neurais Convolucionais (CNNs) são projetadas para processar dados de entrada em formato multivetorial, representando uma dependência de espaço ou proximidade entre cada valor de entrada (Lecun *et al.*, 1998). Esses vetores podem ser unidimensionais para dados temporais, como sinais e sequências, bidimensionais para imagens e espectrogramas de áudio, ou tridimensionais para imagens de vídeo e volumétricas (Lecun, Bengio e Hinton, 2015). Sua estrutura é muito semelhante às redes neurais artificiais, com a diferença de que utilizam operações matemáticas de convolução em vez de simples multiplicação de matrizes em pelo menos uma de suas camadas (Goodfellow, Bengio e Courville, 2016).

Além da camada convolutacional, eles também podem ter camadas de ativação e *pooling*. Juntas, as camadas transformam os dados de entrada, inferindo quais características são críticas para o problema através do processo de treinamento. Para isso, também utilizam as mesmas técnicas

convencionalmente utilizadas em redes neurais artificiais: gradiente descendente e retropropagação. A figura 11 demonstra o modelo de rede neural convolucional proposto por Lecun *et al.* (1998) para a classificação de dígitos manuscritos, sendo um dos precursores deste tipo de rede.



**Figura 11.** Redes Neurais Convolucionais – CNN (Lecun *et al.*, 1998).

- Camada convolucional


Na camada convolucional é realizada uma operação de convolução na entrada, realizando cálculos com estruturas multidimensionais conhecidas como filtros ou *kernels* (Aggarwal, 2018). Os *kernels* são estruturas menores que a entrada e são aplicados em seções do mesmo tamanho e deslocados até serem aplicados em toda a entrada.

A camada convolucional visa destacar, de alguma forma, as características que influenciam o resultado da rede. Ao classificar imagens de animais, por exemplo, os núcleos podem ser ajustados para destacar características como as patas ou a cauda do animal. Os valores *do kernel* são ajustados durante a descida do gradiente e a retropropagação, ou seja, a rede pode identificar por si mesma quais características são mais relevantes para o

problema que está resolvendo. Essas características podem ser semelhantes às características que o cérebro humano identifica ou podem ser completamente diferentes (Aggarwal, 2018; Heaton, 2015). Na figura 12 a imagem de um cachorro é exibida antes e depois da aplicação da operação de convolução.

- Camada de ativação

A camada de ativação da CNN é muito semelhante às camadas de ativação das redes neurais tradicionais, pois aplica uma função de ativação na entrada. Esta operação não afeta a dimensionalidade da entrada, sendo um mapeamento um para um. Em redes convolucionais é mais comum a utilização de funções de ativação abertas como ReLU ou similares (Aggarwal, 2018).




**Figura 12.** Imagem de um cão antes e depois da convolução (Goodfellow, Bengio e Courville, 2016).

- Camada *pooling*

A camada *pooling* reduz a dimensionalidade da entrada de acordo com alguma função. É semelhante à convolução na medida em que realiza operações sobre frações da entrada, com a diferença de que não possuem filtros, portanto não são afetadas durante o treinamento e, na saída, geram dados reduzidos.

Além de reduzirem o *overfitting*, ao descartarem informações não relevantes que poderiam afetar o resultado, também reduzem o tempo de treinamento ao diminuir a quantidade de dados a serem processados (Aggarwal, 2018).

O tipo de *pooling* mais utilizado é o *max pooling*, onde para cada janela é retornado apenas o valor mais alto (Figura 13). Existem outros, como o *average pooling*, que retornam a média de cada janela, mas não são tão usados como o *max pooling*. Como as camadas de convolução destacam características importantes da entrada, faz mais sentido considerar o valor mais alto em vez da média (Chollet, 2017).



**Figure 13.** *Max pooling* (Géron, 2019).

- Camada densa

Camadas densas são utilizadas no final das redes convolucionais e seu comportamento também é semelhante ao das redes neurais artificiais. Após as operações espaciais da rede convolucional, uma camada de achatamento é aplicada para transformar os dados multidimensionais em apenas uma dimensão, conforme esperado pelas camadas densas (Aggarwal, 2018).

- Camada *dropout*



A camada *dropout* é aplicada sobre outra camada densa e consiste em desativar aleatoriamente, ou descartar, alguma porcentagem de neurônios da camada durante o treinamento (Hinton *et al.*, 2012). A porcentagem de evasão geralmente fica entre 20% e 50%. Essa técnica é utilizada para reduzir o *overfitting*, pois ajuda a rede a se adaptar ao ruído nos dados de entrada, evitando que os dados fiquem viciados ou perfeitos, o que geralmente não acontece com dados reais (Chollet, 2017).

## **CAPÍTULO 3**

### **Manuscrito I**

Neste capítulo será visto o manuscrito “*Petrography and Genesis of Carbonate Rocks from the Barra Velha Formation (Santos Basin, Brazil) and Associated Biogenic Structures*”, encaminhado para a *Cretaceous Research*, o qual encontra-se em fase de correção.

Neste artigo estão descritos, dados petrográficos obtidos durante a descrição das lâminas delgadas utilizados para o reconhecimento dos aspectos minerais, texturais e genéticos que envolvem as rochas que compõe as amostras utilizadas no treinamento da rede neural. Este reconhecimento é importante considerando a heterogeneidade do arcabouço que forma as rochas e nos elementos que compõe o material rochoso os quais influenciam, tanto na porosidade quanto nas permeabilidades do reservatório.

----- Forwarded message -----

De: Cretaceous Research <em@editorialmanager.com>

Date: qua., 9 de jul. de 2023 às 22:35

Subject: Decision on submission to Cretaceous Research - [EMID:a14f36ec0264f9d6]

To: RITA FABIANE GUASINA DE OLIVEIRA <rita.fabi@gmail.com>

CC: ekoutsoukos.editor@gmail.com

Manuscript Number: YCRES-D-22-00238

Petrography and Genesis of Carbonate Rocks from the Barra Velha Formation (Santos Basin, Brazil) and Associated Biogenic Structures

Dear Miss De Oliveira and colleagues,

Good day! I sincerely hope all is well with you, your families, and friends.

Thank you for submitting your manuscript to Cretaceous Research.

We are pleased to inform you that your manuscript has been accepted for publication in Cretaceous Research. However, to proceed with the publication process, some adjustments need to be made. Our reviewers have highlighted a series of issues that must be carefully addressed. Please read the suggestions made by the reviewers attentively, and once you have addressed the indicated issues, kindly submit the revised manuscript to us to continue the process.

Please see below a summary of all reviewer comments and the two "attachments" sent by the reviewers, which can be downloaded from EM®.

We appreciate your submission to Cretaceous Research and thank you for giving us the opportunity to consider your work.

Best regards. Cordially, Eduardo

Please see below a summary of all reviewer comments appended below and in the two "attached" files uploaded by both reviewers, which can be downloaded from EM®.

Best regards. Cordially, Eduardo

Eduardo Koutsoukos, Priv.-Doz., Ph.D Editor-in-Chief Cretaceous Research



25 conferred upon them a prominent status in the global energy industry over recent  
26 decades (Riccomini *et al.*, 2012).

27 The assessment and estimation of these deposits indicate recoverable volumes of  
28 oil and natural gas around 10.6 billion and 16 billion barrels, respectively, with  
29 considerable potential reserves of oil equivalent, ranging from 70 to 100 billion barrels  
30 (Riccomini *et al.*, 2012).

31 Over the years, several paleoenvironmental models have been developed to explain  
32 the genesis of the rock sequence comprising the pre-salt, especially those composing  
33 the reservoir units. Currently, the proposed conceptual paleoenvironmental model  
34 suggests the predominance of a hypersaline to alkaline lacustrine environment  
35 implanted during the Aptian (Moreira *et al.*, 2007; Terra *et al.*, 2010; Wright and Barnett,  
36 2015; Tosca and Wright, 2015; Falcão, 2015; Saller *et al.*, 2016; Herlinger Jr *et al.*, 2017;  
37 Pietzsch *et al.*, 2018; Lima and De Ros, 2019; Pietzsch *et al.*, 2020), with deposits evolving  
38 until the establishment of a frank marine environment, resulting in the formation of an  
39 extensive and thick salt deposit, which serves as a seal for the large oil reserves.

40 The reservoir rocks have a limestone composition and were originated during the  
41 lake phase, being inserted in the Barra Velha Formation, found in the Campos and Santos  
42 Basins (Brazil). These limestone rocks, in turn, present a controversial genesis, with  
43 debates revolving around the possibility of their genesis being microbial or chemical  
44 (Moreira *et al.*, 2007; Terra *et al.*, 2010; Wright and Barnett, 2015; Tosca and Wright,  
45 2015; Falcão, 2015; Saller *et al.*, 2016; Herlinger Jr *et al.*, 2017; Pietzsch *et al.*, 2018; Lima  
46 and De Ros, 2019; Pietzsch *et al.*, 2020).

47 Based on the framework structure of the rock and the texture of its deposits, several  
48 scientists link these rocks to the action of bioherm-generating microorganisms, which

49 would serve as receptacles for oil contained in the deposits, similar to what occurs in  
50 deposits in the Middle East (Moreira *et al.*, 2008; Terra *et al.*, 2010; Muniz *et al.*, 2015;  
51 Rezende and Pope, 2015). However, the same framework structure and the constitution  
52 of the elements that compose the structure of these rocks have led other researchers  
53 to indicate a completely different genesis, associated with the chemistry of lakes,  
54 diagenetic, and hydrothermal processes (Wright and Barnett, 2015; Tosca and Wright,  
55 2015; Falcão, 2015; Saller *et al.*, 2016; Lima & De Ros, 2019).

56 This study aims to provide a contribution to the analysis of the genesis of the  
57 limestone rocks composing the reservoir, based on petrographic data, as well as the  
58 description of certain fossil microorganisms identified in certain constituents of the  
59 framework, still poorly known and described.

60

## 61 **2. Geological Context**

62 The Santos Basin originated during the Gondwana breakup in the Neocomian,  
63 approximately 135 million years ago (Thiede, 2010). This process culminated in the  
64 opening of the Atlantic Ocean and the separation between Africa and South America,  
65 resulting in the formation of a series of basins filled with sedimentary sequences formed  
66 during the rift, post-rift, and drift phases.

67 The Barra Velha Formation (Upper Aptian) corresponds to one of the units formed  
68 during the post-rift phase of the Santos Basin. The sedimentation of this unit occurred  
69 in a context of relative tectonic quiescence with localized faults (Dias, 2005), conditions  
70 that Moreira *et al.* (2007) interpreted as the result of a sag-type basin. This basin is  
71 characterized by a transitional environment from continental to marine, composed of

72 microbial stromatolites, laminites, and microbialites, rich in "talc" and silico-magnesian  
73 clays.

74 On the other hand, Wright and Barnett (2015) and Arienti *et al.* (2018) considered  
75 the sediments composing the Barra Velha Formation as non-marine, consisting of an  
76 association of abiotic carbonates and magnesium silicates precipitated in an alkaline  
77 lacustrine context with highly concentrated waters due to evaporation. Arienti *et al.*  
78 (2018) further recognized facies of "shrubs" limestones, stratified travertines, laminated  
79 microbial limestone, rudstones, grainstones, and clays rich in silica and magnesium.

80 Geochemical data from various studies (Pietzsch *et al.*, 2018; Lima and De Ros, 2019;  
81 Faria *et al.*, 2019; Hosa *et al.*, 2020; Rebelo *et al.*, 2023) consistently assert that the  
82 depositional and mineralogical characteristics observed in the Barra Velha Formation  
83 indicate the alkalinity of lacustrine waters. These lacustrine conditions underwent  
84 periodic modifications with variable increments of meteoric and hydrothermal waters  
85 until approximately 113 million years ago, culminating in the establishment of an  
86 evaporitic environment (Ariri Formation). This environment is composed of halite and  
87 anhydrite, thereby concluding the transitional cycle (Moreira *et al.*, 2007) through  
88 marine incursions during the drift phase.

89

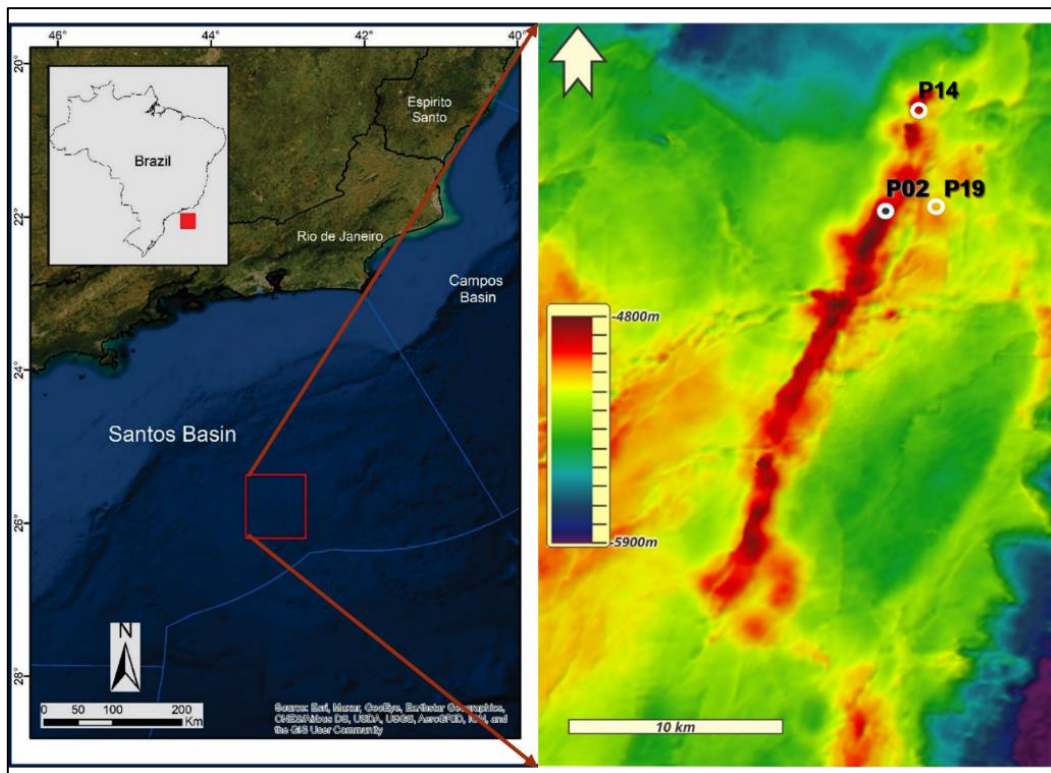
### 90 **3. Materials and Methods**

91 For this study, thin sections of rock obtained from core samples from three wells,  
92 designated as P2, P14, and P19, were analyzed. These wells are situated in an oil field in  
93 the Santos Basin, Brazil (Figure 1). The reservoir corresponds to an elongated

94 topographic high in the NE-SW direction, with wells P2 and P14 located at its summit.  
95 Well core P19 is situated on the eastern flank of the structure.

96 A total of 565 thin sections of carbonate rocks were quantitative petrographically  
97 described (P2: 194 thin sections; P14: 220 thin sections; P19: 149 thin sections). Each  
98 described thin section was quantified at 300 points, and the percentage of its elements  
99 was used for the classification of carbonate facies, diagenetic sequence, and  
100 identification of the porous content of the facies. The mineral content of the described  
101 framework was compared to that previously published for the Barra Velha Formation in  
102 both the Santos Basin and the Campos Basin.

103 The facies described in this study were designated according to the classification  
104 proposed by Gomes *et al.* (2020), which considers the mineralogy and texture of  
105 carbonate facies.



106  
107 **Figure 1.** Location of the study area and wells P02, P14 and P19 in the Santos Basin, Pre-Salt from Brazil

108  
109




110 The potentially biogenic forms were measured, subjected to statistical analysis, and  
111 examined using scanning electron microscopy (SEM) with energy-dispersive X-ray  
112 spectroscopy (EDS).

113

#### 114 4. Optical Petrography

##### 115 4.1 Mineralogy and facies

116 During the descriptions, three main sedimentary and diagenetic mineral  
117 constituents were identified, forming the primary elements of the in situ rock  
118 framework: clay (microcrystalline, massive, or finely laminated texture, with silico-  
119 magnesian or carbonate composition), spherulite (concentricallly radiated carbonate  
120 structure), and fascicular or arborescent calcite termed "shrub" in this study (Figure 2).



121

122 **Figure 2.** Main elements identified under the microscope: A) calcareous clay (Cc); B) spherulite (Sph) in a  
123 matrix of magnesian clay (Cmg); C) calcite spherulite (Sph) and interparticle euhedral dolomite (Dol); D)  
124 shrub (Shr) - primary pore (pp).

125

126 The in situ facies formed mostly by shrubs was classified as shrubstone (Gomes *et*  
127 *al.*, 2020). This facies is characterized by irregular or continuous crusts of calcite with a  
128 fascicular or arborescent habit. The elements composing this facies range from simple

129 and small non-coalescent shapes to compound forms, consisting of clusters of branched  
130 to coalescent elements, intergrown with each other (Figure 3A).


131 On the other hand, spherulitestone (Gomes *et al.*, 2020) is facies composed of fibro-  
132 irradiated and concentric calcite spherulites, with sizes ranging from 0.25 mm to 2 mm  
133 in thin section (Figure 3B). These spherulitic forms are identified associated with clays,  
134 often displacing their thin laminae, or even alongside shrubs. When associated with  
135 shrubs, the spherulites can be elongated and ovoid or even develop forms similar to  
136 fascicular calcites (Lima & De Ros, 2019).

137 The facies composed of mud-sized material are termed mudstone (Gomes *et al.*,  
138 2020) and may be composed of laminated or massive microcrystalline calcite or even  
139 laminated silico-magnesian material (Figure 3C). The laminated silico-magnesian  
140 mudstones are poorly represented and preserved in the described thin sections, with  
141 their occurrences being rare. In most sections, they are identified as protoliths within  
142 spherulitestones, already almost completely replaced by microcrystalline calcite or silica  
143 and euhedral dolomite, the latter developed between the thin clay laminae, now  
144 micritized.


145 The variations among the main facies (spherulitestone, shrubstone, and mudstone)  
146 are numerous, occurring through the blending of the primary constituents (shrub,  
147 spherulite, and mud) in different percentages, as already described by Gomes *et al.*  
148 (2020). This mixture of elements has led to five additional facies, which were identified  
149 throughout the studied interval: shrubby spherulitestone, spherulitic shrubstone,  
150 spherulitic mudstone, mudstone spherulitic, and shrubby spherulitestone with mud.

151 In addition to the in situ facies, intraclastic reworked facies (intrabasinal) such as  
152 grainstones, packstones, and rudstones were described (Gomes *et al.*, 2020),

153 constituted by the reworking of in situ facies (Figure 4A, B, C). The hydrothermal breccia  
 154 facies was identified, corresponding to rocks with a fractured framework, exhibiting  
 155 cataclastic features, where silica minerals predominate with massive microcrystalline  
 156 texture or spherulitic silica forms (Figure 4D, E). Dolomudstone and siliceous mudstone  
 157 (Gomes *et al.*, 2020) were also described, corresponding to massive forms without  
 158 internal structure, unrelated to fractures or veins or breccia aspects, with the former  
 159 composed of microcrystalline or blocky dolomite (Figure 4F).



160  
 161 **Figure 3.** *In situ* facies (Gomes *et al.*, 2020) identified during the thin section descriptions: A) **shrubstone**:  
 162 facies formed by shrub; B) **spherulitestone**: facies predominantly formed by calcite spherulites, and C)  
 163 **mudstone**: facies of laminated microcrystalline carbonate or silico-magnesian composition.  
 164 (Photomicrographs of thin sections).

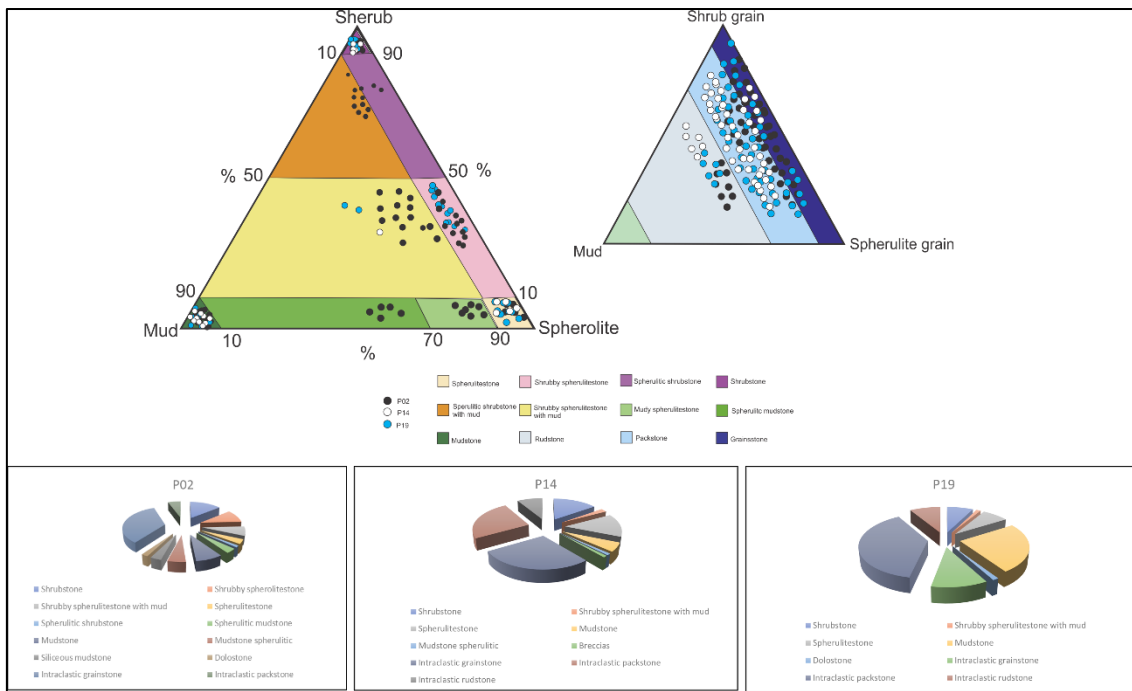


165  
 166 Figure 4. Intraclastic reworked facies: (A) **grainstone** with carbonate intraclasts (intc) and intergranular  
 167 porosity (ip); (B) **packstone** with carbonate intraclasts (intc) and intraparticle porosity (intp); and (C)  
 168 **rudstone** with carbonate intraclasts (intc), moldic porosity (mp), and intraparticle microporosity (micp).  
 169 **Hydrothermal breccias** (D and E) with carbonate intraclasts (intc), microcrystalline quartz (mQz), and  
 170 secondary porosity (sp). **Dolostone** facies (F) composed of euhedral dolomite (dol). (Photomicrographs of  
 171 thin sections).

172  
 173

174 The shrubstone, spherulitestone, and intraclastic grainstone and rudstone facies are  
 175 more common in wells P02 and P14 (Figure 5), which are located at the high topographic  
 176 point and at the top of the sedimentary sequence. Meanwhile, the mudstone facies and  
 177 the intraclastic packstone facies are more common in well P19, situated on the eastern  
 178 flank of the structure. Dolostone is identified in wells P02 and P19, while hydrothermal  
 179 breccia occurs more commonly in well P14 (Figure 5).

180




181  
182  
183  
184

**Figure 5.** Classification of facies according to Gomes et al. (2020) and distribution of recognized facies in thin sections in wells P02, P14, and P19.

185 According to the textural features identified during the petrographic description,  
186 the sequence of formation of *in situ* facies occurs in four stages: 1) deposition of silico-  
187 magnesian clay; 2) partial replacement of clay and neof ormation of calcite spherulites  
188 between the clay laminae; 3) shrubs as isolated and non-coalesced crystals; and 4)  
189 coalesced crusts of shrubs.

190 Regarding porosity, secondary porosity generally predominates in the *in situ* facies  
191 (mudstone, spherulitestone) and in the reworked intraclastic facies (grainstone,  
192 packstone, and rudstone), while primary porosity is restricted to shrubstone facies  
193 (Figure 6).

194




195  
196  
197  
198  
199  
200

**Figure 6.** Types of pores identified in thin rock sections: (A) intercrystalline primary porosity (ip); (B) primary porosity (pp), secondary interparticle (ip), and intraparticle (intp) porosity; C) microporosity (micp); D) fracture porosity (fp); F) moldic porosity (mp); and E) vugular (vug) and intercrystalline (ip) porosity.

201  
202  
203  
204  
205  
206

Secondary porosity, generated by partial or total dissolution of the primary constituents that make up the framework, can be intercrystalline, intracrystalline (interparticle and intraparticle for reworked facies), and moldic (Figure 6). Intercrystalline (or interparticle) porosity accounts for 70% of the total porosity. In addition to these porosities, fracture porosity, microporosities, and *vugs* (pore with a diameter greater than 1 mm) were also recognized (Figure 6).

207 Fully or partially filling the porosity, commonly observed are hexagonal, blocky, or  
208 saddle-shaped dolomite; microcrystalline silica in prismatic or spherulitic crystals; calcite  
209 as individual crystals, in fringes, or mosaics (Figure 7). Occasionally, pyrite and magnesite  
210 are also present. Recrystallizations of calcite crystals, with or without optical orientation,  
211 are also identified, particularly in the shrubstone facies.



212 **Figure 7.** Intercrystalline/interparticle secondary diagenetic constituents: A) microcrystalline quartz  
213 (mQz), euhedral dolomite (Dol); B) euhedral dolomite (Dol) and fringing dolomite (fDol); C) spherulitic  
214 microcrystalline quartz (mQz), euhedral dolomite (Dol); blocky quartz filling primary porosity (blQz); E)  
215 microcrystalline quartz (mQz); F) fringing dolomite (fDol) and saddle-shaped dolomite (sDol).  
216

217  
218  
219  
220  
221

## 222 4.2 Biogenic structures

223 In addition to the described mineral content, 85 thin sections revealed sui generis  
224 structures, resembling biogenic structures. These were identified based on their  
225 morphological characteristics observed under the optical microscope.

- 226 • Filamentous forms


227 The filamentous forms (Figures 8A, B, C, and D) are characterized by elongated  
228 elements, partially filled, associated with carbonate crystals. These forms were  
229 identified in wells P02, P14, and P19, with a higher frequency in well core P02. They are  
230 associated with fascicular (*shrubs*) calcite crystals in the shrubstone facies or with  
231 fragments of fascicular calcite in reworked facies (grainstones, rudstones).

232 The filamentous forms have thickness ranging from 3.12 $\mu$ m to 8.60 $\mu$ m (Graph 1A),  
233 and occasionally, rows of nodules were observed inside the filamentous structure using  
234 *scanning electron microscopy* (SEM) (Figure 9A). During the analysis of the filaments by  
235 *energy-dispersive X-ray spectroscopy* (EDS), residues of carbon and the absence of  
236 calcium were identified within the filamentous structure (Figure 9B, C, D).

- 237 • Circular to oval forms

238 Circular and oval forms (Figures 8E, F, G, H) were identified in all four wells analyzed,  
239 both within fascicular (shrub) calcites in shrubstone facies and in reworked facies  
240 (grainstone and rudstone) within fragments of fascicular calcite. In total, 155 forms were  
241 measured, with predominance of elements having average diameters ranging from  
242 116 $\mu$ m to 199 $\mu$ m (Graph 1B).

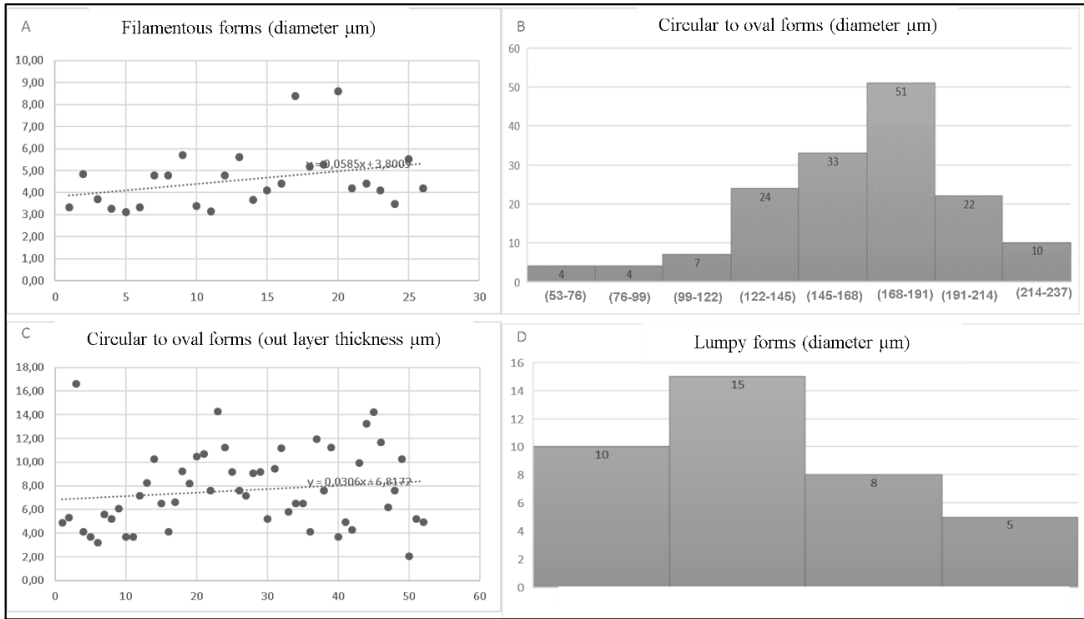




243

244 **Figure 8.** Images of microforms identified in thin sections. (A) **Filamentous forms** in intraclast of shrub in grainstone (scale: 20 µm); (B) detail (white dashed line in photo A)  
 245 of **filamentous forms** (scale: 50 µm); other **filamentous forms** in shrub such as grainstone intraclast (C) and undifferentiated limestone intraclast (D), both on a 50 µm scale.  
 246 (E, F) **circular to oval forms** within shrub, in situ facies, natural light and polarized light, respectively (scale: 500 µm); (G) **circular to oval forms** with external wall, within  
 247 grainstone shrub intraclast (scale: 50 µm); (H) various **circular and oval forms** within limestone intraclast (scale: 100 µm). (I) **Lumpy forms** within shrub, in situ facies (scale:  
 248 500 µm); (J) detail of **lumpy form** inside *shrub* (white square photo I), scale: 50 µm. (K, L) **Segmented forms** in undifferentiated *limestone intraclast*, reworked facies (scale:  
 249 50 µm).


250



251

252 **Graph 1.** A) Thickness of filamentous forms (µm). B) Diameters of circular and oval forms (µm). C) Thickness of  
253 external layers of circular and oval forms (µm). D) Diameter of lumpy forms (µm).

254




255

256 **Figure 9.** A) SEM image of filamentous form; the arrow indicates calcite nodules inside the form (sample 1). B)  
257 Image obtained in EDS (sample 2). Red traces (arrows) indicate carbon residues within the grooves (C), and in  
258 the calcium range (D), at the same points where carbon residues were present, no calcium element was recorded.

259

260

261 Among the measured forms, 52 had an external wall (Figure 7G), with an average thickness  
262 of 7.63 $\mu\text{m}$  (Graph 1C). SEM/EDS analyses indicated that, although the circular to oval form is  
263 composed of calcium, the external layer surrounding it consists solely of carbon (Figure 10).




264  
265 **Figure 10.** A) SEM image of oval form showing in detail the external layer. B) Image obtained in EDS. (C and D)  
266 The images indicate the predominance of carbon (C) in the external layer that forms the shape and the absence  
267 of calcium (D) in the same layer.  
268

269 • Lumpy forms

270 These occurrences present circular forms with an irregular and protruding appearance,  
271 like a *blackberry* (Figure 8I, J), identified in well P19 and more commonly in well P02. They  
272 occur both within fascicular (shrub) calcites in the shrubstone facies and in fragments of  
273 fascicular calcite crystals in reworked facies (grainstone, rudstone), associated or not with  
274 filamentous and circular to oval forms.

275 A total of 38 nodular forms were measured, with diameters ranging from 53 $\mu\text{m}$  to 132 $\mu\text{m}$   
276 (Graphic 1D), and although the *blackberry* form is visible under the optical microscope, it was  
277 not observed under the SEM (Figure 10). Inside this form, small framboidal pyrites can be  
278 found, while superficially the form is covered by a film of clayey composition (Figure 11).



279  
280 **Figure 11.** A) SEM image of lumpy form. EDS images show the occurrence of aluminum (B), silicon (C), potassium  
281 (D), and the absence of the calcium element (E).  
282

- 283
- 284 • Segmented forms

285 Composed of multiple concentric rings (Figure 8K, L), the segmented form was abundantly  
286 identified in only one thin section from well 19. In total, 23 forms were identified in the section  
287 within undifferentiated carbonate fragments, in the reworked grainstone facies. Of the  
288 visualized forms, the largest identified structure was composed of 24 segments, whose rings,  
289 arranged perpendicular to its longitudinal axis, had an average thickness of 14.56  $\mu\text{m}$ . In plain  
290 view, the structure appears as a concentric form composed of two circular rings. When  
291 analyzed under the SEM, no significant response was observed.


## 292

### 293 5. Discussion

294 Since the early publications on the pre-salt deposits of the Santos and Campos Basins  
295 (Barra Velha and Macabu formations, respectively), the origin of the described carbonates in  
296 these units has been associated with microbial processes (Dias, 2005; Moreira *et al.*, 2008;  
297 Terra *et al.*, 2010; Muniz *et al.*, 2015; Rezende and Pope, 2015). However, recent studies  
298 indicate that the genesis of the Barra Velha Formation is predominantly chemical (Wright and

299 Barnett, 2015; Arienti *et al.*, 2018; Pietzsch *et al.*, 2018; Lima & De Ros, 2019; Faria *et al.*, 2019;  
300 Hosa *et al.*, 2020; Rebelo *et al.*, 2023).


301 The stromatolitic structures (bioherms) correspond to a form of biogenic construction  
302 (Sallun Filho, 1999) developed as a product of a microbial/sedimentary association, from the  
303 laminar deposition of bacterial microorganisms (cyanobacteria - photosynthetic bacteria) on  
304 a substrate, involving sediment particles (Figure 12), synthesizing, fixing, and cementing  
305 calcium carbonate (Riding, 2002, Winge *et al.*, 2021).



306  
307 **Figure 12.** Schematic illustration of bioherm formation: cyanobacteria form a succession of layers composed of  
308 filaments and entangled sediments to produce a cryptocrystalline carbonate bioconstruction (Image Knoow.net,  
309 2018).  
310

311 Coalescent structures, irregular and columnar branching structures, decimetric to  
312 metric in scale, finely laminated composed of cryptocrystalline limestone (Figure 13),  
313 characterize the mineralization of benthic microbial communities (bioherms) (cf. Burne and  
314 Moore, 1987; Riding 2000).

315



316

317

318

319

**Figure 13.** Images of microbial stromatolitic structures. (A, B) lateral section of a stromatolite, brown cryptocrystalline carbonate C) lateral section of a fossil stromatolitic structure; D) partially eroded in situ stromatolite (Photos C and D: Salt Lake, Utah, USA). (Image A and B: <https://edisciplinas.usp.br/pluginfile.php>.

320

321

322

323

324

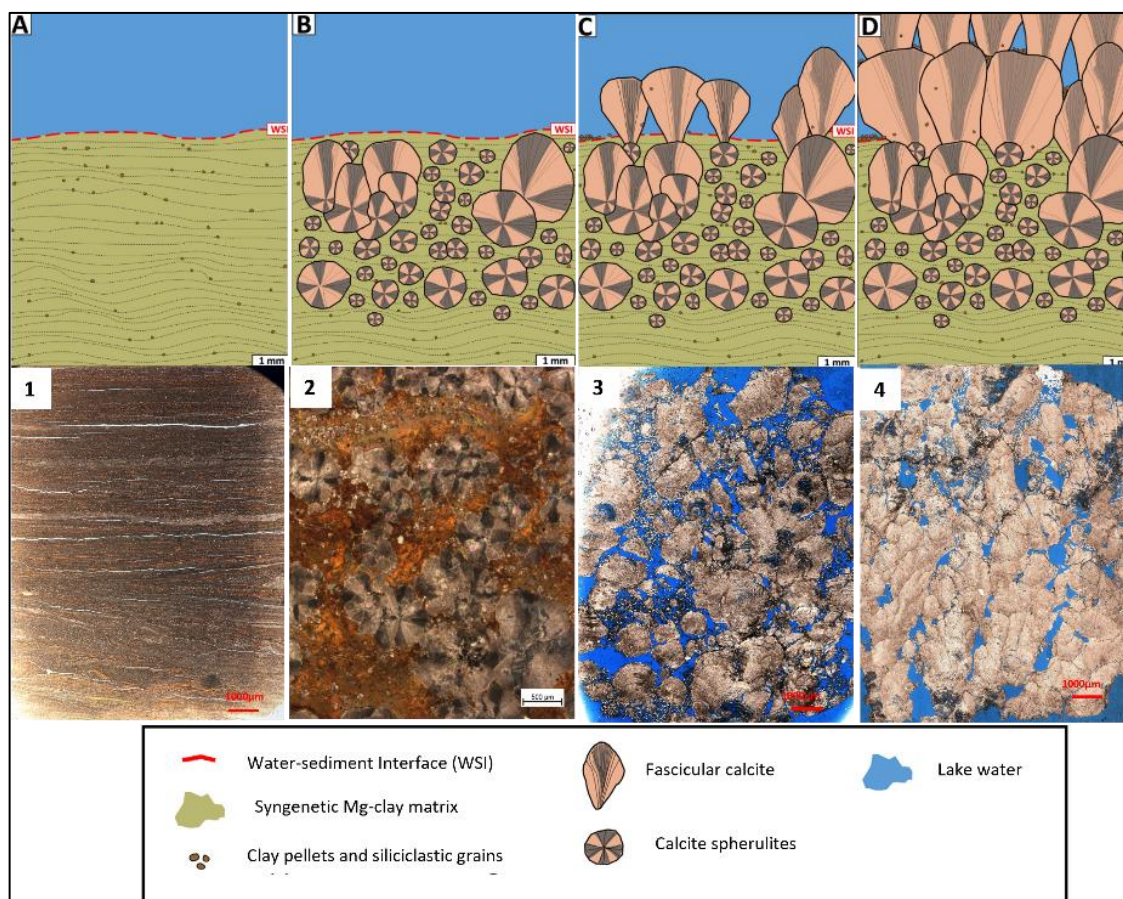
325

326

327

328

During petrographic descriptions, no structures related to bioherms or potentially related to them were identified, even in reworked facies. The material described in thin sections is similar to that previously described for the Barra Velha Formation by Lima & De Ros (2029) and Gomes *et al.* (2020) (Figure 14): crystalline bush-like or fascicular forms of calcite. The shrubs may or may not form continuous crusts composed of single crystals arranged side by side, or branched or coalescent crystals, which are related to the product of abiotic chemical precipitation (*sensu* Burne and Moore 1987).



329

330 **Figure 14.** Formation stages of *in situ* facies in the Barra Velha Formation in the Campos Basin (A, B, C, and D),  
 331 adapted from Lima & De Ros (2019) and for the Santos Basin as described in this study: (1) deposition of silico-  
 332 magnesian clay; (2) partial replacement of clay and neof ormation of calcite spherulites between clay laminae;  
 333 (3) shrubs as isolated non-coalesced crystals; (4) coalesced crusts of shrubs.

334

335 According to Wright and Barnett (2015), the growth of dense, fibrous calcite with  
 336 branching patterns ranging from millimeters to centimeters (up to 20 mm), similar to the  
 337 shrubs identified in thin sections, are generated from the asymmetrical growth of spherulites,  
 338 with these facies also interpreted as equivalent to travertines (cf. Chafetz and Guidry, 1999;  
 339 Fouke, 2011).

340 The shrubstone facies is important facies in terms of oil accumulation for the pre-salt  
 341 reservoir, ranking below only the intraclastic grainstone and rudstone facies. However, the  
 342 origin of this facies occurs from the deposition of silico-magnesian clay and subsequent  
 343 formation of spherulites originated from the partial dissolution of these clays already in an

344 eodiagenetic context, a sequence verified in the described thin sections and also recorded in  
345 the literature used (Lima & De Ros, 2019). Tosca and Wright (2014) and Wright and Barnett  
346 (2015) indicated that the magnesian clays originated from a hydrated gel rich in Si-Mg, which  
347 evolved into stevensite, kerolite, talc, and other mineral phases, in a highly alkaline lacustrine  
348 and palustrine environmental context (Rehim *et al.*, 1986; Pozo and Casas, 1999). The  
349 deposition of this silico-magnesian clay would have occurred under specific conditions of  
350 salinity, temperature, ionic content, and pH of 10 (Jones, 1986; Tosca and Masterson, 2014).  
351 In the mudstone facies analyzed in this study, few samples of silico-magnesian mudstone were  
352 described. In most thin sections where the protolith corresponded to silico-magnesian clay,  
353 the primary mineralogy is totally or partially replaced or recrystallized by other elements, such  
354 as spherulites, dolomite, and even microcrystalline calcite, indicating, similarly to other  
355 authors, an authigenic genesis and the high reactivity of this constituent.

356 Studies indicate that the formation of sub-micrometer spherulites is associated with  
357 microbial activity (Braissant *et al.*, 2003; Spadafora *et al.*, 2010), the spherulites described for  
358 the Barra Velha Formation have dimensions ranging from 0.25 mm to 2 mm and seem to  
359 displace the fine layers of silico-magnesian clay during their genesis García Ruiz (1998) and  
360 Meister *et al.* (2011) describe that under alkaline conditions with high concentrations of silica  
361 and magnesium, coalescent spherulitic forms of calcite tend to form. The low  
362 representativeness of silico-magnesian clay samples and the texture of displacement of clay  
363 lamellae where spherulites are described indicate that these originated from the dissolution  
364 of clays, still in an eodiagenetic context.

365 The occurrence of facies with amalgamated features formed by the coalescence of  
366 fascicular calcites in the shrubstone facies indicates sporadic supersaturation of this element in



367 the aqueous medium, a fact that may be related to influxes of enriched underground aquifers  
 368 or even hydrothermal flows (Pietzsch *et al.*, 2018; Strugale *et al.*, 2023).

369 The textural relationships identified in thin section among the mineral constituents  
 370 indicate that primary porosity is poorly preserved, being practically restricted to the  
 371 shrubstone facies, while in the other facies, secondary porosity predominates, indicating  
 372 dissolution and recrystallization processes operating both in eodiagenesis and  
 373 mesodiagenesis. The occurrence of blocky silica and large euhedral crystals, saddle dolomite,  
 374 barite, and fractures filled with microcrystalline silica (in the hydrothermal breccia facies)  
 375 demonstrates that these rocks have been subjected to various episodes where hydrothermal  
 376 fluids were associated with their formation, with these fluids being decisive for the  
 377 reorganization of the rock's porosity: dissolving, precipitating, and recrystallizing various  
 378 mineral phases (Table 1).

379 **Table 1.** Diagenetic processes and products identified during petrography of rocks from the Barra Velha  
 380 Formation, Santos Basin, in well core P02, P14, and P19.

Diagenetic processes and products	Eodiagenesis	Mesodiagenesis	Hydrothermal
Calcite spherulites	————		
Framboidal pyrits	- - -		
Dolomite replacing magnesian silico clay	- -		
Dissolution of magnesian clay	- -		
Dolomitization	————	- -	
Euhedric dolomite filling porosity	————	- -	
Crustiform calcite spherulites partially replaced by silica	————	- - -	
Dissolution of crustiform calcite spherulites	- - -		
Fracturing		- - - - - - - -	-
Mechanical compaction / chemical compaction		- - - -	
Silicification - chalcedony		————	
Hydrothermal dissolution		————	
Saddle dolomite filling pore			- - - - .
Microcrystalline quartz filling pore			- - - - .
Macrocrystalline calcite filling pore			- - - - .
Barite			- - - - .
Pyrite			- - - - .
Betumen			- -

381

382 From the statistical analysis of petrographic parameters on thin sections, the main  
 383 poroperm attributes that positively or negatively influence the percentage of porosity and  
 384 permeability of different facies were identified (Table 2).

385 Table 2. Relationship between poroperm attributes identified in thin section x facies.

Facies	% Intercrystalline cement (calcite and dolomite)	% Intercrystalline silica	Poro type	Vug	Poro conection	Amalgamated texture	Packaging	Contact between grains
Shrubstone	Little influence	Influence	Intercrystalline	Little influence	Influence	Influence	Not applicable	Not applicable
Spherulitestone	Influence	Influence	Intercrystalline and intracrystalline	Influence	Influence	Not applicable	Not applicable	Not applicable
Mudstone	Little influence	Influence	Moldic, lamellar	Influence	Influence	Not applicable	Not applicable	Not applicable
Reworked	Influence	Influence	interparticle intraparticle, moldic	Influence	Influence	Not applicable	Influence	Influence
Dolostone	Not applicable	Not applicable	Intercrystalline and intracrystalline	Not applicable	Not applicable	Not applicable	Not applicable	Not applicable
Breccia hydrothermal	Not applicable	Influence	Moldic, intercrystalline, intracrystalline	Influence	Not applicable	Not applicable	Not applicable	Not applicable

386

387 Among the attributes that positively influence the increase in rock permeability, one  
 388 can mention the occurrence of vugs, pore connections, and intercrystalline and intergranular  
 389 porosities. The percentages of intercrystalline dolomite and calcite directly influence the void  
 390 percentage of different facies, as well as permeability variations.

391 The occurrence of interstitial microcrystalline silica, while it can completely obliterate  
 392 the framework of different facies, can also increase porosity by dissolving primary elements.  
 393 On the other hand, the amalgamated texture identified in the shrubstone facies decreases  
 394 interconnections and, consequently, permeability.

395 Both interparticle constituents identified and silica content, as well as amalgamated  
 396 facies, appear to be directly related to mesodiagenetic and hydrothermal processes in

397 deposits, indicating a positive correlation between the chemical genesis of these rocks and  
398 the heterogeneity of permeabilities for each facies.

399           Based on geochemical data, Herlinger Jr *et al.* (2017), Pietzsch *et al.* (2018; 2019), Lima  
400 & De Ros (2019), and Farias *et al.* (2019) point to a hydrothermal influence on the pre-salt  
401 deposits. These CO<sub>2</sub>-rich fluids would ascend through faults and fractures to the surface of the  
402 paleolake, initially from a felsic mantle during the rifting phase, and later with rift evolution,  
403 from the volcanic basement (Pietzsch *et al.*, 2018; Farias *et al.*, 2019). Alvarenga *et al.* (2016)  
404 and Vieira (2021), through the analysis of seismic lines from the Barra Velha Formation,  
405 indicate fault systems that would serve as conduits for the flow of hydrothermal fluids with  
406 the formation of vents to the base of the paleolake in the Campos and Santos basins,  
407 respectively.


408           The concept of active tectonics in the basin during the deposition of the Barra Velha  
409 Formation is supported by Adriano *et al.* (2022), whose seismic data point to fault reactivation,  
410 while Strugale *et al.* (2023) confirms that hydrothermal fluids would ascend through faults  
411 concurrently with the deposition of the upper Barra Velha Formation.

412           Limestone rocks associated with fault zones have been commonly described  
413 worldwide, such as in the alkaline lakes Mono Lake and Pyramid Lake in the United States and  
414 in Pamukkale, Turkey. In Pyramid Lake, for example, shrubstone limestones (Figure 15 A) are  
415 recognized internally filling carbonate mound structures. These carbonate crusts, when  
416 analyzed macroscopically, texturally resemble the shrubstone facies identified in thin sections  
417 (Figures 15 B, C and D).

418           Current occurrences of cyanobacteria in alkaline water environments, linked to  
419 hydrothermal fluids, are observed in various locations such as Mono Lake and Bridgeport in

420 the state of Nevada (USA), and in the Yunnan province in China (Souza-Egipsy *et al.*, 2005;  
421 Stam *et al.*, 2010; Song *et al.*, 2012; Keshari *et al.*, 2022). In Bridgeport, for instance, a set of  
422 aligned faults allows hydrothermal fluids to ascend to the surface, precipitating prism-shaped  
423 crustiform limestones under subaerial conditions and promoting the development of  
424 microbial mats associated with these fluids, indicating the coexistence of these organisms and  
425 the alkaline hot fluids (Figure 16).

426



427


428 **Figure 15.** A) Photo of limestone crustiform shrub pebble (Pyramid Lake, Nevada, USA); (B and C) Photomontage  
429 of thin section of shrubs crust (sh), under polarized light (B) and natural light (C), in shrubstone facies, well core  
430 P2 (Barra Velha Formation, Santos Basin); D). (Cross-section of a macroscopic sample core of the shrubstone  
431 facies with shrub forms (sh), Barra Velha Formation (Santos Basin).

432

433            Additionally, associated with acidic hydrothermal vents, giant forms of filamentous  
434 and helical bacteriomorphs are described (Schulz-Vogt, Angert & Garcia-Pichel, 2007; Salman  
435 *et al.*, 2013; Ionescu *et al.*, 2023).

436            Biogenic forms identical to those described in this study have been reported and  
437 attributed to bacterial organism fossils in rocks of similar ages to pre-salt rocks in sedimentary  
438 deposits in Brazil, such as the filamentous forms identified in intraclasts composing sediments  
439 in Lagoa Salgada (RJ, Brazil) by Fairchild *et al.* (2015), and the circular and oval forms identified  
440 in thin sections of limestone rocks from the Crato Member (Santana Formation, Araripe Basin)  
441 by Bardola (2015) and Rodrigues (2015).

442



443

444 **Figure 16.** Vent is in Bridgeport, Nevada, USA (A). From the vent (A), crustiform limestones precipitate (arrow).  
445 In photo B, the arrow indicates the precipitation of crustiform limestone in the form of a floor where the  
446 hydrothermal water flow runs; on the crustiform floor, taking advantage of the hydrothermal water flow, a  
447 microbial mat develops. In photo C, microbial mat and organic clay developed in small basins that accumulate  
448 hydrothermal water generated from the vent.

449

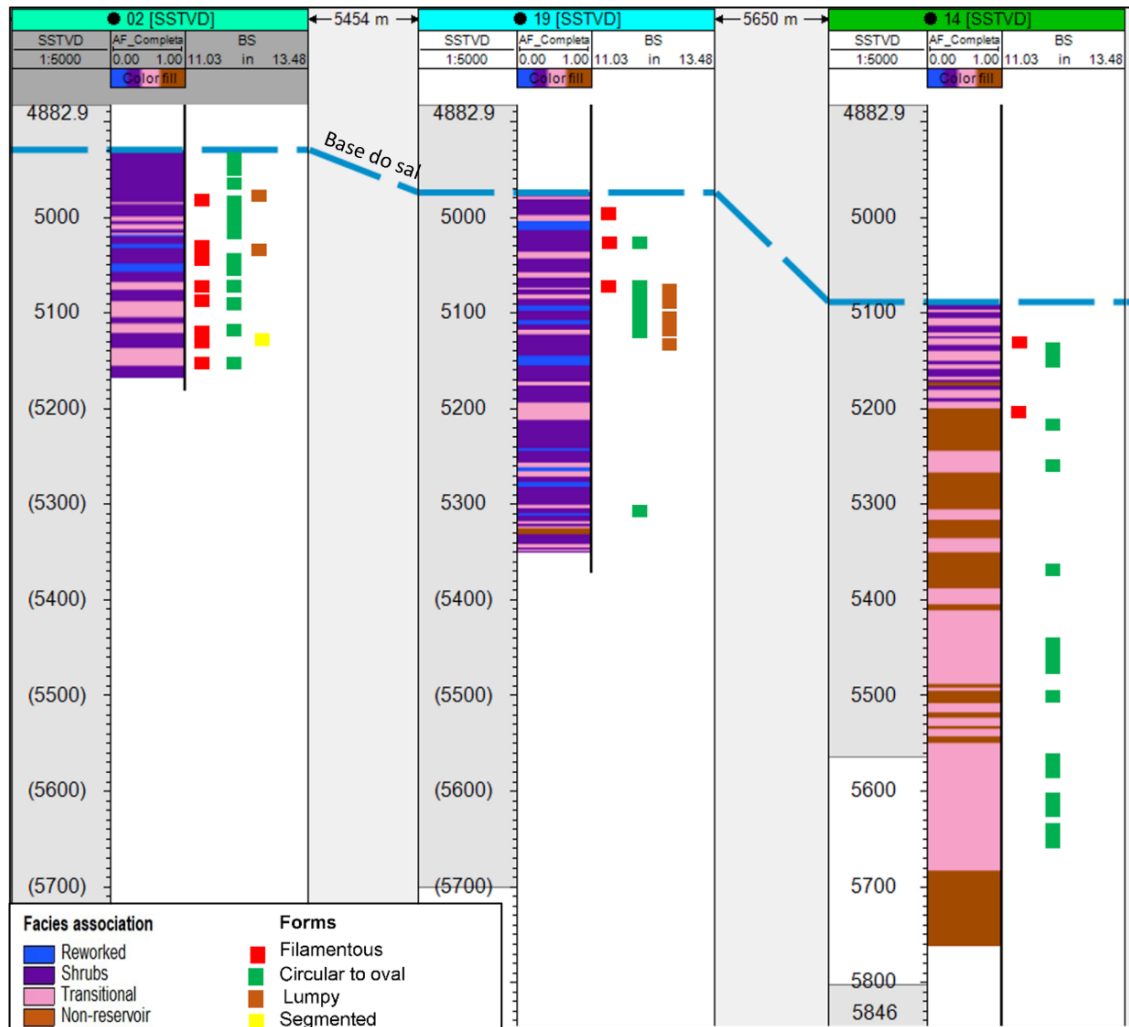
450 Similarly, the segmented structure identified in the described samples was also  
451 identified by Barili *et al.* (2019) in samples from the Barra Velha Formation in the pre-salt,  
452 attributed to an organic form like cyanobacteria (Sharma and Shukla, 2012). This form, similar  
453 to *Obruchevella* sp., extinct in the Precambrian, would have a similar shape to bacteria such  
454 as *Spirulina* or *Arthrospira*, the latter commonly found in alkaline lakes (Vonshak, 1997).

455 On the other hand, the nodular forms described in this study have previously been  
456 associated with clay nodules encapsulated within growing shrubs (Schrank *et al.*, 2024).  
457 However, some researchers have recently suggested that certain organisms (cyanobacteria)  
458 found in alkaline environments have the ability to develop a clay envelope during their lifetime  
459 within the endolithic biofilm during authigenesis, obliterating the porous spaces of the  
460 cytoplasm and damaging the structure of microfossils while preserving the clay envelope (Joel,  
461 2016; Souza-Egipsy *et al.*, 2005; Charlaftis *et al.*, 2023).

462 The occurrence of different bacteriomorphs within fascicular calcite crystals leads us  
463 to believe that such biogenic forms correspond to fossils of organisms that coexisted during  
464 the early eodiagenetic nucleation of crystalline forms of calcite but ended up being trapped  
465 within the crystals as they expanded, generating fascicular or arborescent calcites.

466 The fossilization events of such organisms during the coalescence of calcite crystals are  
467 evidenced in shrubstone facies or even in reworked facies when shrubstone intraclasts are  
468 observed. Observing the distribution of intervals where bacteriomorphs were identified in thin  
469 section (Figure 17), it's apparent that such records are cyclic, which may be associated with  
470 periods of pulses of hydrothermal fluids from the reactivation of associated faults. This  
471 hypothesis is supported by publications that have identified vent-like structures linked to fault  
472 zones in the Barra Velha Formation through seismic data (Alvarenga *et al.*, 2016; Vieira, 2021),  
473 through geochemical studies conducted by various authors indicating that hydrothermal fluids

474 contributed to the lake's chemistry (Pietzsch *et al.*, 2018; Lima & De Ros, 2019; Strugale *et al.*,  
 475 2023), and by the record of active faults even during the deposition period of the Barra Velha  
 476 Formation (Adriano *et al.*, 2022; Strugale *et al.*, 2023).



477  
 478 **Figure 17.** Distribuição das formas biogênicas nas fácies *in situ* e retrabalhadas nos poços P02, P14 e P19.

479

480 In addition to the encapsulated biogenic forms, hydrothermal breccias, differentiated  
 481 siliceous fluids, and saddle dolomite serve as evidence that hydrothermal events occurred at  
 482 different stages in the genesis of the rocks of the Barra Velha Formation, suggesting that the  
 483 precipitation of major minerals was influenced by the supersaturation of the aqueous medium  
 484 due to various hydrothermal inflows at the base of the lake, increasing the availability of  
 485 calcium, magnesium, and silica. This hypothesis will be explored in new studies to be

486 conducted, integrating data obtained through petrography, lithogeochemical profiles, and  
487 seismic data. Similarly, further studies should be developed to ensure that the events  
488 culminating in the encapsulation and fossilization of organisms were local events associated  
489 with vents, or considering occurrences documented by various authors (Barili *et al.*, 2019;  
490 Fairchild *et al.*, 2015; Bardola, 2015; Rodrigues, 2015), it might represent a record of a larger  
491 event on a regional scale.

492

## 493 **6. Conclusions**

494 Petrographic analysis of thin sections from well samples located in a carbonate reservoir  
495 of the Barra Velha Formation in the Santos Basin revealed that the mineralogy and identified  
496 facies are similar to rocks previously described by Lima and De Ros (2019) for the same unit in  
497 the Campos Basin. The observed textural relationships among the described facies indicate  
498 that the formation of the main elements composing the mineral structure of the rock occurred  
499 during eodiagenesis, from silico-magnesian clayey sediments. Both the described mineralogy  
500 and the identified biogenic forms in the thin sections suggest, however, that these rocks have  
501 their chemical origin associated with pulses of hydrothermal fluids, which contributed to the  
502 concentration of salts in the lake waters, intensifying the precipitation of carbonate and  
503 siliceous minerals, thus causing the fossilization of microbial organisms within coalescent  
504 calcite crystals.

505

## 506 Acknowledgment

507 This work was supported by the UNISINOS-PETROBRAS Cooperation Agreement  
508 (Contract: 5900.0113025.19.9/SAP No. 4600593919 and Contract: 2023/00130-3 /SAP No.



509 4600675263). Special thanks to Dr. Gerson Fauth, Dr. Renata Guimarães Netto, and Dr. Vitor  
510 Hugo Valiatti for their valuable discussions. Our gratitude also goes to Dr. Ilana Lehn and  
511 geologist Monique Bordinon for laboratory guidance, and to geologist Vinícius Lôndero and  
512 geology student Bruna Poatskievick for formatting the figures.

513

514 **Bibliographic references**

- 515 Abed, R.M., Dobrestov, S., Al-Kharusi, S., Schramm, A., Jupp, B. and Golubic, S., 2011.  
516 Cyanobacterial diversity and bioactivity of inland hypersaline microbial mats from a  
517 desert stream in the Sultanate of Oman. *Fottea*, 11(1), pp.215-224.
- 518 Adriano, M. S., Figueiredo, J. P., Coelho, P. H. G. R., & Borghi, L. (2022). Tectonic and  
519 stratigraphic evolution of the Santos Basin rift phase: New insights from seismic  
520 interpretation on Tupi oil field area. *Journal of South American Earth Sciences*, 116,  
521 103842.
- 522 Alvarenga, R. S., Iacopini, D., Kuchle, J., Scherer, C. M. S., & Goldberg, K. (2016). Seismic  
523 characteristics and distribution of hydrothermal vent complexes in the Cretaceous  
524 offshore rift section of the Campos Basin, offshore Brazil. *Marine and Petroleum Geology*,  
525 74, 12-25.
- 526 Arienti, L. M., Souza, R. S., Viana, S., Cuglieri, M. A., Silva, R. P., Tonietto, S., ... & Gil, J. A. (2018).  
527 Facies association, depositional systems, and paleogeographic models of the Barra Velha  
528 Formation, pre-salt sequence—Santos Basin, Brazil. In AAPG ACE 2018.
- 529 Azerêdo, A.C., Duarte, L.V. and Silva, A.P., 2021. The challenging carbonates from the Pre-Salt  
530 reservoirs offshore Brazil: facies, palaeoenvironment and diagenesis.  
531 *Journal of South American Earth Sciences*, 108, p.103202.
- 532 Bardola, T.P. 2015. Caracterizacao paleoambiental dos carbonatos microbiais do Membro  
533 Crato, Formacao Santana, Aptiano-Albiano da Bacia do Araripe. M.Sc. Thesis,  
534 Universidade Federal do Rio Grande do Sul, Brazil. 147pp.
- 535 Barili, R., Marconatto, L., Oliveira, D.M. and De Ros, L.F. , 2019. Colloid microfossils  
536 (cyanobacteria?) from Brazil Pre-Salt. Bathurst Meeting Mallorca. 16th International  
537 Meeting of Carbonate Sedimentologists. Theme 4: South Atlantic Pre-Salt Carbonates  
538 and Potential Analogs. pp. 164.
- 539 Burne, R. V., & Moore, L. S. (1987). Microbialites: organosedimentary deposits of benthic  
540 microbial communities. *Palaios*, 241-254.
- 541 Carramal, Nívea G., Daniel M. Oliveira, Alessandra SM Cacula, Matheus AA Cuglieri, Natasha  
542 P. Rocha, Samuel M. Viana, Sérgio LV Toledo, Saulo Pedrinha, and Luiz F. de Ros.

543 "Paleoenvironmental insights from the deposition and diagenesis of Aptian pre-salt  
544 magnesium silicates from the Lula Field, Santos Basin, Brazil." *Journal of Sedimentary*  
545 *Research* 92, no. 1 (2022): 12-31.

546 Carvalho, A. M. A., Hamon, Y., De Souza Jr, O. G., Carramal, N. G., & Collard, N. (2022). Facies  
547 and diagenesis distribution in an Aptian pre-salt carbonate reservoir of the Santos Basin,  
548 offshore Brazil: A comprehensive quantitative approach. *Marine and Petroleum Geology*,  
549 141, 105708.

550 Catto, B., Jahnert, R.J., Warren, L.V., Varejao, F.G. and Assine, M.L., 2016. The microbial nature  
551 of laminated limestones: Lessons from the Upper Aptian, Araripe Basin, Brazil.  
552 *Sedimentary Geology*, 341, pp.304-315Crispino & Sant'Anna, 2006.

553 Chafetz, H. S., & Guidry, S. A. (1999). Bacterial shrubs, crystal shrubs, and ray-crystal shrubs:  
554 bacterial vs. abiotic precipitation. *Sedimentary Geology*, 126(1-4), 57-74.

555 Charlaftis, D., Jones, S. J., Grimm, L., & Kappler, A. (2023). Interdependence between bacterial  
556 EPS and early grain coat development. *Terra Nova*, 35(4), 241-249.

557 Crispino, L.M.B. and Sant'Anna, C.L., 2006. Cianobactérias marinhas bentônicas de ilhas  
558 costeiras do Estado de São Paulo, Brasil. *Brazilian Journal of Botany*, 29, pp.639-656.

559 Dias, J. L., 2005. Tectônica, estratigrafia e sedimentação no Andar Aptiano da margem leste  
560 brasileira. *Boletim de Geociências da Petrobras*, v. 13, n. 1, p. 7 -25.

561 Dorobek, Steve, Leo Piccoli, Brian Coffey, and Aaron Adams. "Carbonate rock-  
562 forming processes in the Pre-salt "sag" successions of Campos Basin, offshore Brazil:  
563 evidence for seasonal, dominantly abiotic carbonate precipitation, substrate controls,  
564 and broader geologic implications." In AAPG Hedberg Conference "Microbial Carbonate  
565 Reservoir Characterization" Houston Texas. 2012.

566 Fairchild, T.R., Rohn, R. and Dias-Brito, D., 2015. Microbialitos do Brasil do Pré-Cambriano ao  
567 Recente: um atlas.

568 Falcão, L. C. (2015). Estudo faciológico de um intervalo aptiano do poço SB-1 (Bacia de Santos)  
569 e sua comparação com travertinos quaternários de San Juan, Argentina. 2015. 118 f.  
570 Dissertação (Mestrado) – Instituto de Geociências, Universidade Federal Fluminense,  
571 Niterói.

572 Foster, J. B. (1964). Evolution of mammals on islands. *Nature*, 202(4929), 234-235.

573 Fouke, B. W. (2011). Hot-spring Systems Geobiology: abiotic and biotic influences on  
574 travertine formation at Mammoth Hot Springs, Yellowstone National Park, USA.  
575 *Sedimentology*, 58(1), 170-219. García Ruiz, J.M. (1998). Carbonate precipitation into  
576 alkaline silica-rich environments. *Geology*, 26(9), 843-846.

577 Gomes, J.P., Bunevich, R.B., Tedeschi, L.R., Tucker, M.E. and Whitaker, F.F., 2020. Facies  
578 classification and patterns of lacustrine carbonate deposition of the Barra Velha  
579 Formation, Santos Basin, Brazilian Pre-salt. *Marine and Petroleum Geology*, 113,  
580 p.104176.

581 Herlinger Jr, R., Zambonato, E.E. and De Ros, L.F., 2017. Influence of diagenesis on the quality  
582 of Lower Cretaceous pre-salt lacustrine carbonate reservoirs from northern Campos  
583 Basin, offshore Brazil. *Journal of Sedimentary Research*, 87(12), pp.1285-1313.

584 Hosa, A., Wood, R. A., Corbett, P. W. M., de Souza, R. S., & Roemers, E. (2020). Modelling the impact  
585 of depositional and diagenetic processes on reservoir properties of the crystal-shrub limestones in  
586 the 'Pre-Salt' Barra Velha Formation, Santos Basin, Brazil. *Marine and Petroleum Geology*, 112,  
587 104100.

588 Ionescu, D., Volland, J. M., Contarini, P. E., & Gros, O. (2023). Genomic Mysteries of Giant  
589 Bacteria: Insights and Implications. *Genome Biology and Evolution*, 15(9), ebad163.

590 Joel, L., 2016. How did fragile early microbes become fossils? *Eos*, 97,  
591 <https://doi.org/10.1029/2016EO057519>.

592 Lima, B.E.M. and De Ros, L.F., 2019. Deposition, diagenetic and hydrothermal processes in the  
593 Aptian Pre-Salt lacustrine carbonate reservoirs of the northern Campos Basin, offshore  
594 Brazil. *Sedimentary Geology*, 383, pp.55-81.

595 Keshari, N., Zhao, Y., Das, S. K., Zhu, T., & Lu, X. (2022). Cyanobacterial community structure  
596 and isolates from representative hot springs of Yunnan Province, China using an  
597 integrative approach. *Frontiers in microbiology*, 13, 872598.

598 Mareš, J., Johansen, J.R., Hauer, T., Zima Jr, J., Ventura, S., Cuzman, O., Tiribilli, B. and  
599 Kaštovský, J., 2019. Taxonomic resolution of the genus *Cyanothece* (Chroococcales,  
600 Cyanobacteria), with a treatment on *Gloeothece* and three new genera, *Crocospaera*,  
601 *Rippkaea*, and *Zehria*. *Journal of Phycology*, 55(3), pp.578-610.

602 Meister, P., Reyes, C., Beaumont, W., Rincon, M., Collins, L., Berelson, W., ... & Nealson, K. H.  
603 (2011). Calcium and magnesium-limited dolomite precipitation at Deep Springs Lake,  
604 California. *Sedimentology*, 58(7), 1810-1830.

605 Moreira, J.L.P., Madeira, C.V., Gil, J.A. and Machado, M.A.P., 2007. Bacia de Santos. *Boletim*  
606 *de Geociencias da PETROBRAS*, 15(2), pp.531-549.

607 Muniz, M.C. and Bosence, D.W.J., 2015. Pre-salt microbialites from the Campos Basin  
608 (offshore Brazil): image log facies, facies model and cyclicity in lacustrine carbonates.  
609 Geological Society, London, Special Publications, 418(1), pp.221-242.

610 Pietzsch, R., Oliveira, D.M., Tedeschi, L.R., Neto, J.V.Q., Figueiredo, M.F., Vazquez, J.C. and de  
611 Souza, R.S., 2018. Palaeohydrology of the Lower Cretaceous pre-salt lacustrine  
612 system, from rift to post-rift phase, Santos Basin, Brazil.  
613 *Palaeogeography, Palaeoclimatology, Palaeoecology*, 507, pp.60-80.

614 Pietzsch, Raphael, Leonardo R. Tedeschi, Daniel M. Oliveira, Camila Wense Dias dos Anjos,  
615 Joselito C. Vazquez, and Milene F. Figueiredo. "Environmental conditions of deposition of  
616 the Lower Cretaceous lacustrine carbonates of the Barra Velha Formation, Santos Basin  
617 (Brazil), based on stable carbon and oxygen isotopes: a continental record of pCO<sub>2</sub> during  
618 the onset of the Oceanic Anoxic Event 1a (OAE1a) interval?" *Chemical Geology* 535  
619 (2020): 119457.

620 Pozo, M., & Casas, J. (1999). Origin of kerolite and associated Mg clays in palustrine-lacustrine  
621 environments. The Esquivias deposit (Neogene Madrid Basin, Spain). *Clay Minerals*, 34(3),  
622 395-418.

623 Rehim, H. A. A. A., Mizusaki, A. M. P., Carvalho, M. D., & Monteiro, M. (1986, October). Talco  
624 e estevensita na Formação Lagoa Feia da bacia de Campos-possíveis implicações no  
625 ambiente deposicional. In *Anais XXXIV Congresso Brasileiro de Geologia* (Vol. 1, pp. 416-  
626 422).

627 Rezende, M.F. and Pope, M.C., 2015. Importance of depositional texture in pore  
628 characterization of subsalt microbialite carbonates, offshore Brazil. *Geological Society*,  
629 London, Special Publications, 418(1), pp.193-207.

630 Riding, R. (2006). Microbial carbonate abundance compared with fluctuations in metazoan  
631 diversity over geological time. *Sedimentary Geology*, 185(3-4), 229-238.

- 632 Riccomini, C., Sant, L.G. and Tassinari, C.C.G., 2012. Pré-sal: geologia e exploração. Revista  
633 Usp, (95), pp.33-42.
- 634 Rodrigues, K.C. 2015. Caracterização petrográfica dos “carbonatos” laminados do Membro  
635 Crato, Bacia do Araripe, Nordeste do Brasil. Senior Thesis, Universidade Federal do Rio  
636 Grande do Sul, Brazil. 167pp.
- 637 Schrank, A. B. S., Dos Santos, T., Altenhofen, S. D., Freitas, W., Cembrani, E., Haubert, T., ... &  
638 De Ros, L. F. (2024). Interactions between Clays and Carbonates in the Aptian Pre-Salt  
639 Reservoirs of Santos Basin, Eastern Brazilian Margin. *Minerals*, 14(2), 191.
- 640 Schulz-Vogt, H. N., Angert, E. R., & Garcia-Pichel, F. (2007). Giant bacteria. *eLS*.
- 641 Sharma, M. and Shukla, Y., 2012. Occurrence of helically coiled microfossil *Obruchevella*  
642 in the Owk Shale of the Kurnool Group and its significance. *Journal of earth system*  
643 *science*, 121(3), pp.755-768.
- 644 Salman, V., Bailey, J. V., & Teske, A. (2013). Phylogenetic and morphologic complexity of giant  
645 sulphur bacteria. *Antonie Van Leeuwenhoek*, 104, 169-186.
- 646 Saller, A., Rushton, S., Buambua, L., Inman, K., McNeil, R. and Dickson, J.T., 2016. Presalt  
647 stratigraphy and depositional systems in the Kwanza Basin, offshore Angola. *Aapg*  
648 *Bulletin*, 100(7), pp.1135-1164.
- 649 Silva, F. N. 2020. Regra das Ilhas e genética quantitativa evolutiva do tamanho corporal em  
650 *Elephas maximus borneensis*. Dissertação (Mestrado em Genética e Biologia Molecular)  
651 – UFG. 40 p.

652 Song, Z. Q., Wang, F. P., Zhi, X. Y., Chen, J. Q., Zhou, E. M., Liang, F., ... & Li, W. J. (2013).  
653 Bacterial and archaeal diversities in Yunnan and Tibetan hot springs, China.  
654 *Environmental microbiology*, 15(4), 1160-1175.

655 Souza-Egipsy, V., Wierchos, J., Ascaso, C., & Neelson, K. H. (2005). Mg–silica precipitation in  
656 fossilization mechanisms of sand tufa endolithic microbial community, Mono Lake  
657 (California). *Chemical Geology*, 217(1-2), 77-87.

658 Sallun Filho, W. (1999). Análise dos estromatólitos do Grupo Itaiacoca (Proterozóico), ao sul de Itapeva,  
659 SP. *Unpublished M. Sc. Dissertation, Instituto de Geociências, Universidade de São Paulo, São*  
660 *Paulo, SP, Brazil.*

661 Terra, G., Spadini, A., França, A., Sombra, C., Zambonato, E., Juschaks, L., Arienti, L., Erthal,  
662 M., Blauth, M., Franco, M., Matsuda, N., Carramal da Silva, N., Moretti, P., Davila, R.,  
663 Souza, R., Tonietto, S., Anjos, S., Campinho, V., Winter, W. (2010). Classificação de rochas  
664 carbonáticas aplicável às bacias sedimentares brasileiras. *Boletim de Geociências -*  
665 *Petrobras*. 18. 9-29.

666 Thiede, D.S. and Vasconcelos, P.M., 2010. Paraná flood basalts: rapid extrusion hypothesis  
667 confirmed by new  $^{40}\text{Ar}/^{39}\text{Ar}$  results. *Geology*, 38(8), pp.747-750.

668 Tosca, N. and Wright, V. (2015). Diagenetic pathways linked to labile Mg-clays in lacustrine  
669 carbonate reservoirs: A model for the origin of secondary porosity in the Cretaceous pre-  
670 salt Barra Velha Formation, offshore Brazil. *Geological Society, London, Special*  
671 *Publications*. 435. 10.1144/SP435.1.

672 Viera, A.O. (2021). Syn- and post-depositional silicification in a pre-salt carbonate reservoir: a  
673 case study in the Santos Basin (SE Brazil). Monography. Masters dissertation. University



674 of Vale do Rio dos Sinos (UNISINOS), Brazil. Vonshak, A., 1997. *Spirulina Platensis*  
675 (*Arthrospira*) (pp. 43-65). London: Taylor & Francis.

676 Wright, V.P. and Barnett, A.J., 2015. An abiotic model for the development of textures in some  
677 South Atlantic early Cretaceous lacustrine carbonates. Geological Society, London,  
678 Special Publications, 418(1), pp.209-219.

679

## CAPÍTULO 4

### Manuscrito II

Este capítulo apresenta o manuscrito “*Prediction of Porosity and Permeability of Carbonate Rocks Using Thin Section Data and Machine Learning Methods: A Systematic Review*”, o qual foi encaminhado a revista *Petroleum*, estando este em fase de revisão.

Este manuscrito traz uma revisão bibliográfica sistemática referente às técnicas inteligentes utilizadas para problemas de predição de porosidade e permeabilidade, utilizando como *dataset* imagens micrográficas e dados petrográficos obtidos a partir de lâminas delgadas de rochas.

----- Forwarded message -----

De: Petroleum <em@editorialmanager.com>

Date: sáb., 30 de jul. de 2023 às 05:46

Subject: Decision on submission to Petroleum

To: RITA FABIANE GUASINA De OLIVEIRA <rita.fabi@gmail.com>

Manuscript Number: PETLM-D-22-00055

Prediction of rock porosity and permeability using digital images, optical microscopy, and Machine Learning: A systematic review.

Dear Miss OLIVEIRA,

Thank you for submitting your manuscript to Petroleum.

I am pleased to inform you that the reviewers recommend the publication of your manuscript, and therefore we will accept it for publication in Petroleum. To proceed with publication, the items contained in my comments, as well as the reviewers' comments, must be reviewed, which are provided below.

We appreciate you submitting your manuscript to Petroleum and thank you for giving us the opportunity to consider your work.

Best regards, Guangchuan Liang Editorial Office Petroleum

Editor and Reviewer Comments: Reviewer #1: Please see the attached PDF.

Reviewer #2: This is a review manuscript. Through a bibliographic search of scientific articles published in the last five years on the Google Scholar search platform, the best practices in using machine learning to predict porosity and permeability in carbonate rocks were reviewed. Future challenges were discussed. It is noted that the use of an architecture that combines digital images and annotated data for permeability prediction is a promising approach. It seems interesting. I recommend its publication provided the following items are clarified:

Clearly state the main topic or scientific question addressed in this study. As it is a review article, wouldn't it be better to include other methods? What are the advantages and disadvantages of these methods? How to use these methods and examples? What are the broad implications of the results? Update the references.

1 Prediction of Porosity and Permeability of Carbonate Rocks Using  
2 Thin Section Data and Machine Learning Methods: A Systematic  
3 Review.

4  
5 Rita Fabiane Guasina de Oliveira<sup>a</sup>, Sandro José Rigo<sup>b</sup>, Farid Chemale Jr. <sup>a</sup>, Ariane Santos da  
6 Silveira<sup>a</sup> and Paulo Sérgio Gomes Paim<sup>a</sup>

7  
8 <sup>a</sup>Unisinos – University of Vale do Rio dos Sinos – Geology Graduate Program

9 <sup>b</sup>Unisinos – University of Vale do Rio dos Sinos – Computer Science Department

10

11 ARTICLE INFO

12

13 Keywords:

14 Machine Learning

15 Prediction of porosity and permeability

16 Permo-porous attributes

17 Conventional optical microscopy

18 Digital images

19

20 Authorship contribution statement

21 **Rita Fabiane Guasina de Oliveira:** Wrote the paper and participated of the discussions and conclusions of this  
22 research article. **Sandro José Rigo:** Participated in the discussions and conclusions of this research article. **Farid**  
23 **Chemale Jr:** Participated in the discussions and conclusions of this research article. **Ariane da Silva Silveira:**  
24 Participated in the discussions and conclusions of this research article. **Paulo Sérgio Gomes Paim:** Participated  
25 in the discussions and conclusions of this research article.

26

27

28 ABSTRACT

29

30 Reservoir rocks have an intricate system of pores which are directly related to the fluid flow capacity. In carbonate  
31 rocks, the porous framework is complex, and permeability is not always solely related to the presence of pores.  
32 Many of the elements that influence rock permeability can be observed through optical microscopy. The use of  
33 machine learning methods applied to a dataset composed of poroperm attributes obtained from thin section analysis  
34 of rocks and 2D images of thin sections can help predict the permeability of even the most complex reservoirs,  
35 such as carbonate ones. This systematic research aims to present the current state of knowledge on predicting  
36 porosity and permeability using thin section image datasets. Articles published in various journals over 34 years  
37 were studied, highlighting the relevant aspects of various machine learning techniques used for permeability  
38 prediction. The most widely used approaches that produce the best results are convolutional neural networks  
39 applied to real data or synthetic samples.

40

41

42

## 43        **1. Introduction**

44        This article aims to update the scientific knowledge related to the use of machine learning as a tool to be  
45 employed in predicting porosity and permeability in reservoirs, including carbonate reservoirs, using 2D digital  
46 images and poroperm attributes acquired through conventional optical microscopy.

47        The poroperm attributes to be used correspond to specific datasets generally used to determine reservoir  
48 petrofacies (De Ros and Goldberg, 2007). These attributes are obtained analyzing thin slices of rock through  
49 optical microscope, when the main characteristics of the rock that impact the porosity and permeability of the  
50 reservoir are verified. Among the analyzed petrographic attributes, the different types of pores that make up the  
51 framework, as well as the connection between them, impact the distribution and variability of permeability within  
52 the reservoir. This dataset about the porous framework of the rock, including the pores and their connections  
53 (throats), corresponds to a complex, multiscale system difficult to classify (Van der Land *et al.*, 2013). This system  
54 is controlled by depositional processes, which gave rise to the sediments that make up the reservoir, including their  
55 primary mineralogical composition, as well as by sin- and post-depositional diagenetic processes that affected the  
56 primary grains. The systematic microscopic description of thin sections allows the identification of important  
57 features that influence the distribution of effective porosity in the rock. This analysis becomes a powerful tool  
58 when we associate these features with 2D images of thin sections of the rock and machine learning methods,  
59 enabling the identification of different types of pores and their distribution.

60        To achieve the objective of this work, a bibliographic search of scientific articles was carried out, referring to  
61 the main concepts of machine learning and best practices involving this technique with optical microscopy and the  
62 use of 2D digital images for permeability prediction. For this purpose, this review was divided into three main  
63 parts: a methodological part, a conceptual part, and a section presenting research results. A final section is  
64 dedicated to discussing the obtained results and future challenges.

65

## 66        **2. Methodology**

67        In this review, we chose to search for scientific articles focused on the main analytical techniques and based  
68 on these, discuss taxonomies, identifying data sets, pre-processing methods and more significant intelligent  
69 techniques for obtaining predictive models of porosity and permeability, applicable to reservoir studies. At the  
70 end, based on the research carried out, we identify the challenges and gaps in the literature, indicating new  
71 directions for future research.

72 Defining research questions is a fundamental part of a literature review. It is based on these questions that  
73 information is obtained to help defining the best practices. In this specific case, the bibliographical research carried  
74 out will help in the search for the best practices in the use of machine learning to predict porosity and permeability  
75 in carbonate rocks.

76 In this work, the literature analysis was based on the following general and specific questions:

77 • General questions:

78 ○ What intelligent machine learning models are used to predict porosity and permeability from  
79 optical microscopy data and 2D digital images?

80 ○ What taxonomy is used for intelligent detection of poroperm attribute datasets from thin rock  
81 sections and 2D digital images?

82 • Specific questions:

83 ○ What datasets are used?

84 ○ What pre-processing techniques are used?

85 ○ What metrics are used?

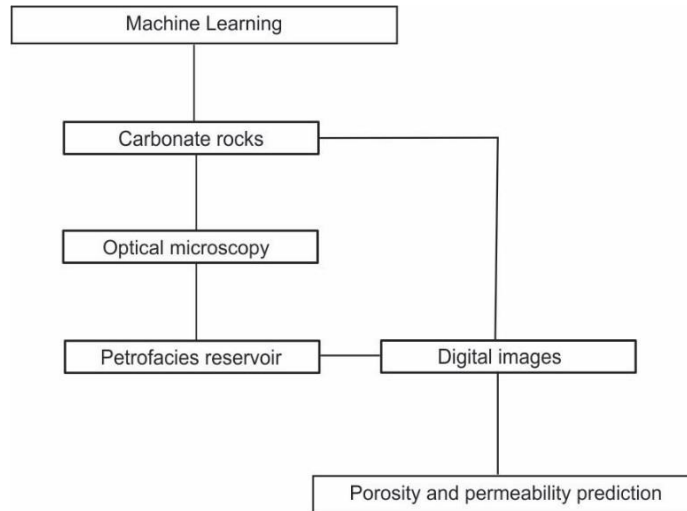
86

## 87 2.1. Search systematics

88 The research was conducted using a direct search on the internet search platform Google Scholar, through the  
89 following set of hierarchically grouped terms: *"machine learning" OR "deep learning" OR "artificial*  
90 *intelligence" AND "poroperm prediction" OR "permeability prediction"*. Initially, the search yielded 10.600  
91 articles. Then, a filter was applied by adding a new set of words to refine and restrict the search: *"2D images" OR*  
92 *"thin section images" AND "carbonate rocks"* (Figure 1). In this new search, articles published since the 1980s  
93 were selected, excluding theses or dissertations.

94 From the proposed search set, 70 (seventy) scientific articles were found. After the first filtering based on  
95 reading the abstracts, articles that did not use intelligent techniques to predict porosity and permeability were  
96 excluded, which reduced the number of articles found to a total of 40 (forty) articles. A second filtering was  
97 performed, which excluded all articles that did not use poroperm parameters obtained from optical microscopy  
98 associated with digital images as the main training data for the prediction of porosity and permeability. Finally,  
99 there were 16 (sixteen) articles that integrated the techniques informed. Table 1 contains the fifteen (15) articles  
100 found in the search listed in order by number of citations.

101



102

103

**Figure 1.** Sets of words used when searching for scientific references.

104

105

**Table 1.** Related articles x number of citations (last search February 2024).

Journal	Authors	Year of publication	Number of citations
Computer & Geosciences	Sudkov, Burnaev and Koroteev	2019	192
Scientific Reports	Wu, Fang, Kang, Tao and Qiao	2019	123
Journal of Petroleum Science and Engineering	Alqahtani, Alzubaidi, Armstrong, Swietojanski and Mostaghimi	2020	118
Engineering & Computers	Tian, Qi, Sun, Yaseen and Pham	2020	88
Journal of Natural Gas Science and Engineering	Rabbani, Assadi, Kharrat, Dashti and Ayatollahi	2017	46
Geophysics	Silva, Tavares, Carrasquilla, Misságia and Ceia	2020	30
Proceedings of the 16th International Congress of the Brazilian Geophysical Society & Expogef	Bordignon, Figueiredo, Esterkoetter, Rodrigues and Duarte	2019	16
Energy & Fuels	Zhang and Cai	2021	14
European Association of Geoscientists & Engineers	Araya-Polo, Alpak, Hunter, Hofmann and Saxena	2018	13
Abu Dhabi International Petroleum Exhibition & Conference	Tembely and Alsumaiti	2019	13
Sociedade Brasileira de Geofísica	Duarte-Coronado, Tellez-Rodriguez, Pires de Lima, Marfurt and Slatt	2019	11
Acta Geophysica	Jamshidi Gohari, Emami Niri and Ghiasi-Freez	2021	9
E3S Web of Conference	Andrew, M.	2019	6
Journal of African Earth Sciences	Esmaeili, Hosseinzadeh, Radkhodaie, Wood and Akbarzadeh	2024	-
Scientific Repoerts	Yalamanchi and Datta Gupta	2024	-

106

107



## 108        2. Concepts

109        A sedimentary rock is composed of three basic elements that correspond to framework, that is, its framework.  
110        This structure is formed by solid materials (mineral or biogenic grains, matrix, and cements) and voids. When  
111        talking about the poroperm property of a given rock, it refers to certain physical properties that directly influence  
112        the storage and exploitation of hydrocarbons (or other fluids, such as groundwater), such as porosity and  
113        permeability. Porosity corresponds to the percentage of void spaces (pores) that each rock has in its framework  
114        and that is not filled by solid material (Yang, 2017). While porosity is a measure of the rock's ability to store a  
115        given fluid, permeability is the ability of the rock framework to transmit fluid through a given pressure (Yang,  
116        2017), measured in Darcy (D) or milidarcy (mD).

117        Artificial Intelligence (AI) is the broad term used to encompass all software tools, methods and devices that  
118        perform intelligent activities. AI is related to the ability of technological solutions to carry out activities in a way  
119        that is considered intelligent. An AI solution involves a grouping of various technologies, such as Artificial Neural  
120        Networks (ANN), search algorithms and knowledge representation systems, which manage to simulate human  
121        capacity linked to intelligence (Kubat, 2017).


122        The ability of coded computational systems to obtain their own knowledge through diverse data and raw data,  
123        comprises the machine learning field (Goodfellow *et al.*, 2016). According to Mitchell (1997), machine learning  
124        occurs when a computer program learns from a specific experience, referring to a class of tasks, metrics, and  
125        performance, improving that experience.

126        In general, machine learning computers are programmed to learn from a given experience, using the principle  
127        of induction. From a given set of examples generic conclusions may be achieved, inducing learning aspects through  
128        algorithms, from a function or hypothesis and solving a problem based on the aspects of certain instances (data)  
129        of the problem to be solved (Carvalho *et al.*, 2011). In this way, it is understood that in machine learning,  
130        processing is carried out from a set of data combined with results. Starting from the combination of data and  
131        results, an algorithm is trained and calculates the hypothesis from the input data to obtain a specific result. In  
132        addition of being flexible to new examples, algorithms used in training are interdependent on the number of rules  
133        to work, being advantageous when used for high performance problems as they do not rely on many rules explicitly  
134        programmed to work as expected. Another benefit is their flexibility to incorporate knowledge from new examples.

135        Deep learning corresponds to a part of machine learning that seeks to solve complex problems that a normal  
136        algorithm cannot efficiently solve, through successive layers of increasingly significance and simple

137 representation. (Chollet, 2017). In this way, deep learning maintains the same relationship with machine learning  
138 that machine learning maintains with artificial intelligence (Figure 2).

139



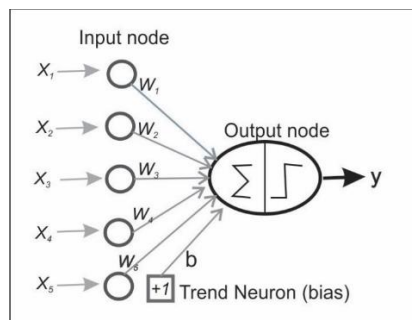
140

141 **Figure 2.** Relationship between Artificial Intelligence, Machine Learning and Deep Learning (adapted by  
142 Chollet, 2017).

143

144 Artificial neural networks were developed to mimic aspects of the functioning of the human brain where  
145 computational units simulate the functioning of neurons and can learn any mathematical function from training a  
146 given data set (Aggarwal, 2018). The network works from the application of an activation function generated by  
147 a neuron, from an input set, multiplied by a set of weights and added to a constant or bias. The result of this  
148 function is propagated to the next neuron and so on. This behavior is called Perceptron (Figure 3), the simplest  
149 form an artificial neuron (Aggarwal, 2018). At last, it is understood that a neural network is a set of artificial  
150 neurons interconnected between multiple layers where the first layer of the network is called the input layer, the  
151 last layer is the output layer and the intermediate layers they are called hidden layers (Nielsen, 2015).

152



153

154 **Figure 3.** Artificial neuron or Perceptron (adapted by Alggarwad, 2018).

155

156 Convolutional neural networks are designed to process input data in multi-vector format, representing a space  
157 dependency or proximity between each input value (LeCun *et al.*, 1998). These vectors are one-dimensional when  
158 the data is temporal, two-dimensional for images and audio spectrograms, or three-dimensional for video and

159 volumetric images (LeCun *et al.*, 2015). The structure of the convolutional neural network is like artificial neural  
160 networks, but they use mathematical operations of convolution instead of simple matrix multiplication in at least  
161 one of its layers (Goodfellow *et al.*, 2016). In addition to the convolution layer, the convolutional artificial network  
162 can contain activation and pooling layers. Together, these layers transform the input data, inferring which  
163 characteristics are decisive for the problem through the training process, using for this the same conventional  
164 techniques used in artificial neural networks: gradient descent and backpropagation.

165

### 166 **3. Search results**

167 In general, the result of the direct search performed in the Google Scholar indicates that machine learning  
168 applied to the prediction of porosity and permeability, having as input data parameters obtained in thin sections  
169 and digital images of rock, comprises a subject still poorly exploited.

170 Among the selected papers, Rabanni *et al.* (2017) is one of the most complete articles that uses most of the  
171 listed techniques. Intelligent and empirical techniques were used to predict porosity from 200 thin sections and 2D  
172 images. The authors created two neural network models from information obtained through optical microscopy.  
173 The first model used for porosity prediction a set of input data related to the porous framework (average pore size,  
174 average throat size, average throat length and 2D coordination number of the pore network). The second model  
175 used data from lithology, pore types and sample factory. In the second predictive model, permeability was obtained  
176 empirically according to the porosity observed in optical microscopy associated with digital images. For this  
177 model, the images pass through a pre-processing when they were converted to gray shades based on the average  
178 of red, green, and blue colors in the RGB format. Afterwards, a watershed segmentation algorithm was employed  
179 to separate the pore content and solid parts of the sample. Altogether, Rabanni *et al.* (2017), tested 5 different  
180 images associated with each thin lamina to reduce the negative effect of the results heterogeneity. A neural network  
181 with 10 neurons was created using the Levenberg Marquardt method of MATLAB Neural for a total of 500 epochs.  
182 Neural network performance was measured using the Mean Squared Error (MSE). At the end of the training, they  
183 concluded that porosity and coordination number are the most reliable attributes to be used for predicting  
184 permeability. However, they stated that some diagnosed errors are difficult to overcome using this methodology,  
185 such as the low amplitude of the information representation contained in a thin section, the lack of microporosity  
186 identification on digital images and the average of pore measurements that masks the breadth of some information  
187 regarding true pore size.

188 Araya-Polo *et al.* (2018) sought to predict permeability using a convolutional neural network (CNN) with 2D  
189 images collected by Scanning Electron Microscopy (SEM). Training with this type of image achieved an MSE of  
190 11.69% and  $R^2$  of 0.7967 on test data. The authors did not provide a complete architecture for utilizing images  
191 collected with this technology. The good results obtained validated the use of convolutional architectures in rock  
192 data processing, as well as the potential growth in the use of this type of network for regression tasks, which is not  
193 as common compared to classification tasks. Also in 2018, Wu *et al.* also proposed a convolutional neural network  
194 model to predict the porosity of rocks using synthetic data from an image bank. For this purpose, as input they  
195 used artificially generated 2D images in addition to a set of physical data (permeability). The convolutional neural  
196 network created by Wu *et al.* (2018) obtained good predictive results, even with synthetic data, with  $R^2$  of 0.926315  
197 and MSE of 0.000470.

198 After 2018, Wu, Fang, Kang, Tao and Qiao (2019) tested the response of convolutional neural networks  
199 applied to fuzzy synthetic models and found that CNNs yielded better results than other applied methods. Also in  
200 2019, new studies applied convolutional neural networks to predict the same properties using multivariate  
201 statistical regression techniques (Andrew, 2019) or even solving image segmentation problems and predicting rock  
202 physical properties using an end-to-end model, where grayscale images are used as input and directly return  
203 properties as output, applying traditional segmentation techniques in the process (Sudakov *et al.*, 2019; Wu *et al.*,  
204 2019; Bordignon *et al.*, 2019; Tembely and Al'Sumaiti, 2019; Duarte-Coronado *et al.*, 2019; Al'qahtani *et al.*,  
205 2020; Tian *et al.*, 2020).

206 Sudakov *et al.* (2019) tested different machine learning techniques to predict permeability from 3D rock  
207 images. They concluded that 3D convolutional networks bring the best results for predicting permeability, with a  
208 MSE of 3.37%, as they can identify complex features without losing space dependence in the three dimensions.  
209 This seminal paper influenced several other works dealing with similar themes.

210 Bordignon *et al.* (2019), in turn, used synthetic data (set of spheres) to train a 3D convolutional neural  
211 network with the aim of performing fast predictions of grain size and porosity distribution. During the pre-  
212 processing of the images, a simple thresholding segmentation technique was used whereas the training was done  
213 with the "Adam" optimizer for 1000 epochs. Real samples of the Berea Sandstone was used as data set for training.  
214 The authors concluded that convolutional networks applied to 3D images bring better results for permeability  
215 prediction as it is possible to identify complex characteristics related to the porous rock framework, without losing  
216 the space dependence in the three dimensions.

217 Using a combination of numerical and machine learning techniques, Tembely and Al'Sumaiti (2019) also  
218 predicted permeability of carbonate rocks. Using thousands of 3D images obtained from computed  
219 microtomography (Micro-CT) as input data for a deep learning network, the authors achieved results with a  $R^2$  of  
220 0.915. However, the same network did not obtain good results when the images were directly associated with the  
221 physical properties of the rocks. In the same year, Duarte-Coronado *et al.* (2019) tested four different types of  
222 convolutional neural networks for porosity prediction, using for training datasets of 2D photomosaics of thin  
223 sections and lab measured porosities of three different types of rocks. The images were classified according to  
224 their porosity (low <3%; mean 3% to 5%; and high >5%), imaged in six, lower resolution compositions and pre-  
225 processed by rotation at 90, 180 and 270. This latter procedure was adopted in order to increase the number of  
226 samples to be used in training, generating a total of 2,655 images at the end of the process. At the end of pre-  
227 processing, the authors used the convolutional neural network models VGG19, MobileNetV2, InceptionV3,  
228 Xception and InceptionResNetV2. The authors concluded that the best results were obtained through the use of  
229 the MobileNetV2 network, whose result was presented in a Confusion Matrix.

230 Another approach was adopted by Andrew (2019) who created a porosity prediction model using the  
231 Multivariate Statistical Regression technique from synthetic 3D digital images. These images were parameterized  
232 in 34 statistical parameters, derived from specific properties and validated through an open-source digital rock  
233 dataset, containing different pore geometries of carbonate and sandstone. Also using a hybrid model, Tian *et al.*  
234 (2020) presented the results obtained through the application of an Artificial Neural Network (ANN) and a Genetic  
235 Algorithm (GA) for permeability prediction from 1000 2D synthetic porous media. As pre-processing, the authors-  
236 built 3D images from the 2D data for training. As input parameter for the training the authors used a synthetic pore  
237 structure, while the laboratory physical permeability was used as an output parameter. As a result of the hybrid  
238 method, the authors obtained an  $R^2$  of 0.998 in the training set and  $R^2$  of 0.999 in the test set.

239 Different from Tian *et al.* (2020), Alqahtani *et al.* (2020) sought to predict porosity, specific surface area and  
240 mean pore size from a convolutional network model using 3D images of three types of sandstones, converted to  
241 2D slices, using a segmentation technique called Otsu thresholding. The final mean error obtained was low, with  
242 an MSE of 4.5% and MAE (Mean Absolute Error) of 5.4%. The  $R^2$  obtained was 0.96 for porosity, 0.92 for specific  
243 surface area and 0.71 for average pore size.

244 Silva *et al.* (2020) proposed a working model based on machine learning techniques to classify and predict  
245 different reservoir petrofacies of carbonate units present in the Campos Basin (SE Brazilian margin). The Decision  
246 Tree (DT), Random Forest (RF), Gradient Boosting (GB), K-Nearest Neighbors (KNN) and Naïve Bayes (NB)

247 methods were used for the tests. For network training, 1677 data from two oil wells were used, combining  
248 description of cores, capillary pressure measurements, physical lab data of porosity and permeability, in addition  
249 to total porosity obtained through the RHOB log and estimated permeability calculated through multiple linear  
250 regression. To test the result obtained by the algorithms the following metrics were applied: accuracy, precision,  
251 recall and F1-score. As a pre-processing technique, data normalization was performed to increase consistency  
252 among them. After 10 training sessions for each method, the authors verified that the best results in terms of  
253 absolute precision were obtained through the use of the following methods: Random Forest, with 96.23%, followed  
254 by K-Nearest Neighbors and Gradient Boosting, with 96.25% and 94, 78%, respectively.

255 In turn, Jamshidi Gohari, Emami Niri and Ghiasi-Freez (2021) estimated the permeability of carbonate rocks  
256 using pore networks extracted from 150 thin section images. Associated with the images were petrophysical data  
257 obtained from well geophysical logs and physical permeability data obtained in the laboratory. For permeability  
258 prediction, the Levenberg-Marquardt backpropagation algorithm was employed, yielding an  $R^2$  of 0.97, and when  
259 using the same method applied to geophysical data, an  $R^2$  of 0.73 was obtained.

260 In the same year, Zhang and Cai (2021) employed a dataset consisting of digital images of thin sections of  
261 carbonate rocks, aiming to correlate rock permeabilities with observed pore parameters in thin sections. Regarding  
262 pores, they considered observations on equivalent diameter and dominant size, alongside inverse correlations with  
263 perimeter-to-area ratio and fractal dimension. As intelligent techniques, they utilized a combination of  
264 Backpropagation (BP) and Random Forest. This methodology yielded excellent results with an  $R^2$  of 0.936,  
265 demonstrating good generalization and the association between permeability and pore attributes.

266 Most recently in 2024, Yalamanchi and Gupta utilized scanning electron microscope (SEM) images and well  
267 logs to analyze pore structure and estimate permeabilities of carbonate rocks. They employed the MaxEntropy,  
268 Watershed, and Boltzmann numerical network (LBM) algorithms to estimate pore networks and permeability of  
269 samples, comparing them with values derived from well logs. The authors conducted two tests: one using Artificial  
270 Neural Network (ANN) and another Support Vector Machine (SVM) to predict carbonate sample permeability.  
271 The pore network served as input, while permeability values obtained through LBM served as output. The ANN  
272 model exhibited an  $R^2$  value of 0.892, along with root mean square error RMSE of 1.927, mean square error (MSE),  
273 and mean absolute error (MAE) values of, 3.716, and 1.580, respectively, for permeability values, whereas the  
274 SVM model estimation produced an  $R^2$  value of 0.849, with RMSE, MSE, and MAE values of 2.324, 5.401, and  
275 2.166.

276 Esmaeili *et al.* (2024), on the other hand, utilized micrographic images of 109 thin sections of rock and  
277 applied the K-means algorithm to segment the images and calculate the porosity of each part. Through this method,  
278 the authors estimated the porosity values of the images and compared them with the porosity values of rock cores,  
279 obtaining a correlation coefficient of 67%.

280 The systematic search for articles referring to the topic in question, showed that the use of parameters  
281 obtained in optical microscopy related to “reservoir petrofacies” (De Ros and Goldberg, 2007) are still under  
282 explored. During the research, only one record was obtained whose theme corresponds to the prediction of  
283 reservoir petrofacies (Silveira *et al.*, 2020).

284

#### 285 **4. Discussion**

286 Although at first the search for articles produced a good response, with seventy articles responding to the  
287 search, after two initial filtering, the number of articles dropped to sixteen when considering only those whose  
288 content really met the entire set of searched words (“carbonate rocks” – “prediction of porosity and permeability”  
289 - “optical petrography” - “digital images” – “reservoir petrofacies”). This significant decrease in the number of  
290 selected articles indicates that the use of datasets from a thin rock section to predict reservoir porosity and  
291 permeability is still poorly explored.

292 A major part of the 15 (fifteen) analyzed articles, mainly published between 2019 and 2024 (Graph 1), used  
293 convolutional artificial networks or hybrid methods involving convolutional networks and specific algorithms to  
294 predict porosity and permeability (Table 2). The most used metrics were the coefficient of determination ( $R^2$ ), the  
295 Mean Absolute Error (MAE) and the Mean Square Error (MSE). As input data for training, synthetic and real data  
296 were used. Input data are pre-processed to increase consistency as a result of the lack of uniformity in the input  
297 parameters that present different magnitudes (% , size, mD) and resolutions (number of pixels and RGB tones).  
298 Usual pre-processing techniques include segmentation (watershed, thresholding, and thresholding Otsu),  
299 binarization and pixelization.

300 Along the second article filtering we realized that the researchers prefer the use of 3D instead of 2D images,  
301 even being known that the use of optical microscopy makes it possible to acquire several important information  
302 for the analysis of permeability, such as the pore types and content of diagenetic material. This preference is related  
303 to the low representativity of the thin sections relative to the sample framework and the reservoir itself, as explained  
304 by Sudakov *et al.* (2019), one of the most cited papers among all (Graph 2).


305

**Table 2.** Related works

Authors	Method	Data Type	Number Sample	Attribute	Results
Rabbani, Assadi, Kharrat, Dashti and Ayatollahi (2017)	Levenberg Marquardt to MATLAB Neural	Thin rock sections and 2D images	200 thin rocks sections – 1000 images	Porosity Permeability	R <sup>2</sup> 0,82
Araya-Polo, Alpak, Hunter, Hofmann and Saxena (2018)	Convolutional Neural Network (CNN)	2D scanning Electron microscope (SEM) images	-	Permeability	R <sup>2</sup> 0,79
Wu, Fang, Kang, Tao and Qiao (2019)	Convolutional Neural Network (CNN)	Synthetic 2D images	1960	Permeability	R <sup>2</sup> 0,88
Duarte-Coronado, Tellez-Rodriguez, Pires de Lima, Marfurt and Slatt (2019)	Convolutional Neural Network (CNN)	2D images of thin rock sections, core sample and laboratory porosities	2655	Porosity	-
Bordignon, Figueiredo, Esterkoetter, Rodrigues and Duarte (2019)	3D Convolutional Neural Network (CNN)	synthetic images of spheres	-	Porosity	Data validated with data from Berea sandstone
Tembely and Alsumaiti (2019)	Convolutional Neural Network (CNN)	3D segmented images	1100	Permeability	R <sup>2</sup> 0,92
Sudkov, Burnaev and Koroteev (2019)	3D Convolutional Neural Network (CNN)	3D images	-	Permeability	MSE 3,37%
Andrew, M. (2019)	Multivariate Statistical Regression (MSR)	Synthetic images	2190	Permeability	RMSFE <4%
Tian, Qi, Sun, Yaseen and Pham (2020)	Artificial Neural Network (ANN) + Genetic Algorithm	Synthetic images + variables	1000 images, 15 variables	Permeability	R <sup>2</sup> 0,99
Alqahtani, Alzubaidi, Armstrong, Swietojanski and Mostaghimi (2020)	Convolutional Neural Network (CNN)	2D slices of 3D images	7860 slices	Porosity	R <sup>2</sup> 0,96
Silva, Tavares, Carrasquilla, Misságia and Ceia (2020)	Decision Tree (DT), Random Forest (RF), Gradient Boosting (GB), K-Nearest Neighbors (KNN) and Naive Bayes (NB)	Geophysical profiles, hysical permeabilities, core descriptions	1677 data from 2 oil wells	Reservoir petrofacies	Absolute accuracy of 96,23%
Zhang and Cai (2021)	Backpropagation (BP) and Random Forest	2D images of thin rock sections + variables	-	Relationship between visible attributes in the thin rock sections and permeabilities	R <sup>2</sup> 0,936
Jamshidi Gohari, Emami Niri and Ghiasi-Freez (2021)	Levenberg-Marquardt backpropagation algorithm	pore networks extracted from thin rock section images	150	Permeability	R <sup>2</sup> 0,97
Esmaeili, Hosseinzadeh, Radkhodaie, Wood and Akbarzadeh (2024)	K-means algorithm	2D images of thin rock sections	109	Porosity	R <sup>2</sup> 0,67
Yalamanchi and Datta Gupta (2024)	MaxEntropy, Watershed, and Boltzmann numerical network (LBM) algorithms; Support Vector Machine (SVM)	Scanning electron microscope (SEM) images and well logs	-	Pore networks and permeability	R <sup>2</sup> 0,892 RMSE 1,927 MSE 3,716 MAE 1,580

307

308



309


310

311

**Graph 1.** Number publications x Year.



312 Rabanni *et al.* (2017) was one of the pioneers in the use of optical petrography data and 2D images for  
 313 permeability prediction. Using the Levenberg Marquardt method (MATLAB Neural) he obtained, for a group of  
 314 200 thin sections, an  $R^2$  of 0.823. Although the coefficient of determination was not fully satisfactory, we see the  
 315 result as consistent with the type of used images in the training as these were detailed, partial images of thin  
 316 sections, and not photomosaics. Images of details do not represent the entire framework of the thin section, being  
 317 insufficient in number and amplitude to train the recognition of the different types of pores contained in the rock.  
 318 Araya-Polo *et al.* (2018) had the same problem when using SEM images for training, focusing on microporosity  
 319 and small areas of thin sections, which do not represent the entire rocky framework. The influence of the type of  
 320 image used (detail or mosaic) for training is one of the precautions that we must take during training when we seek  
 321 answers closer to reality. This fact was evidenced in the experiment developed by Duarte-Coronado *et al.* (2019).  
 322 It uses a methodology like Rabanni *et al.* (2017) and Araya-Polo *et al.* (2018), by using 2D images, but not in  
 323 photomosaic format, therefore achieving better training results with the use of a convolutional neural network  
 324 .



325  
 326 **Graph 2.** Number citations for papers.  
 327

328 Although Duarte-Coronado *et al.* (2019) have shown good results with their network, the work of Tian *et al.*  
 329 (2020) showed the best results among all the analyzed articles, with a coefficient of determination very close to 1  
 330 ( $R^2$  0.99). The reason for the better response of the network was the use of a hybrid method composed of an  
 331 artificial neural network and a genetic algorithm and the following input parameters: tortuosity of the connections

332 (throats) and the relationship between pore number x throat number. The authors pointed out that these are the  
333 fundamental parameters that most impact the permeability of any porous system.

334 In 2021, Zhang and Cai, as well as Jamshidi Gohari *et al.*, employed thin-section rock images to predict  
335 permeability. Zhang and Cai utilized a hybrid method to relate certain parameters observed in thin-section rock to  
336 permeability values. They applied backpropagation (BP) and Random Forest algorithms to the dataset, achieving  
337 very good results with an  $R^2$  of 0.93. On the other hand, Jamshidi Gohari *et al.* utilized 150 thin-section rock  
338 images to predict permeability using the Levenberg-Marquardt backpropagation algorithm. The results obtained  
339 surpassed those involving geophysical profiles, with an  $R^2$  of 0.97.

340 Similar to the approach developed by Jamshidi Gohari *et al.* (2021), Esmaeili *et al.* (2024) utilized 109  
341 micrographic images to calculate porosity using the K-means algorithm. The application of this method yielded a  
342 correlation coefficient of 67%. These results were further enhanced by the methodology proposed by Yalamanchi  
343 and Gupta, who achieved an  $R^2$  of 0.89 by employing a dataset comprising scanning electron microscopy (SEM)  
344 images for predicting the permeability of carbonate rocks. Their approach involved a series of numerical  
345 techniques such as Max Entropy, Watershed, LBM, and SVM.

346 Although we found some works that used digital images of thin sections of rock as input data for artificial  
347 neutrals networks to predict porosity and permeabilities, our research showed that there is a gap regarding the use  
348 of the input data set obtained from thin sections, mainly those related to the petrofacies reservoir. An interesting  
349 fact is that the concept of reservoir petrofacies (De Ros and Goldberg, 2017) is not used in training networks for  
350 permeability prediction. Although the attributes of reservoir petrofacies are very important for the analysis of  
351 permeability in a reservoir, in this systematic review, only one article responded to the search for the group of  
352 words “*reservoir petrofacies*” and “*carbonate rocks*” (Silva et al., 2020), focusing on predicting petrofacies rather  
353 than permeabilities. The lack of articles on this subject indicates how little explored the concept of reservoir  
354 petrofacies for permeability prediction has been.

355 Table 3 contains answers to the general and specific questions listed at the beginning of this work based on  
356 the filtered articles. This compilation was made in a generic way in order to include most of the analyzed articles.

357

358

359

360

361

**Table 3.** General and specific questions.

<b>General questions:</b>	
<b>What machine learning-based intelligent models are used to predict porosity and permeability from optical microscopy data and digital images?</b>	Convolutional Neural Networks (CNN) are the most widely used.
<b>What taxonomy is used for intelligent detection of poroperm attribute datasets from thin rock sections and digital images?</b>	There is no single taxonomy for models for the researched techniques.
<b>Specific questions:</b>	
<b>What datasets are used?</b>	<ul style="list-style-type: none"> <li>Annotated data: there is no consensus, but some authors use porosity, coordination number, pore size, throat size and tortuosity.</li> <li>2D and 3D (real and synthetic), detail and mosaic images.</li> </ul>
<b>What pre-processing techniques are used?</b>	Segmentation (watershed, thresholding and Otsu thresholding); binarization and pixelization.
<b>What metrics are used?</b>	Coefficient of determination ( $R^2$ ), Mean Square Error (MSE) and Confusion Matrix.

363

364

365

## 5. Future Challenges

366

367

368

369

370

371

372

373

374

375

376

377

378


In general, after analyzing the articles, it was possible to verify that there is no consensus among researchers about which annotated data should be used in the training input of thin rock sections. A specific taxonomy that integrates annotated data and images for permeability prediction was also not found. This is an important gap to be filled, and perhaps this can be solved using hybrid methods and selection of reservoir petrofacies attributes obtained through a good quantification of thin sections.

In ongoing work, we are generating labeled data sets based on the quantification of different types of pores and constituents of the rock framework (diagenetic, hydrothermal), as well as parameters such as packing index (for reworked material), textural aspects and the total and effective porosities obtained from data obtained in thin sections of rock. These labels, in addition to providing a greater understanding of the rock's framework and its genesis, also help to indicate which are the true parameters that influence the permeability of carbonate rocks, with a focus on predicting permeability, through the use of a convolutional neural network hybrid.

Through these data sets, an integration of the taxonomy of images and labeled data is suggested for the development of research (Figure 4). From a preliminary analysis, the labeled attributes that directly influence

379 permeability will serve as input data for the neural network and were selected according to the degree of relevance  
 380 in relation to the generation and obliteration of available pore spaces.

381



382

383

**Figure 4.** Proposed taxonomy including images and datasets per reservoir petrofacies.

384

385 Another important gap found in the research is the lack of a methodology that allows upscaling the results  
 386 obtained in the training to a reservoir scale. Perhaps this can be achieved through the study of fractals (Pia and  
 387 Sanna, 2014; Xia *et al.*, 2018), but this is an issue that still have to be properly addressed in the context of the  
 388 research being carried out.

389

## 390 6. Conclusions

391 This work presented a survey and a comparative study of articles whose focus is the application of machine  
 392 learning resources for porosity and permeability prediction, using digital images and other parameters of thin rock  
 393 sections as data sets.

394 The analysis of the articles showed that the convolutional architecture is the most used for the prediction of  
 395 porosity and permeability using the listed techniques, but it was not possible to obtain a consensus regarding the  
 396 data sets used to provide input to the network. Likewise, it was possible to see that 2D images in mosaic format  
 397 provide a better response to training.

398 We see the use of an architecture that merges digital images and annotated data for permeability prediction as  
 399 a promising approach. In turn, a taxonomy that considers reservoir petrofacies and integrates both images taken  
 400 from thin sections and attributes obtained from the microscopic description is suggested. A methodology that  
 401 allows the upscaling of the results obtained in the training to the scale of the reservoir has still to be developed.

402        **Acknowledgment**

403        Special thanks to the Postgraduate Course in Geology at the University of Vale do Rio dos Sinos and to  
404        CNPQ/Capes/Prosuc.

405

406        **References**

407        Aggarwal, C.C. 2018. Neural networks and deep learning. Springer, v. 10, p. 978-3.

408        Alqahtani, N., Alzubaidi, F., Armstrong, R. T., Swietojski, P., Mostaghimi, P. 2020. Machine learning for  
409        predicting properties of porous media from 2d X-ray images. Journal of Petroleum Science and Engineering,  
410        v. 184, p. 106514.

411        Andrew, M. 2020. Permeability prediction using multivariant structural regression. In: E3S Web of Conferences.  
412        EDP Sciences, p. 04001.

413        Araya-Polo, M., Alpak, F. O., Hunter, S., Hofmann, R., Saxena, N. 2018. Deep learning-driven pore-scale  
414        simulation for permeability estimation. In: ECMOR XVI-16th European conference on the mathematics of  
415        oil recovery. European Association of Geoscientists & Engineers, p. 1-14.

416        Bordignon, F., Figueiredo, L.P., Exterkoetter, R., Rodrigues, B. B. and Duarte, M. 2019. Deep Learning for Grain  
417        Size and Porosity Distributions Estimation on micro-CT Images. In: Proceedings of the 16th International  
418        Congress of the Brazilian Geophysical Society & Expogef. [S.l.: s.n.].

419        Carvalho, A., Faceli, K., Lorena, A., Gama, J. 2011. Inteligência Artificial – uma abordagem de aprendizado de  
420        máquina. Rio de Janeiro: LTC, p. 45, 2011.

421        Chollet, F. 2017. Deep Learning with Python. Nova Iorque, EUA: Manning Publications Company.

422        De Ros, L. F., Goldberg, K. 2007. Reservoir Petrofacies: A Tool for Quality Characterization and Prediction.  
423        Search and Discovery Article #50055.

424        Duarte-Coronado, D., Tellez-Rodriguez, J., Pires de Lima, R., Marfurt, K., Slatt, R. 2019. Deep convolutional  
425        neural networks as an estimator of porosity in thin-section images for unconventional reservoirs. In: SEG  
426        Technical Program Expanded Abstracts 2019. Society of Exploration Geophysicists, p. 3181-3184.

427        Esmaili, B., Hosseinzadeh, S., Kadkhodaie, A., Wood, D. A., & Akbarzadeh, S. (2024). Simulating reservoir  
428        capillary pressure curves using image processing and classification machine learning algorithms applied to  
429        petrographic thin sections. Journal of African Earth Sciences, 209, 105098.

430        Goodfellow, I., Bengio, Y., Courville, A. 2016. Machine learning basics. Deep learning, v. 1, n. 7, p. 98-164.

431 Jamshidi Gohari, M. S., Emami Niri, M., & Ghiasi-Freez, J. (2021). Improving permeability estimation of  
432 carbonate rocks using extracted pore network parameters: a gas field case study. *Acta Geophysica*, 69, 509-  
433 527.

434 LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. 1998. Gradient-based learning applied to document recognition.  
435 *Proceedings of the IEEE*, v. 86, n. 11, p. 2278-2324.

436 LeCun, Y.; Bengio, Y.; Hinton, G.2015. Deep learning. *Nature*, v. 521, p. 436–444.

437 Mitchell, T. M. 1997. *Machine Learning*. [S.l]: McGraw-Hill.

438 Nielsen, M.A. 2015. *Neural networks and deep learning*. San Francisco, CA: Determination press.

439 Pia, G. and Sanna, U. 2014. An intermingled fractal units model and method predict permeability in porous rock.  
440 *International Journal of Engineering Science* 75. 31–39;

441 Rabbani, A., Assadi, A., Kharrat, R., Dashti, N., Ayatollahi, S. 2017. Estimation of carbonates permeability using  
442 pore network parameters extracted from thin section images and comparison with experimental data. *Journal*  
443 *of Natural Gas Science and Engineering*, v. 42, p. 85-98.

444 Silva, AA, Tavares, MW, Carrasquilla, A., Misságia, R., Ceia, M. 2020. Petrofacies classification using machine  
445 learning algorithms. *Geophysics*, v. 85, n. 4, p. WA101-WA113.

446 Sudokov, O.; Burnaev, E.; Koroteev, D. 2019. Driving digital rock towards machine learning: Predicting  
447 permeability with gradient boosting and deep neural networks. *Computers & Geosciences*, v. 127, p. 91–98.

448 Tembely, M., Alsumaiti, A. 2019. Deep learning for a fast and accurate prediction of complex carbonate rock  
449 permeability from 3D micro-CT images. In: Abu Dhabi International Petroleum Exhibition & Conference.  
450 OnePetro.

451 Tian, J., Qi, C., Sun, Y., Yaseen, Z. M., Pham, B. T. 2020. Permeability prediction of porous media using a  
452 combination of computational fluid dynamics and hybrid machine learning methods. *Engineering &*  
453 *Computers*, v. 2020.

454 Van Der Land, C; Wood, R.; Wu, K.; Van Duke, M.I.; Jiang, Z.; Corbett, O.W.; Couples, G. 2013. Modelling the  
455 permeability Evolution of carbonate rocks. *Marine and Petroleum Geology*, 48. P. 1-7.

456 Wu, J., Yin, X. and Xiao, H., 2018. Seeing permeability from images: fast prediction with convolutional neural  
457 networks. *Science bulletin*, 63(18), pp.1215-1222.

458 Wu, H., Fang, W.Z., Kang, Q., Tao, W.Q., Qiao, R. 2019. Predicting Effective Diffusivity of Porous Media from  
459 Images by Deep Learning. *Scientific Reports*, Nature Publishing Group, v. 9, n. 1, p. 1–12.

- 460 Yalamanchi, P., & Datta Gupta, S. (2024). Estimation of pore structure and permeability in tight carbonate  
461 reservoir based on machine learning (ML) algorithm using SEM images of Jaisalmer sub-basin, India.  
462 Scientific Reports, 14(1), 930.
- 463 Yang, S. 2017. Fundamentals of Petrophysics – Second Edition – Book Springer Geophysics. 502p.
- 464 Zhang, Z., & Cai, Z. (2021). Permeability prediction of carbonate rocks based on digital image analysis and rock  
465 typing using random forest algorithm. Energy & Fuels, 35(14), 11271-11284.

## **CAPÍTULO 5**

### **Manuscrito III**

O Capítulo 5 traz o manuscrito “*PREDICTION OF CARBONATE ROCKS POROPerm PROPERTIES USING CONVOLUTIONAL NEURAL NETWORKS*”, encaminhado para a *Computers & Geosciences*, este em fase final de correção.

Este manuscrito descreve uma abordagem desenvolvida através de uma rede neural convolucional (CNN), cuja arquitetura é descrita em detalhe, onde os dados de entrada são as imagens micrográficas obtidas durante a etapa de petrografia, descritos em detalhe no Manuscrito I.



----- Forwarded message -----

De: Computers and Geosciences <em@editorialmanager.com>

Date: dom., 23 de nov. de 2023 à 10:55

Subject: Decision on submission to Computers and Geosciences

To: RITA GUASINA DE OLIVEIRA <rita.fabi@gmail.com>

Manuscript Number: CAGEO-D-23-00240

PREDICTION OF POROPERMEABLE PROPERTIES OF CARBONATE ROCKS USING  
CONVOLUTIONAL NEURAL NETWORKS

Dear Mrs. DE OLIVEIRA,

Thank you for submitting your manuscript to Computers & Geosciences. I have conducted a preliminary assessment of your manuscript to determine if it meets our requirements in terms of scope, presentation, and technical solidity.

After reviewing your article, I found that it fits within the scope of our journal. Indeed, CAGEO aims to publish innovative approaches related to computer sciences. Upon reading your article, I have forwarded it to our reviewers, whose suggestions are included in the PDF files attached to this email. To proceed with the publication process, I kindly request that you carefully read the comments and make every effort to address all the points raised by our reviewers.

Please make the necessary adjustments and submit the revised article, including the suggestions, by May 23, 2024.

Best regards,

Pauline Collon

Editor-in-Chief

Computers and Geosciences

1 PREDICTION OF CARBONATE ROCKS POROPERM  
2 PROPERTIES USING CONVOLUTIONAL NEURAL  
3 NETWORKS

4

5 Rita Guasina de Oliveira<sup>1</sup>, Augusto Pasini<sup>2</sup>, Ariane Santos da Silveira<sup>1</sup>, Paulo Sérgio Gomes  
6 Paim<sup>1</sup>, Sandro José Rigo<sup>2</sup> and Farid Chemale Jr.<sup>1</sup>

7

8 <sup>a</sup>Unisinos – University of Vale do Rio dos Sinos – Geology Graduate Program

9 <sup>b</sup>Unisinos – University of Vale do Rio dos Sinos – Computer Science Department

10

11 ARTICLE INFO

12

13 Keywords:

14 Machine Learning

15 Deep Learning

16 Carbonate Rock

17 Prediction of porosity and permeability

18 Digital images

19

20

21 Authorship contribution statement

22 **Rita Fabiane Guasina de Oliveira:** Wrote the paper and participated of the discussions and conclusions of this  
23 research article. **Augusto Pasini:** Wrote the paper and participated of the discussions and conclusions of this  
24 research article. **Ariane da Silva Silveira:** Wrote the paper and participated of the discussions and conclusions of  
25 this research article. **Paulo Sérgio Gomes Paim:** Wrote the paper and participated of the discussions and  
26 conclusions of this research article. **Sandro José Rigo:** Wrote the paper and participated of the discussions and  
27 conclusions of this research article. **Farid Chemale Jr.:** Wrote the paper and participated of the discussions and  
28 conclusions of this research article

29


30 ABSTRACT

31 In the realm of oil research and exploration, identifying rocks with favorable porosities and  
32 permeabilities is crucial for informed decision-making. Traditionally, this entails predicting  
33 these properties within different sedimentary sequences using geophysical or petrophysical  
34 methods, which can be both expensive and potentially destructive. To address these challenges  
35 and streamline the process while preserving valuable samples, we have developed a  
36 convolutional neural network (CNN) architecture. We use 366 images of thin sections of pre-  
37 salt rocks to be able quickly predict porosities and permeabilities, minimizing influence of  
38 human bias. Our model used a dataset composed only of 2D images of thin slices of sample  
39 rocks and a convolutional artificial neural network to predict both properties. The generated  
40 architecture allowed excellent results, like the results obtained in petrophysical laboratory tests  
41 and sometimes better than the results obtained by other researchers employing 3D images  
42 techniques. For porosity prediction, we achieve an R-Squared ( $R^2$ ) value of 0.8385, Mean  
43 Absolute Error (MAE) of 0.0132, Mean Squared Error (MSE) of 0.0004 and Root Mean  
44 Squared Error (RMSE) of 0.0209. Similarly, for permeability, our model demonstrates an  $R^2$   
45 of 0.9826, MAE of 0.0700, MSE of 0.0161 and RMSE of 0.1256 for permeability.

46 **1 Introduction**

47 Poroperm properties are the most important physical properties to be measured in reservoir  
48 rocks, regarding fluid transmission (Buryakovsky *et al.*, 2012). These properties are related to  
49 the void (pore) content of a rock and the ability to allow the flow of fluids within the pore space  
50 (Figure 1). Thus, the analysis of these parameters can be used as indicators of the quality of a  
51 reservoir concerning the storage, migration, and extraction capacity of fluids such as oil and  
52 gas (Yang and Wei, 2017; Valentin *et al.*, 2019; Buryakovsky *et al.*, 2012; Tembely, Alsumaiti  
53 and Alameri, 2020; Yang *et al.*, 2022).

54



55 **Figure 1.** Micrographic images of the same thin section of rock, under natural light (A) and polarized light (B). In  
56 blue, void content (porosity) whose arrangement enables fluid flow within the rock.  
57

58

59

60

61 Obtaining these physical properties usually involves the use of expensive or potentially  
62 destructive geophysical and laboratory methods, in addition to having experts to analyze and  
63 correctly handle the equipment. This, in turn, makes it extremely important to identify these  
64 attributes quickly, economically, accurately, and in the most automated way possible.

65 In parallel, Artificial Intelligence (AI) is currently gaining prominence with the  
66 development of new technologies (Faceli *et al.*, 2011; Nielsen, 2015). When the idea of  
67 Machine Learning (ML) techniques such as Deep Learning (DL) emerged in the mid-1960s,  
68 technological resources were not enough to train and apply complex and layered models

69 (Mitchell, 1997; Schmidhuber, 2015; LeCun *et al.*, 2015; Goodfellow *et al.*, 2016; Wason,  
70 2018). It is only recently that deep learning techniques regained popularity and are being  
71 efficiently applied as a solution to real and complex problems.

72       Excellent results were obtained, as in the deep neural network model proposed by  
73 Krizhevsky, Sutskever and Hinton (2012) to classify images from the ImageNet database. Some  
74 of the main reasons for this recent significant advance were the evolution of computational  
75 power, storage capacity, quality and quantity of data obtained (largely due to Big Data and the  
76 Internet of Things), the complexity of knowledge of algorithms, and studies of neuroscience  
77 (Arel, Rose and Karnowski, 2010; Chollet, 2017; Saikia *et al.*, 2020).

78       The advancement of technology, mainly in the capture of data and images and the increase  
79 in computational power, made it possible to apply deep learning to solve various problems using  
80 fundamental and complex geological data. An example is the various studies that have been  
81 developed applying deep learning techniques to images collected during the drilling of oil wells  
82 (Tahmasebi *et al.*, 2020; Tembely, Alsumaiti and Alameri, 2021).

83       In this study, we present the results of experiments employing a convolutional neural  
84 network (CNN) applied to a regression problem for predicting the porosity and permeability of  
85 reservoir rocks. The input data for this CNN consisted of micrographic (2D) images of thin  
86 sections of carbonate samples collected from a core obtained from an oil well located in pre-  
87 salt rocks of the Santos Basin (Brazil).

88       The reservoir rocks from which the images were derived correspond to limestone rocks  
89 from the Barra Velha Formation, dating back to the Aptian age. Carbonate rocks, in general,  
90 have high reactivity to dissolution, replacement and recrystallization processes, making them  
91 susceptible to variations in mineral content and percentage of voids in their framework, giving  
92 them a heterogeneous textural appearance (Akbar *et al.*, 2001). Pre-salt rocks are composed of  
93 facies generated in situ (bushes, spherulites, mudstones) and facies resulting from the reworking

94 of in situ facies (grainstones, rudstones and packstones) (Guasina Oliveira *et al.*, *in press*).  
95 These are lithologies whose complex genesis, linked to chemical, diagenetic and hydrothermal  
96 processes, resulted in a set of rocks with unique characteristics, whose porous aspects respond  
97 to the heterogeneity of their genesis (Lima and De Ros, 2019; Basso *et al.*, 2021; Guasina  
98 Oliveira *et al.*, *in press*).

99 These framework heterogeneities are reflected in the distribution of porosity and  
100 differences in permeability among the sedimentary sequence's facies. An example of this is  
101 depicted in Figure 2, where the shrubstone facies exhibit varying percentages of porosity and  
102 permeability values along the profile, which are not correlatable at different sampled depths.

103 This complex characteristic was one of the reasons for seeking the robustness of  
104 convolutional neural networks for predicting porosity and permeability using a dataset  
105 composed of images, making the task of predicting these attributes more agile, secure, and cost-  
106 effective, in the most automated manner possible. Thus, the novelty of this work lies in the use  
107 of a dataset composed solely of images of thin rock sections for predicting permeability and  
108 porosity, as the prediction of these attributes for the enumerated rock types is typically  
109 performed using more elaborate geophysical methods.

110 The method presented in this article utilizes real data for both the network input and output,  
111 as all images used in the training process are linked to laboratory control data and thin rock  
112 sections, making the obtained results more coherent and reliable. This assertion is confirmed  
113 by comparing the results obtained with the proposed model to those obtained by other authors.

114 With that said, this article is organized as follows: Section 2 presents the materials and  
115 methods, including the dataset used and data preparation; Section 3 details the model used and  
116 the training process; Section 4 presents the results obtained; and Section 5 discusses the  
117 methodology applied to the dataset and the results obtained. Finally, Sections 6, 7, and 8  
118 respectively address the conclusions, acknowledgments, and code availability.

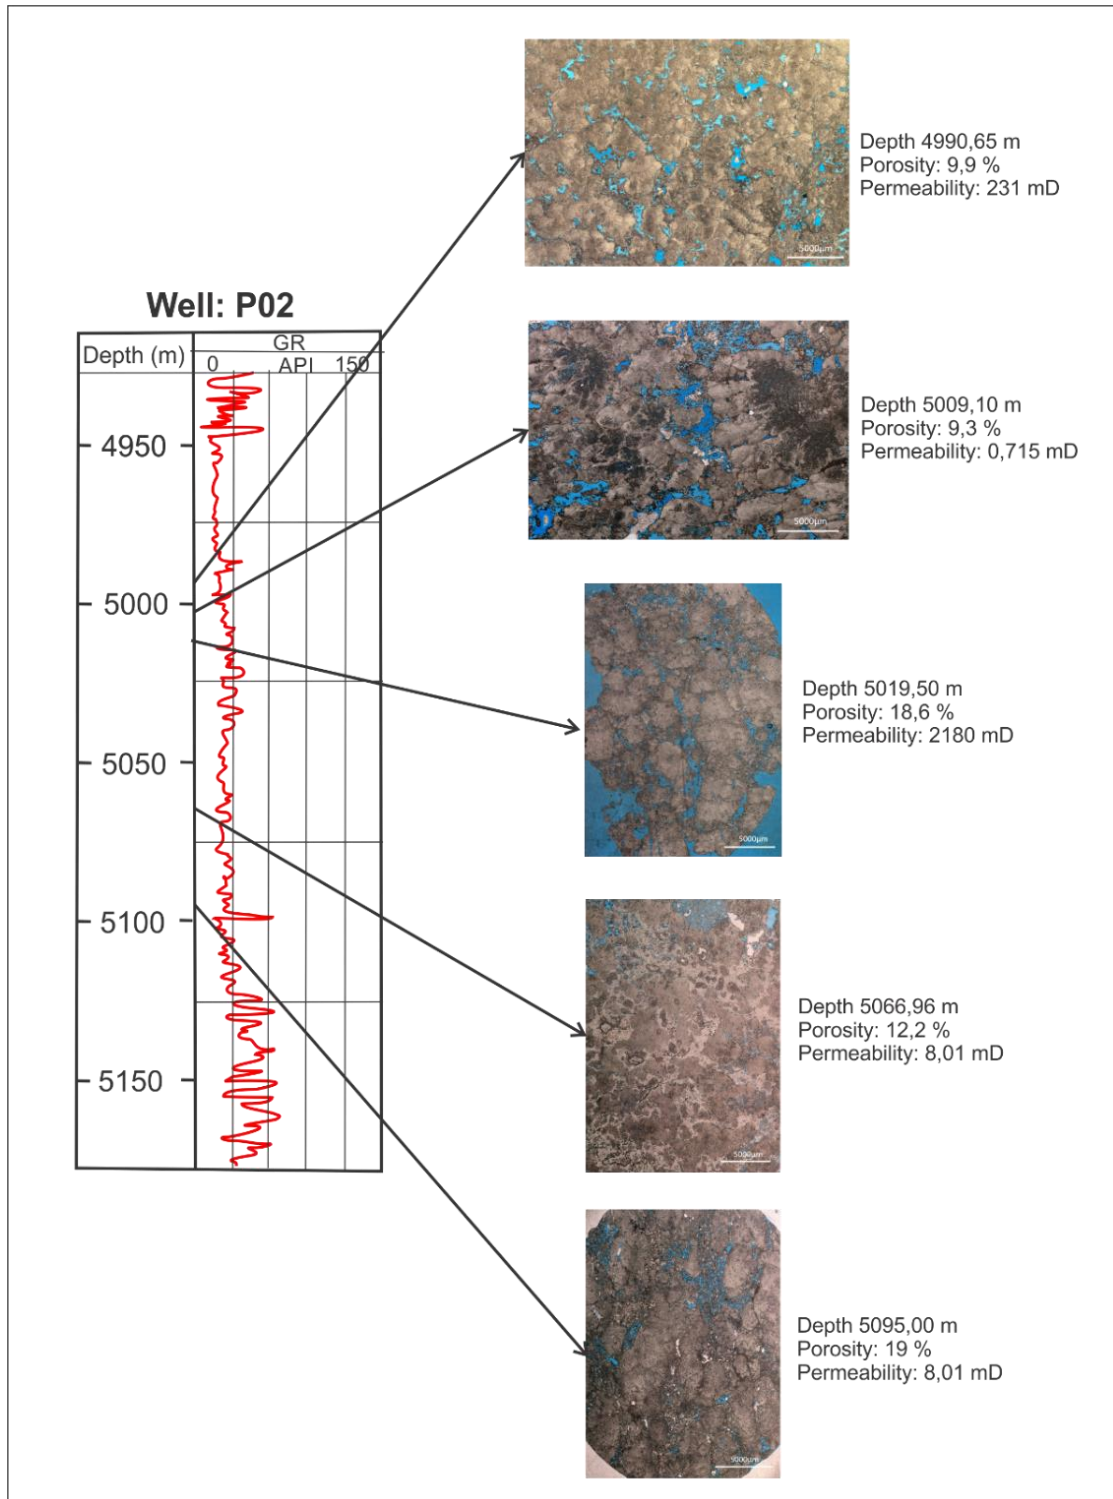
119 **2 Materials and Methods**

120 For the network training, micrographic images of thin sections of Aptian-aged carbonate  
121 rocks were utilized. These images were obtained from a petroleum well (P02) located in the  
122 Sapinhoá field, Santos Basin, Brazil (Figure 3). The Sapinhoá field spans a total area of 233  
123 km<sup>2</sup> and is situated in the central portion of the Santos Basin.

124 The pre-salt carbonate rocks exhibit a complex porous structure due to the highly reactive  
125 mineral constituents comprising their framework. This intricate arrangement of voids (pores)  
126 and minerals results in heterogeneous porosity percentages and permeability values for the same  
127 facies throughout the borehole (Figure 2).

128 The images used as the dataset were derived from thin sections of samples from well P02,  
129 which is situated atop a topographic high forming the reservoir (Figure 3). Images from well  
130 P02 were selected because it is a well whose samples are associated with reservoir units (Barra  
131 Velha Formation) and because it possesses physical permeability and porosity data obtained in  
132 the laboratory, relative to the same images used in training. In total, 183 images of samples  
133 from the reservoir interval were used, acquired at regular intervals, at depths exceeding 5000  
134 meters below sea level (Figure 4).

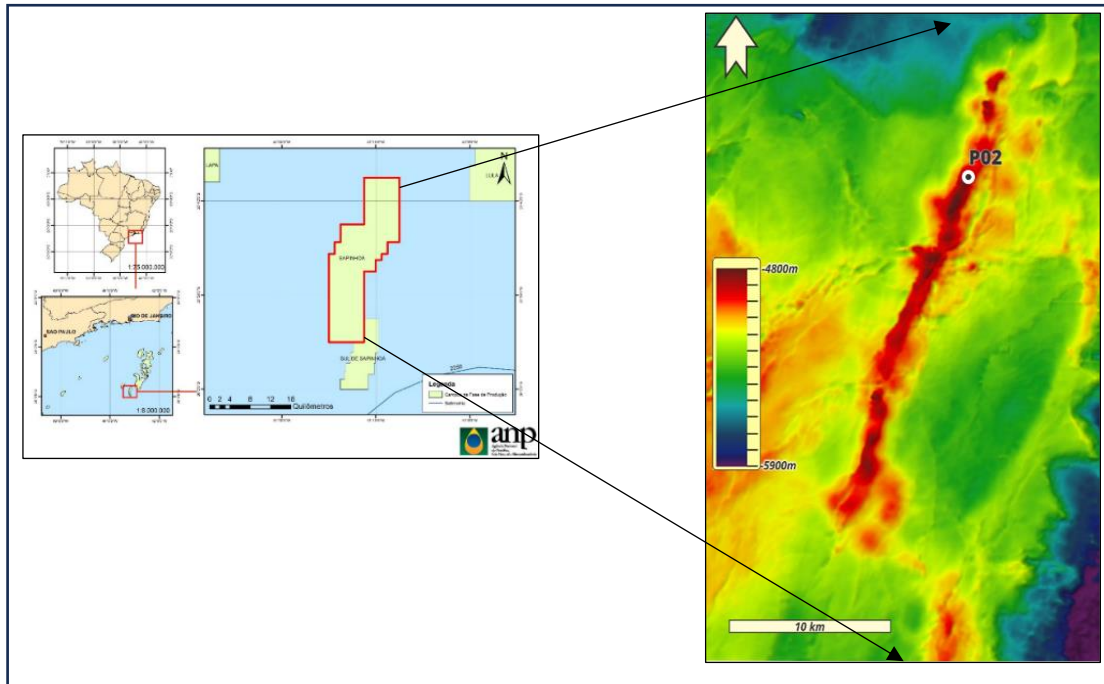
135



136  
137  
138  
139  
140  
141  
  
142  
  
143

**Figure 2.** Photomicrographs of thin sections of rock, obtained under an optical microscope, in natural light (NL). The blue color corresponds to the voids (pores) in the rock; the pink and brownish colors are the mineral elements that make up the rock's framework. Example of the variation of porosity and permeability values along the P02 well core for shrubstone facies.

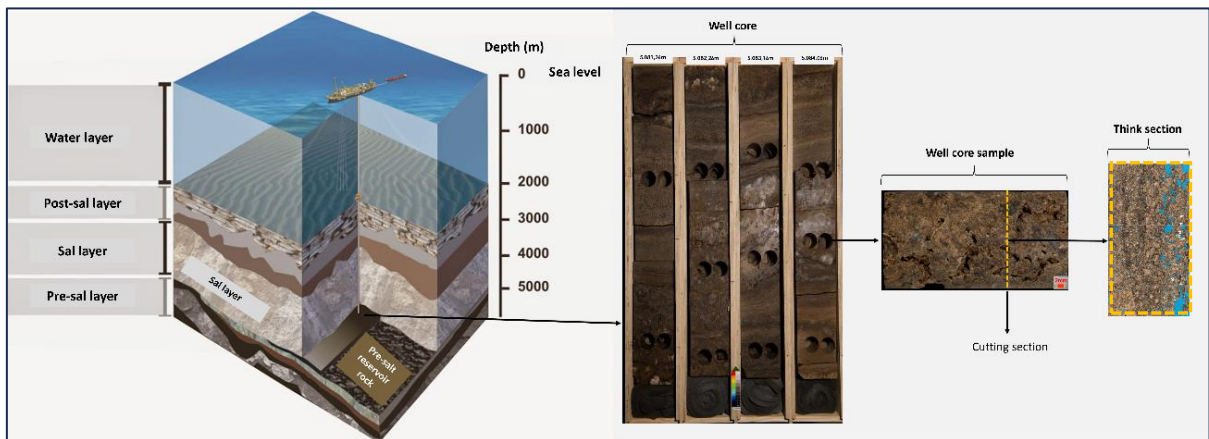




144  
145  
146  
147  
148

**Figure 3.** Location of the Petrobras Sapinhoá field. The colors represent the depths of the saline base of the Arari Formation sedimentary sequence (Sapinhoá project, 2022).

149



150  
151  
152  
153

**Figure 4.** Schematic diagram depicting the location of the images/samples used in this study relative to their origin (Figure adapted from: <https://comunicabaciadesantos.petrobras.com.br/pre-sal-bacia-de-santos>).

154       The thin rock sections used were petrographically described regarding their mineralogy,  
155       textural aspects, diagenetic and hydrothermal processes, and void content (Guasina Oliveira *et*  
156       *al.*, *in press*), to support discussions regarding the results obtained in the network training using  
157       the image dataset. In addition to petrographic description, all thin sections were photographed  
158       under an optical petrographic microscope, ensuring images with the best possible resolution.

159       The 183 micrographic images used in training had resolutions of either 1388x1040 or  
160 1384x1036 pixels. These images were resized to a standard resolution of 1384x1036 pixels,  
161 keeping them close to the original resolution and avoiding information loss. To increase the  
162 input dataset, the data augmentation technique was applied by mirroring the images, generating  
163 a total of 366 images for training, validation, and testing. The mirroring process fully preserved  
164 the identification of porosity and permeability, regardless of the viewing angle.

165       The next step involved scaling the images that were in RGB format, containing three values  
166 from 0 to 255 corresponding to the levels of red, green, and blue. All values were divided by  
167 255, resulting in values between 0 and 1 while maintaining the same distance relationship  
168 between them without losing information.

169       As output labels, a dataset composed of 186 percentage porosity values and 186  
170 permeability values obtained from petrophysics laboratory measurements was used. These  
171 labels have a direct relationship with the images used during training, obtained at the same  
172 depths. Similar procedures to those applied to the images were performed on the labels to  
173 homogenize the data: porosity values were divided by 100 to convert the percentage values  
174 (ranging from 0 to 100) into decimal values between 0 and 1, and permeability values were  
175 divided by 1000 to convert mD values (ranging from 0 to 5000) to D values (ranging from 0 to  
176 5).

177       In addition to dataset preparation and data homogenization, images and labels with low  
178 resolution (images) or permeability values exceeding 5000 mD (labels) were excluded from  
179 training. This exclusion procedure, along with the homogenization of the used data, was  
180 necessary to reduce outliers and expedite the neural network training, helping to prevent issues  
181 such as gradient disappearance and explosion.

182

183

### 184 3 Network Model

185 To support the development of a neural network coherent with the available dataset, a  
186 preliminary bibliographic search was carried out in qualified journals, of already used models  
187 by other authors, restricted to the following topics "*machine learning*" OR "*deep learning*"  
188 OR "*artificial intelligence*" AND "*poroperm prediction*" OR "*permeability prediction*" AND  
189 "*2D images*" OR "*thin section images*" AND "*carbonate rocks*" (Guasina Oliveira *et al.*, in  
190 *press*).

191 Based on research, studies were selected that utilized datasets similar to the one used in  
192 this work and whose architecture aimed to acquire porosity and permeability (Wu, Yin, and  
193 Xiao, 2018; Araya-Polo *et al.*, 2018; Sudakov, Burnaev, and Koroteev, 2019; Bordignon *et al.*,  
194 2019; Tembely and Alsumaiti, 2019; Alqahtani *et al.*, 2020; Jamshidi Gohari *et al.*, 2021;  
195 Yalamanchi and Datta Gupta, 2024). Of these works, only the articles by Jamshidi Gohari *et al.*  
196 (2021) and Yalamanchi and Datta Gupta (2024) developed different predictive models using  
197 2D images, one for permeability prediction and the other for porosity, respectively (Guasina  
198 Oliveira *et al.*, in *press*).

199 The developed model used the Python programming language, the Keras framework  
200 (Chollet, 2017) together with TensorFlow (Abadi *et al.*, 2016) and consisted of convolutional  
201 layers of 128, 64, and 32 neurons with rectified linear unit (ReLU) activation function  
202 (Ramachandran *et al.*, 2017; Sharma, 2020). Searching for activation functions together with  
203 layers max pooling and dropout (Rumelhart *et al.*, 1986) (Table 1).

204 As a loss function, *Huber's* function was used together with Adam's optimization algorithm  
205 (Kingma and Ba, 2017), whose task was to update the weights of each layer of the network  
206 through stochastic descent.

207 The model was trained using a GPU environment with 25 GB of RAM provided by Google  
208 Colab in a maximum of 150 epochs (iterations across the entire training set). To avoid memory

209 exhaustion, the parameter batch size was reduced from 32 to 16. So 16 iterations were needed  
 210 at each epoch to propagate all training samples. The early stop technique was also used for the  
 211 model to stop training when it does not identify an improvement in the result to avoid  
 212 overfitting.

213  
 214

**Table 1.** Convolutional neural network used in training.

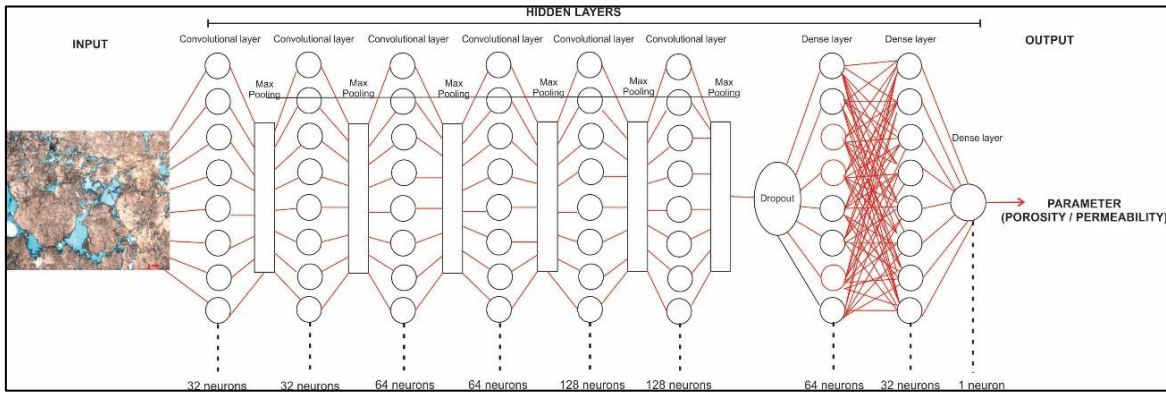
Layer	Neurons	Activation	Filter
Convolution	32	ReLU	3x3
Max pooling	-	-	2x2
Convolutional	32	ReLU	3x3
Max pooling	-	-	2x2
Convolution	64	ReLU	3x3
Max pooling	-	-	2x2
Convolution	64	ReLU	3x3
Max pooling	-	-	2x2
Convolution	128	ReLU	3x3
Max pooling	-	-	2x2
Convolution	128	ReLU	3x3
Dropout	-	-	20%
Dense	32	ReLU	-
Dense	64	ReLU	-
Dense	1	Identify	-
Total parameters: 3.352.993			

215  
 216

217 Early stop has been configured to monitor the loss function in the validation data with the  
 218 patience of 20 epochs (consecutive periods with no improvement in the metric being evaluated)  
 219 and reset the network weights on activation. Thus, it ensures that the final model will be trained  
 220 with the best possible result obtained during the training.

221 The training sessions were designed to separately train the two properties (porosity and  
 222 permeability). The training sessions resulted in two instances trained for each of the properties,  
 223 as shown in figure 5.

224



225

226

**Figure 5.** Proposed model structure.

227

228 Max pooling was used as a filter with 2x2 and 3x3 and as metrics used were coefficient of  
 229 determination ( $R^2$ ), mean absolute error (MAE), mean square error (MSE) and square root mean  
 230 error (RMSE) (Chai and Draxler, 2014), which were obtained from an average of 5 training  
 231 sessions, so that the results were more consistent and reliable.

232 From a dataset consisting of 366 images, 186 laboratory porosity and permeability data,  
 233 70% of the data were used for training, 15% validation and 15% testing.

234

#### 235 **4 Results**

236 The training performed on the test images resulted in an  $R^2$  of 0.8385, MAE of 0.0132,  
 237 MSE of 0.0004 and RMSE of 0.0209 for porosity prediction, and the permeability prediction  
 238 training an  $R^2$  of 0.9826, MAE of 0.0700, MSE of 0.0161 and RMSE of 0.1256 (Table 2).

239 **Table 2.** Metrics obtained through test

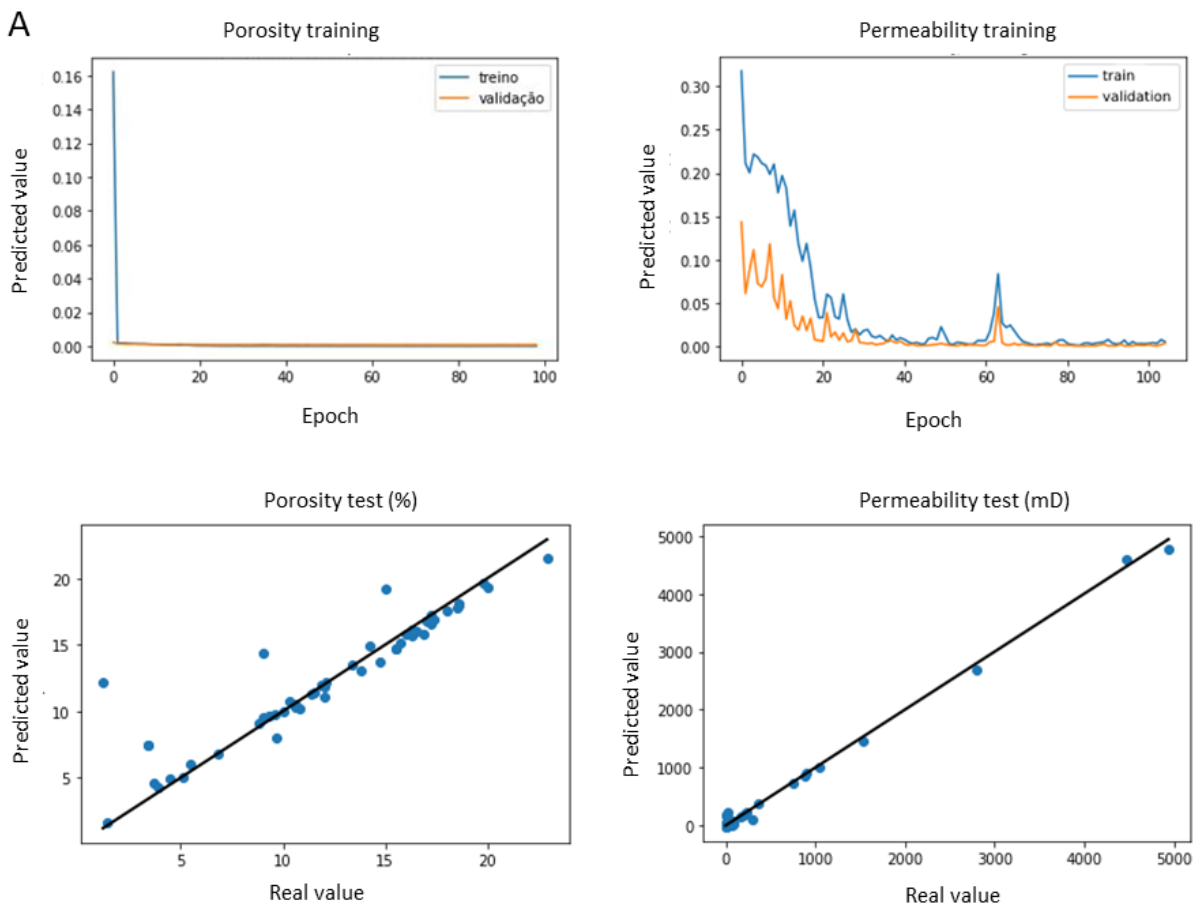
Test	Porosity				Permeability			
	$R^2$	MAE	MSE	RMSE	$R^2$	MAE	MSE	RMSE
1	0.8487	0.0125	0.0004	0.0203	0.9814	0.0772	0.0173	0.1314
2	0.8409	0.0138	0.0004	0.0208	0.9809	0.0661	0.0178	0.1334
3	0.8041	0.0138	0.0005	0.0231	0.9743	0.0722	0.0239	0.1545
4	0.8283	0.0135	0.0005	0.0216	0.9889	0.0618	0.0103	0.1014
5	0.8704	0.0124	0.0004	0.0188	0.9876	0.0727	0.0115	0.1072
<b>Mean</b>	<b>0.8385</b>	<b>0.0132</b>	<b>0.0004</b>	<b>0.0209</b>	<b>0.9826</b>	<b>0.0700</b>	<b>0.0161</b>	<b>0.1256</b>

240

241

242 Figure 6 shows, respectively, brightness plots between predicted porosity and  
243 permeability by the model on test data concerning the actual porosity and permeability of the  
244 rocks after one of the training sessions. In the same figure, graphs illustrating the evolution of  
245 the loss function across epochs during porosity training and permeability training, for both  
246 training and validation data, until its termination due to early stopping, when it was observed  
247 that the error ceased to decrease after 20 epochs.

248



249 **Figure 6.** (A) Porosity and (B) Permeability predicted by the model in contrast to the actual porosity and  
250 permeability of the rocks. Evolution of the loss function over training epochs.  
251

252

253 The results indicated that for the labels used, both properties of the network showed a  
254 good correlation since for both results the adjustment took place in less than ten epochs.

255 **5 Discussion**

256 The developed model has shown promising results in predicting porosity and permeability  
 257 using an image dataset of thin sections of pre-salt carbonate rock. When comparing our  
 258 prediction results with those obtained by other researchers using a similar dataset, we observe  
 259 that our model consistently exhibits higher predictive accuracy than what is typically reported  
 260 in the literature (Table 3).

261

262 **Table 3.** Comparative Results


Authors	Architecture	Data Type	Number of Sample	Attribute	Results (R <sup>2</sup> )
Jamshidi Gohari, Emami Niri and Ghiasi-Freez (2021)	Levenberg-Marquardt backpropagation algorithm	pore networks extracted from thin rock section images	450	Permeability	0,97
Alqahtani, Alzubaidi, Armstrong, Swietojanski and Mostaghimi (2020)	Convolutional Neural Network (CNN)	2D slices of 3D images	7860 slices	Porosity	0,96
Tembely and Alsumaiti (2019)	Convolutional Neural Network (CNN)	3D segmented images	1100	Permeability	0,92
Wu, Yin and Xiao (2018)	Convolutional Neural Network (CNN)	Synthetic 2D images	1960	Permeability	0,92
This paper	Convolutional Neural Network (CNN)	2D thin rock section images	366	Porosity	0,83
				Permeability	0,98

263  
264

265 Among the results obtained, it is noteworthy that the model applied to permeability  
 266 prediction exhibited the highest coefficient of determination, despite having a (MSE) greater  
 267 than that obtained for porosity.

268 Although most of the images used in training are associated with low permeability values,  
 269 the network was able to predict higher permeabilities with good accuracy. The network  
 270 response is quite promising, especially considering that the dataset consists of images obtained  
 271 from carbonate rock samples from the pre-salt layer. These samples are known for their  
 272 heterogeneous framework and complex poroperm behavior.

273 The complexity of poroperm features was indicated in Guasina Oliveira *et al.* (*in press*),  
274 where the different types of voids existing in the carbonate facies of reservoir rocks were  
275 described. This complexity becomes evident when we observe that the permeability values used  
276 in training are imbalanced compared to the porosity values, as few samples have permeability  
277 above 2,000 mD, while porosity data are more evenly distributed, with many samples  
278 containing both high and low porosities (Graphic 1).  
279



280

281 **Graphic 1.** Comparison between porosity and permeability of each rock sample.  
282

283

284 The variation in porosity percentages is closely linked to mineral products and diagenetic  
285 and hydrothermal processes which, throughout the rock's genesis, redistribute the original  
286 porosity, obliterating or enlarging the existing porosity (Guasina Oliveira *et al.*, *in press*).  
287 Permeability, in turn, is related to the number of voids existing in each facies, and more closely,  
288 to the number of connections between these voids.

289

290

291

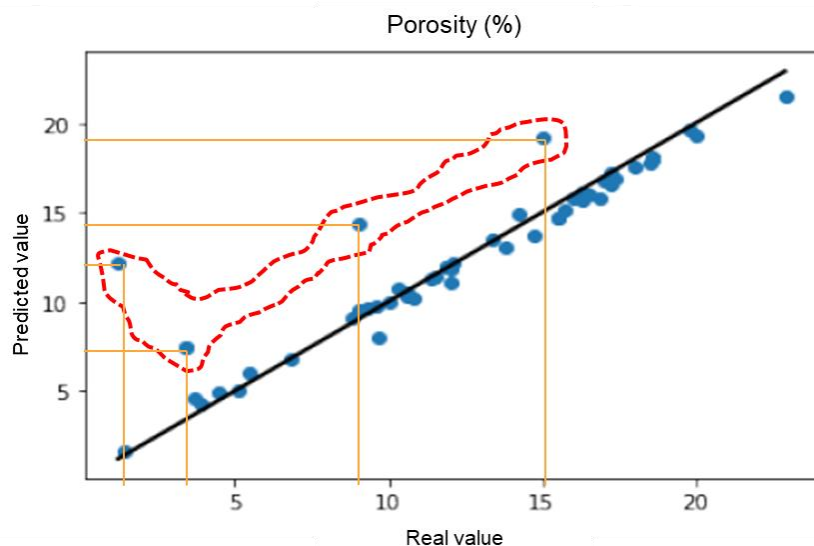
When analyzing point-to-point the values of porosity and permeability for each sedimentary facies, it is observed that they are not always correlated, with the same facies potentially exhibiting either good porosity and low permeability, good porosity and high



292 permeability, or even low porosity and high permeability. This lack of direct relationship  
293 between porosity and permeability values within the same facies was decisive for employing  
294 the same model applied to the parameters individually, thus achieving good predictive values.

295 During testing, some outlier values were observed, primarily related to porosity prediction  
296 (Graph 2). Initially, upon analyzing the permeability data used as output labels, it is noted that  
297 its relationship with the percentages of voids identified in the micrographic images tends to  
298 differ. This occurs because the label values are derived from the analysis of a three-dimensional  
299 sample, while the thin-section image provides a two-dimensional measurement (Figure 7). In  
300 addition to the dimensional difference, there is also a scale difference in what is visible to the  
301 network, as the labels used as void percentages encompass all voids present in the sample,  
302 including the microporosity of the carbonate constituents (Guasina Oliveira *et al.*, *in press*),  
303 while the micrographic image, depending on the magnification used by the equipment, may not  
304 allow the visualization of microporosity (Figure 8).

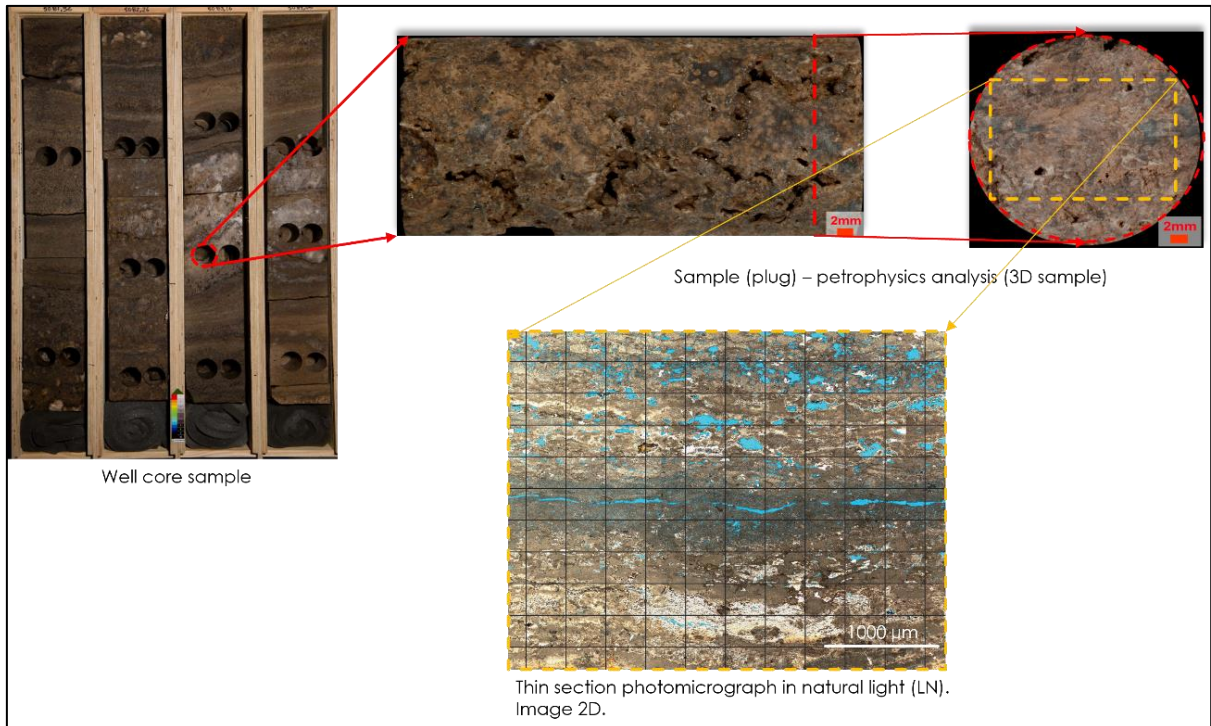
305



306  
307  
308  
309


**Graphic 2.** Outliers obtained during the test phase for porosity prediction. Most values indicate a void (pore) value greater than the actual value.

310



311  
 312  
 313  
 314  
 315


**Figure 7.** Schematic figure depicting the relationship between the input dataset and the output dataset of the neural network: the labels utilized as training output were derived from three-dimensional samples, whereas the input images originate from two-dimensional thin sections.



316  
 317  
 318  
 319  
 320  
 321

**Figure 8.** Image (A) corresponds to a micrograph of a thin section of a rock from the intraclastic *grainstone* facies, where carbonate fragments have developed intracrystalline microporosity. In (B), a detail of the same image obtained using a higher magnification objective (mcp: microporosity). Both micrographs were captured using an optical microscope under natural light (LN).

322 Although these criteria may influence the predicted values of porosity, upon checking the  
 323 outliers, it was identified that they were primarily generated by variations in the tones of the  
 324 images used and by the imbalance in the representation of mudstone facies in the training set  
 325 (Figure 9).




326  
 327 **Figure 9.** Images A, B, C of Intraclast grainstone with varying shades of both mineral content and voids (blue).  
 328 Fine material (mudstone) with differences in tone due to mineral content: D) carbonate predominates and, E)  
 329 microcrystalline silica predominates.  
 330

331       The variation in tone of the micrographic images is primarily related to the mineral  
 332 elements contained within the rock structure. Each constituent of the structure is composed of  
 333 a set of mineral elements arranged in a specific crystalline arrangement, which responds in a  
 334 particular way to the incidence of light used in the optical microscope. This response occurs  
 335 through changes in color, tone, and reflectance. Some minerals, such as quartz, for example,  
 336 exhibit greater brightness in response to light incidence compared to carbonate minerals (Figure  
 337 10).

338       In addition to tone variation, the low representativeness of fine facies like mudstone  
 339 (Guasina Oliveira *et al.*, *in press*), which exhibits very low or absent void content, caused the  
 340 network to fail in recognizing the parameters, contributing to confusion and incorrect responses  
 341 during training.

342



343  
344 **Figure 10.** Photomicrograph highlighting two sets of minerals that respond differently to the lighting used in  
345 optical microscopy: quartz (qz) and carbonate (cb). In blue, interparticle porosity (ip) is indicated. Thin section of  
346 the grainstone facies, captured under natural light (LN).  
347

348  
349 Both the difference in tone of the images and the low representativeness and absence of  
350 permeability in fine facies (mudstone) generated outliers indicating void percentages higher  
351 than the actual values. In both cases, the outliers can be corrected by homogenizing the tones  
352 of the images and adding a greater number of samples from the mudstone facies.

353 Despite the occurrence of these outliers, the network demonstrated excellent performance  
354 in fulfilling the initial proposal of predicting the porosity and permeability of pre-salt carbonate  
355 rocks without the use of additional tools, such as geophysical profiles.

356 As the next steps of this study, new tests will be conducted, expanding the dataset used by  
357 including micrographic images from other wells distributed in the same reservoir. Tests will  
358 also be performed with a hybrid data network, exploring the predictive potential of the method  
359 by including new labels obtained during petrographic description by Guasina Oliveira et al., in  
360 press, which can provide additional information such as interporous mineral material, types of  
361 pores, connections between pore spaces, among others. Thus, by hybridizing the network and

362 expanding the dataset of images, the aim is to confirm the predictive capacity of the applied  
363 methodology.

364 Subsequently, if the predictive capability of the network is confirmed, the same method  
365 could be applied to other types of rocks, such as siliciclastic rocks. These rocks typically have  
366 a more homogeneous structure and may produce favorable predictive results.

367

## 368 **6 Conclusions**

369 The aim of this study was to present the results of using a convolutional neural network to  
370 predict the porosity and permeability of carbonate rocks from the pre-salt Barra Velha  
371 formation, using only a dataset composed of 2D images of thin sections for input and laboratory  
372 porosity and permeability data as output.

373 Pre-salt reservoir rocks are unique and extremely heterogeneous in terms of their poroperm  
374 characteristics, as described by Guasina Oliveira et al. (in press). Due to the lack of correlation  
375 between the porosity and permeability values of the carbonate facies, two trainings were  
376 conducted with the same model, one for porosity prediction and the other for permeability.

377 Some outliers were identified during training and are related to differences in lighting, tone,  
378 and texture of the constituents of the different facies. These outliers were more frequent during  
379 the porosity prediction training, increasing the percentage values of the labels. The low  
380 representation of fine facies (mudstone) may have largely contributed to the lack of recognition  
381 of the poroperm attributes for these lithologies. Despite the outliers, the results obtained were  
382 very good, comparable to models using 3D images.

383 Porosity prediction obtained through the model achieved an  $R^2$  0.8385, MAE 0.0132, MSE  
384 0.0004, and RMSE 0.0209, while the results obtained for permeability prediction using the  
385 model were an  $R^2$  0.9826, MAE 0.0700, MSE 0.0161, and RMSE 0.125.

386           The predictive results obtained indicate excellent potential for the development of the  
387 methodology but require new trainings with an increased dataset, in which all described facies  
388 are represented equally. Similarly, in order to expand the application of the methodology, it is  
389 intended to develop new trainings using a hybrid dataset composed not only of images but also  
390 of labels extracted from the thin section itself, which may influence reservoir quality and  
391 increase the accuracy of the results obtained.

392

### 393 **7 Acknowledgments**

394           This project has been supported by UNISINOS-PETROBRAS Cooperation Agreement  
395 (Contract:5900.0113025.19.9/SAP N° 4600593919). Rita Oliveira thanks to Coordination for  
396 the Improvement of Higher Education Personnel (CAPES) for the Ph.D. scholarship.

397

### 398 **8 Code Availability**

399           Name of the code/library: Modelo Pasini

400           Contact: tuto\_pasini@hotmail.com

401           Program language: Python

402           The source codes are available for downloading at the link:

403           <https://github.com/tutopasini/Prediction-of-carbonate-rocks-permoporous-properties>

404

405

406

407

408

409

410

411

412

413 **References**

414 Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. (2016).

415 {TensorFlow}: a system for {Large-Scale} machine learning. In 12th USENIX  
416 symposium on operating systems design and implementation (OSDI 16) (pp. 265-283).

417 Aggarwal, C.C., 2018. Neural networks and deep learning. *Springer, 10*, pp.978-3.

418 Akbar, M., Vissapragada, B., Alghamdi, A.H., Allen, D., Herron, M., Carnegie, A., Dutta, D.,  
419 Olesen, J.R., Chourasiya, R.D., Logan, D. and Stief, D., 2000. A snapshot of carbonate  
420 reservoir evaluation. *Oilfield review, 12*(4), pp.20-21.

421 Alqahtani, N., Alzubaidi, F., Armstrong, R.T., Swietojanski, P. and Mostaghimi, P., 2020.  
422 Machine learning for predicting properties of porous media from 2d X-ray  
423 images. *Journal of Petroleum Science and Engineering, 184*, p.106514.

424 Araya-Polo, M., Alpak, F.O., Hunter, S., Hofmann, R. and Saxena, N., 2018, September. Deep  
425 learning-driven pore-scale simulation for permeability estimation. In *ECMOR XVI-16th*  
426 *European conference on the mathematics of oil recovery* (Vol. 2018, No. 1, pp. 1-14).  
427 European Association of Geoscientists & Engineers.

428 Arel, I., Rose, D.C. and Karnowski, T.P., 2010. Deep machine learning-a new frontier in artificial  
429 intelligence research [research frontier]. *IEEE computational intelligence*  
430 *magazine, 5*(4), pp.13-18.

431 Basso, M., Belila, A.M.P., Chinelatto, G.F., Souza, J.P.D.P. and Vidal, A.C., 2021.  
432 Sedimentology and petrophysical analysis of pre-salt lacustrine carbonate reservoir from  
433 the Santos Basin, southeast Brazil. *International Journal of Earth Sciences, 110*(7),  
434 pp.2573-2595.

435 Bordignon, F., Figueiredo, L.P.D., Exterkoetter, R., Rodrigues, B.B. and Correia, M.D., 2019,  
436 August. Deep learning for grain size and porosity distributions estimation on micro-CT  
437 images. In *Proceedings of the 16th International Congress of the Brazilian Geophysical*  
438 *Society & Expogef* (pp. 1-6).

439 Buryakovsky, L., Chilingar, G.V., Rieke, H.H. and Shin, S., 2012. *Fundamentals of the*  
440 *petrophysics of oil and gas reservoirs*. John Wiley & Sons.

441 Chai, T. and Draxler, R.R., 2014. Root mean square error (RMSE) or mean absolute error  
442 (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model*  
443 *development*, 7(3), pp.1247-1250.

444 Chollet, F., 2017. *Deep learning with Python*. Simon and Schuster. Company. ISBN

445 Faceli, K., Lorena, A.C., Gama, J. and Carvalho, A.C.P.D.L.F.D., 2011. Inteligência artificial:  
446 uma abordagem de aprendizado de máquina. ISBN 9788521618805.

447 Gomes, J.P., Bunevich, R.B., Tedeschi, L.R., Tucker, M.E. and Whitaker, F.F., 2020. Facies  
448 classification and patterns of lacustrine carbonate deposition of the Barra Velha  
449 Formation, Santos Basin, Brazilian Pre-salt. *Marine and Petroleum Geology*, 113,  
450 p.104176.

451 Goodfellow, I., Bengio, Y. and Courville, A., 2016. *Deep learning*. MIT press.

452 Guasina Oliveira, R.F., Goldberg, K., Silveira, A.S., Rigo, S.J., Martins, M.L.J. and Paim, P.S.G.,  
453 2024. Petrography and Genesis of Carbonate Rocks from the Barra Velha Formation  
454 (Santos Basin, Brazil) and Associated Biogenic Structures. *Crethaceous Research* (in  
455 press).

456 Guasina Oliveira, R.F., Rigo, S.J., Chemale Jr, F., Silveira, A.S, da, Paim, P.S.G. 2024.  
457 Prediction of Porosity and Permeability of Carbonate Rocks Using Thin Section Data and  
458 Machine Learning Methods: A Systematic Review. *Petroleum* (in press).



459 Kingma, D.P. and Ba, J.L., 2017. Adam: A method for stochastic optimization, conference paper  
460 at the 3rd International Conference for Learning Representations.

461 Krizhevsky, A., Sutskever, I. and Hinton, G.E., 2012. Imagenet classification with deep  
462 convolutional neural networks. *Advances in neural information processing systems*, 25.

463 LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *nature*, 521(7553), pp.436-444.

464 Lima, B.E.M. and De Ros, L.F., 2019. Deposition, diagenetic and hydrothermal processes in the  
465 Aptian Pre-Salt lacustrine carbonate reservoirs of the northern Campos Basin, offshore  
466 Brazil. *Sedimentary Geology*, 383, pp.55-81.

467 Mitchell, T.M., 1997. *Machine learning* (Vol. 1, No. 9). New York: McGraw-hill.

468 Nielsen, M.A., 2015. *Neural networks and deep learning* (Vol. 25). San Francisco, CA, USA:  
469 Determination press.

470 Ramachandran, P., Zoph, B. and Le, Q.V., 2017. Searching for activation functions. *arXiv*  
471 *preprint arXiv:1710.05941*.

472 Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986. Learning representations by back-  
473 propagating errors. *nature*, 323(6088), pp.533-536.

474 Saikia, P., Baruah, R.D., Singh, S.K. and Chaudhuri, P.K., 2020. Artificial Neural Networks in  
475 the domain of reservoir characterization: A review from shallow to deep  
476 models. *Computers & Geosciences*, 135, p.104357.

477 Schmidhuber, J., 2015. Deep learning in neural networks: An overview. *Neural networks*, 61,  
478 pp.85-117.

479 Sharma, S., 2020. Activation functions in neural networks. *towards data science*, 6(12), pp.310-  
480 316.

481 Sudakov, O., Burnaev, E. and Koroteev, D., 2019. Driving digital rock towards machine learning:  
482 Predicting permeability with gradient boosting and deep neural networks. *Computers &*  
483 *geosciences*, 127, pp.91-98.

484 Tahmasebi, P., Kamrava, S., Bai, T. and Sahimi, M., 2020. Machine learning in geo-and  
485 environmental sciences: From small to large scale. *Advances in Water Resources*, 142,  
486 p.103619.

487 Tembely, M. and AlSumaiti, A., 2019, November. Deep learning for a fast and accurate  
488 prediction of complex carbonate rock permeability from 3D micro-CT images. In *Abu*  
489 *Dhabi International Petroleum Exhibition & Conference*. OnePetro.

490 Tembely, M., AlSumaiti, A.M. and Alameri, W., 2020. A deep learning perspective on predicting  
491 permeability in porous media from network modeling to direct  
492 simulation. *Computational Geosciences*, 24(4), pp.1541-1556.

493 Tembely, M., AlSumaiti, A.M. and Alameri, W.S., 2021. Machine and deep learning for  
494 estimating the permeability of complex carbonate rock from X-ray micro-computed  
495 tomography. *Energy Reports*, 7, pp.1460-1472

496 Valentin, M.B., Bom, C.R., Coelho, J.M., Correia, M.D., Márcio, P., Marcelo, P. and Faria, E.L.,  
497 2019. A deep residual convolutional neural network for automatic lithological facies  
498 identification in Brazilian pre-salt oilfield wellbore image logs. *Journal of Petroleum*  
499 *Science and Engineering*, 179, pp.474-503.

500 Wason, R., 2018. Deep learning: Evolution and expansion. *Cognitive Systems Research*, 52,  
501 pp.701-708.

502 Wu, J., Yin, X. and Xiao, H., 2018. Seeing permeability from images: fast prediction with  
503 convolutional neural networks. *Science bulletin*, 63(18), pp.1215-1222.

504 Yang, L., Wang, S., Chen, X., Chen, W., Saad, O.M., Zhou, X., Pham, N., Geng, Z., Fomel, S.  
505 and Chen, Y., 2022. High-Fidelity Permeability and Porosity Prediction Using Deep  
506 Learning With the Self-Attention Mechanism. *IEEE Transactions on Neural Networks*  
507 *and Learning Systems*.

508 Yang, S. 2017. Fundamentals of Petrophysics – Second Edition – Book Springer Geophysics.  
509 502p.

## CAPÍTULO 6

### 6.1 Discussão dos Resultados

A petrografia das rochas carbonáticas da Formação Barra Velha (Manuscrito I) indicou a ocorrência de três constituintes minerais principais, os quais estruturam o arcabouço das unidades: argila, esferulitos de calcita e calcita fascicular (arborescente). Estes elementos de origem singenética e diagenética consituem os principais elementos que compõe o arcabouço das fácies da Formação Barra Velha, e cujas fácies principais correspondem às fácies mudstone, spherulitestone e shrubstone (Gomes *et al.*, 2020).

Os elementos principais, esferulito e calcita fascicular (arborescente), originaram-se durante a eodiagênese a partir da dissolução das argilas silico-magnesianas singenéticas. Este processo de dissolução deu origem a porosidade secundária da rocha e à precipitação de dolomita e calcita, estas já em um contexto de eodiagênese tardia a início da mesodiagênese.

Durante a eodiagênese tardia e a mesodiagênese, a sílica substituiu parcialmente a calcita dos esferulitos e das formas fasciculares. A sílica pervasiva, no entanto, microcristalina e esferulítica, ocorre em vários momentos, o que indica uma grande variabilidade das condições ambientais lacustres, uma vez que o principal fator de controle da precipitação de sílica é a flutuação do pH. Assim, valores acima de 9 aumentam a solubilidade desse mineral e abaixo dele, o mineral é considerado precipitado. Ademais, nota-se que existe uma relação inversa de solubilidade entre calcita e sílica, uma vez que pH acima de 9 favorece a precipitação da calcita e a dissolução da sílica enquanto que pH abaixo de 9 precipita a sílica e dissolve a calcita (Bustillo, 2010).

Além da sílica diagenética, dados geoquímicos de vários autores (Herlinger Jr *et al.*, 2017; Tritlla *et al.*, 2018; Pietzsch *et al.*, 2018; Tritlla *et al.*, 2019; Lima & De Ros, 2019; Lima *et al.*, 2020; Pietzsch *et al.*, 2020) apontam a presença de diferentes fases de precipitação de quartzo e cujas soluções apontam temperaturas de formação variando de 90 a 170°C sugerindo uma fonte hidrotermal ativa para os fluídos originários.

A presença de estruturas biogênicas dentro dos cristais de calcita fascicular (arborescentes) em intervalos não contínuos existentes ao longo de todo o perfil amostrado nos três poços (02, 14 e 19), sugerem que esses organismos coexistiram no ambiente lacustre mesmo em condições alcalinas, e que foram preservados ainda em vida dentro dos cristais de calcita durante fases de alta saturação do meio, momento este de coalescência dos cristais de esferulito e de formação das calcitas fasciculares (Manuscrito I). Esta supersaturação do meio possivelmente encontra-se associada aos diferentes pulsos de fluxos hidrotermais ascendentes através de falhas do manto para dentro do ambiente lacustre como *vents* subaquosos. Segundo Vieira (2021), imagens sísmicas da mesma área de onde foram obtidas as amostras indicam falhas que devem ter sido as condutoras do fluxo de fluídos ricos em sílica mantélica para dentro das fácies em formação.


Esses fluídos hidrotermais, além da sílica, possibilitaram a precipitação tardia de calcita em mosaico, dolomita em sela, barita e pirita, indicando um fluído inicialmente félsico que aos poucos tornou-se mais básico. Este contexto químico conferiu as rochas da Formação Barra Velha um arcabouço extremamente complexo e heterogêneo cujo conteúdo permo-poroso tornou-se de difícil predição.

Essa complexidade dos eventos de precipitação ocasionados pela gênese química do reservatório influenciou diretamente no arcabouço poroso das rochas que


compõe a Formação Barra Velha. Processos de geração e obliteração da porosidade estão intimamente relacionados a eventos de dissolução, precipitação e recristalização das diferentes fases minerais identificadas nas lâminas delgadas. Essa complexidade de produtos e processos, por sua vez afetam os valores de permeabilidade do reservatório, uma vez que uma mesma fácies possui valores de porosidade e permeabilidade variáveis ao longo dos poços, impedindo a sua correlação direta e a sua predição por métodos geofísicos convencionais.

A partir da análise petrográfica foi possível obter os percentuais dos diferentes elementos que compõe a estrutura da rocha e comparar cada um deles com as permeabilidades obtidas em laboratório ([Planilha Dados Petrográficos](#)). Foram analisados ao todo 21 elementos em lâmina delgada, perfazendo um *dataset* rotulado de 13.734 dados para o total de lâminas descritas. Após a quantificação, os rótulos foram comparados aos valores de permeabilidade física de forma a entender quais dos elementos descritos apresentavam uma relação com a permeabilidade em cada uma das fácies descrita. Ao final da análise, alguns elementos destacaram-se pela correlação positiva com os valores de permeabilidade nas diferentes fácies: minerais precipitados entre os poros (dolomita e calcita / argila / sílica); poros intergranulares (intercristalino) e intragranulares (intracristalino); porosidade total ou absoluta (soma de todos os poros); *vug's* (poros ampliados), conexões (gargantas) e feições amalgamadas (estes últimos identificados qualitativamente).


Um exemplo das correlações feitas está sintetizado nos gráficos abaixo, referentes a fácies *shrubstone* (Gráficos a, b, c e d).




**Gráfico a.** Rótulos que influenciam diretamente nos valores de permeabilidade das fácies *shrubstone*: arcabouço amalgamado (coluna cinza); conexão entre poros (coluna laranja) e *vug* (coluna azul). No eixo *x* são indicadas as profundidades (m) onde ocorrem as fácies *shrubstone* ao longo do poço 02. No eixo *y* o “0” corresponde a ausência de determinado rótulo e “1” a ocorrência do rótulo nas diferentes profundidades descritas. O eixo secundário contém os valores de permeabilidade em mD para cada intervalo descrito. Observa-se que quando há *vug* e conexão entre os poros, mesmo com o arcabouço amalgamado, as permeabilidades são > 1000 mD; quando não há conexão, mesmo que ocorram *vug*'s, havendo um arcabouço amalgamado a permeabilidade cai podendo chegar a 0 mD.



**Gráfico b.** Relação entre a porosidade total obtida em lâmina delgada e os valores de porosidade e permeabilidades de laboratório. A linha azul indica a variação da permeabilidade, a coluna azul escura corresponde a porosidade de lâmina e a coluna azul clara a porosidade de laboratório. No eixo *x* são registradas as profundidades (m) das fácies *shrubstone* no poço 02. No eixo *y* estão representados os percentuais de porosidade enquanto no eixo secundário estão os valores de permeabilidade em mD para cada intervalo descrito. Valores de porosidade total e de laboratório acima de 10% relacionam-se a altas permeabilidades destas fácies; abaixo de 5062,35m as porosidades mantêm valores semelhantes, mas a permeabilidade cai radicalmente indicando ausência de conectividade entre os vazios.




**Gráfico c.** Relação entre a permeabilidade da fácies *shrubstone* com os elementos interpartículas principais descritos em lâmina. A linha azul clara refere-se a permeabilidade da rocha; a linha preta representa o percentual de sílica; a linha rosa representa percentuais de dolomita; a linha amarela indica argila-Mg e a linha azul escura representa a micrita. No eixo *x* são registradas as profundidades (m) das fácies *shrubstone* no poço 02. No eixo *y* estão representados os percentuais dos elementos intersticiais e no eixo secundário estão os valores de permeabilidade em milidarcy (mD) para cada intervalo descrito. A permeabilidade cai quando há maior percentual de dolomita e sílica interpartículas, indicando a obliteração dos espaços porosos ou conexões nestes intervalos devido a cimentação.



**Gráfico d.** Relação entre os poros intergranulares e intragranulares em relação as permeabilidades da fácies *shrubstone*. A linha azul clara refere-se a permeabilidade da rocha; a linha rosa representa o percentual de poro intrapartícula; a linha verde representa percentuais de porosidade interpartícula. No eixo *x* são registradas as profundidades (m) das fácies *shrubstone* no poço 02. No eixo *y* estão representados os percentuais das porosidades interpartícula e intrapartícula e no eixo secundário estão os valores de permeabilidade em milidarcy (mD) para cada intervalo descrito. A permeabilidade parece não depender da porosidade intrapartícula; por vezes a permeabilidade também não apresenta dependência do percentual de porosidade interpartícula, indicando a não dependência destes parâmetros ao longo do perfil amostrado.

Ainda durante a análise modal, foi obtida a porosidade total (ou absoluta) com base na soma de todos os vazios quantificados em lâmina delgada. Essa porosidade total mostrou boa correlação com a porosidade e permeabilidade de laboratório (Gráfico e), indicando um comportamento semelhante à porosidade de laboratório quando confrontada com as permeabilidades reais.





**Gráfico e.** Gráfico contendo a correlação entre a porosidade total obtida em lâmina petrográfica (laranja) e a porosidade de laboratório (azul) *versus* as permeabilidades de laboratório. No eixo *x* os valores de porosidade em % e no eixo *y* valores de permeabilidade em mD. Os rótulos de porosidade demonstram comportamento semelhantes em relação as permeabilidades de cada intervalo.

As correlações feitas entre os diferentes atributos, a porosidade e a permeabilidade de laboratório demonstram que embora haja alta complexidade entre estes elementos, a petrografia pode estabelecer as relações entre estes elementos indicando quais são as variáveis que influenciam na permeabilidade e no padrão do arcabouço, condicionando assim o fluxo de fluídos.

De maneira genérica, as relações entre as fácies identificadas e os atributos descritos em lâmina delgada demonstram que a fácies *in situ shrubstone* e as fácies retrabalhadas *grainstone* e *rudstone* intraclásticos, possuem as melhores propriedades reservatório.

Na fácies *shrubstone* a estrutura de crescimento arborescente dos cristais preserva a porosidade primária, enquanto a porosidade interpartícula secundária gerada a partir da dissolução predomina nas fácies não amalgadas e nas fácies retrabalhadas como os *grainstones* e *rudstones*.

Por sua vez, o processo de dissolução e a percolação de fluídos ricos em sílica, auxiliam na ampliação da porosidade secundária existente e na dissolução de

constituintes minerais primários que compõe o arcabouço gerando vug's e ampliando a conexão entre os poros, processo este também elencado por Matheus *et al.*, (2023).

Nas tabelas 2 e 3 é possível ver que cada rótulo (parâmetro) descrito na petrografia influencia de forma negativa ou positiva os percentuais de porosidade e os valores de permeabilidades de cada uma das fácies descrita. Estes rótulos posteriormente podem ser utilizados para a identificação das petrofácies reservatório e para comporem *datasets* específicos para a predição.

**Tabela 1.** Relação de porosidade de laboratório com as porosidades total e efetiva obtidas através da planilha.

Fácies	% $\phi$ total x % $\phi$ laboratório	% $\phi$ efetiva x % $\phi$ laboratório	% $\phi$ laboratório x % cimento interporo	% $\phi$ laboratório x % sílica	% $\phi$ total x $\phi$ efetiva x K (mD)
Shrubstone	≠	Tendência $\cong / > \phi$ laboratório	Indiferente	Inversa	Tendência $\cong$
Spherulitestone	=	Tendência $\cong / > \phi$ laboratório	Inversa	Inversa	Tendência $\cong$
Mudstone	$> \phi$ total	Tendência $\cong / > \phi$ laboratório	Indiferente	Indiferente	Indiferente
Retrabalhadas	$\cong$	Tendência $\cong / > \phi$ laboratório	Inversa	-	Indiferente
Brecha	=	Tendência $\cong / > \phi$ laboratório	Indiferente	Não se aplica	Indiferente

\* Relação entre as porosidades total e efetiva com os valores de permeabilidade de laboratório.

Diante a complexa relação dos diferentes rótulos e os valores de porosidade e permeabilidade definiu-se que o primeiro teste preditivo seria realizado com um *dataset* composto por imagens micrográficas a partir das lâminas delgadas descritas. Desta forma, foi selecionada uma rede neural convolucional (CNN), considerando ser esta a rede mais utilizada para o treinamento com imagens, conforme as pesquisas bibliográficas indicaram (Manuscrito II).

**Tabela 2.** Relação da permeabilidade (K) com os parâmetros (rótulos) obtidos na petrografia.

Fácies	$K (mD) \times$ $\% \phi$ total	$\% \phi$ efetiva $\times$ $\% K (mD)$	$\%$ dolomita/ calcita interporo	$\%$ sílica	$\%$ argila	Tipo poro	Vug	Textura amalgamada	Pp	Contato entre grãos
Shrubstone	Tendência $\cong /$ $> \phi$ total	$\neq$	Independente	Inversa	Não se aplica	I ntercristalino	Não se aplica	Influencia	Não se aplica	Não se aplica
Spherulitestone	Tendência $\cong /$ $> \phi$ total	$\neq$	Inversa	Inversa	Inversa	Intercristalino, Intracristalino	Influencia	Influencia	Não se aplica	Não se aplica
Mudstone	Tendência $\cong /$ $> \phi$ total	$\neq$	Independente	Inversa	Não se aplica	Móldico	Influencia	Não se aplica	Não se aplica	Não se aplica
Retrabalhadas	Tendência $\cong /$ $> \phi$ total	$\neq$	Inversa	Inversa	Inversa	Intergranular, móldico	Influencia	Não se aplica	inversa	Inversa
Brecha	Tendência $\cong /$ $> \phi$ total	$\neq$	Inversa	Inversa	Não se aplica	Fratura, intercristalino	Influencia	Não se aplica	Não se aplica	Não se aplica

O primeiro treinamento (Manuscrito III) utilizou imagens micrográficas selecionadas do poço 02, considerando a distribuição das fácies em profundidade e a quantidade de imagens micrográficas disponíveis.

Os resultados obtidos nos testes feitos com o *dataset* de imagens aplicado a uma CNN foram ótimos, com valores de porosidade de  $R^2$  de 0.8385, MAE de 0.0132, MSE de 0.0004 e RMSE de 0.0209 e, de permeabilidade de  $R^2$  de 0.9826, MAE de 0.0700, MSE de 0.0161 e RMSE de 0.1256 (Manuscrito III).

O coeficiente obtido com esse treinamento para os valores de permeabilidade foi superior ao resultado obtido por Jamshidi Gohari *et al.*, (2021) para os valores de permeabilidade,  $R^2$  de 0.97, utilizando um *dataset* composto por imagens 150 imagens de lâminas delgadas aplicado ao algoritmo de retropropagação de Levenberg-Marquardt (Manuscritos II e III).

Embora os nossos resultados preditivos para porosidade e permeabilidade tenham sido muito bom, se comparados com resultados de outros trabalhos usando *dataset* semelhante (Manuscritos II e III), alguns *outliers* foram identificados como

relacionados à qualidade das imagens e a pouca representatividade de certas fácies, no caso específico em relação as fácies de mudstone, as quais são pouco representativas no poço 02.


Os resultados indicaram que o processo preditivo é bastante promissor ao utilizar um *dataset* de imagens, mesmo para rochas com alta complexidade como as rochas heterogêneas da Formação Barra Velha. O modelo de rede convolucional com poucos *layers* conseguiu prever tanto a porosidade quanto a permeabilidade, mas de forma distinta uma propriedade por vez, o que parece ter facilitado o treinamento tendo em vista a baixa correlação apresentada para os dois atributos.

A análise petrográfica feita preliminarmente mostrou o quanto é diverso o sistema poroso do reservatório com um arcabouço poroso heterogêneo refletindo as interações dos elementos físicos, químicos e bióticos descritos na tese a partir das lâminas delgadas (Manuscrito I). Como, por exemplo, o percentual elevado de fases interpartículas associadas à cimentação dolomítica e a precipitação extensiva de sílica. Neste caso, a ocorrência de material intersticial preenchendo poros pode interferir diretamente nos valores de porosidade e permeabilidade, uma vez que tanto a porosidade quanto a permeabilidade são relações que consideram a existência de vazios no arcabouço.

O coeficiente obtido com a predição da porosidade é resultante da falta de relação destacada entre a porosidade e a permeabilidade, demonstrando a ação das diferentes variáveis na conformação do arcabouço das rochas da Formação Barra Velha. A integração das informações obtidas durante a petrografia auxiliou a identificar as variáveis que interferiram nos resultados preditivos da rede, principalmente aqueles relacionados com os resultados de porosidade ( $R^2$  0,88). A maior parte dos *outliers*

identificados em lâmina delgada relacionados a porosidade quando analisados em profundidade, indicam que embora a arquitetura funcione bem para arcabouços mais homogêneos, para arcabouços complexos ainda há necessidade de se detalhar melhor os diferentes elementos que compõe o arcabouço como, por exemplo, os diferentes tipos de poros e a ocorrência de conexões e as relações destes elementos com o conteúdo de poros x permeabilidades.

A maior parte dos *outliers* verificados na predição da porosidade estão relacionados aos aspectos texturais como microporosidades interpartículas e as conexões. Esses atributos, quando não reconhecidos pela rede neural, ocasionam *outliers* relacionados a valores superestimados ou subestimados de porosidade. Exemplo deste tipo de *outlier* textural está indicado na figura 14, onde os valores de porosidade foram superestimados ou subestimados de acordo com o percentual visual de porosidade.




**Figura 14.** Amostras contendo *outliers* identificados relacionados a textura do arcabouço da rocha, na fácies shrubstone: os valores de teste obtidos para porosidade estão subestimados ou superestimados de acordo com a característica visual da amostra.

## 6.2 Trabalhos em Andamento

Atualmente, novos testes estão sendo feitos com um conjunto maior de imagens em formato de fotomosaicos obtidas de amostras dos três poços utilizados neste trabalho (poços 02, 14 e 19).

Os primeiros resultados obtidos indicaram que o caráter preditivo da rede está intimamente ligado a um bom balanceamento dos dados em relação a distribuição das diferentes fácies e com o uso de imagens com boa resolução e contraste homogêneo (livres de estruturas e mineralogias contrastantes), fazendo com que seja necessário selecionar previamente as imagens usadas no treinamento (Figura 15).



**Figura 15.** Exemplos de fotomontagens excluídas do treinamento: A) Imagem ondulada e com marcas de *merged*; B) escala gráfica sobre a imagem; C) diferenças de iluminação e contraste de minerais; D) imagem pouco nítida e escura.

Além do treinamento com imagens, outros dois testes estão sendo conduzidos em paralelo: o primeiro tem como objetivo criar uma rede híbrida (CNN + um algoritmo de predição) para a predição de porosidade e de permeabilidade utilizando um *dataset* composto por imagens e por rótulos obtidos com a petrografia, o segundo visa a

predição petrofácies reservatório (De Ros & Goldbger, 2007) a partir do *dataset* obtido durante a descrição petrográfica.

Os primeiros resultados com a rede híbrida para predição da porosidade e da permeabilidade estão sendo obtidos mas ainda não são conclusivos, porém observa-se uma tendência de melhora dos resultados com a composição ampliada de dados de entrada. A hibridização da rede tem como finalidade gerar um *dataset* mais robusto que possa, com o detalhamento de diversos atributos, minimizar os *outliers* identificados como procedentes da heterogeneidade do arcabouço, como aqueles descritos na figura 14.

Para esta fase será utilizada a planilha gerada durante a petrografia, a qual é composta de colunas e linhas onde cada linha refere-se a uma determinada amostra (lâmina petrográfica) obtida a uma determinada profundidade no poço e cada coluna, compreendendo um determinado parâmetro descrito durante a fase de análise das lâminas ([Planilha Dados Petrográficos](#)).

Apartir das análises feitas entre os diferentes rótulos descritos *versus* as permeabilidades, os atributos que serão parte da rede híbrida considerados como parâmetros permo-porosos correspondem aos seguintes rótulos:

- ✓ % de cimento interporos;
- ✓ % de argila;
- ✓ % de sílica
- ✓ % de vazios (poro interpartícula e intrapartícula; porosidade total).

Outros elementos estão sendo utilizados com base no grau de relevância em relação a sua influência para uma maior permeabilidade da rocha, isto é, “3” é considerado o elemento com maior influência para o aumento da permeabilidade e “0”

o elemento que mais prejudica ou menos influencia na permeabilidade de determinada fácies. Se encaixaram neste item os parâmetros: ‘contatos entre grãos do arcabouço’ e ‘coeficientes de empacotamento’, utilizáveis apenas para as fácies retrabalhadas.

- ✓ Contatos entre os grãos do arcabouço: **0 – contatos suturados; 1 – contatos concavo-convexos; 2 – contatos retos e pontuais; 3 – contatos flutuantes.**
- ✓ Coeficiente de empacotamento: **0 – fechado; 2 – normal; 3 - frouxo**

Além disso os parâmetros ‘vug’, ‘conexões’ (“garganta” entre poros) e ‘textura amalgamada’ (esta comum na fácies *shrubstone*) são registrados de acordo com a sua presença na lâmina delgada, sendo “0” (não ocorrem) e “1” (ocorrem).

Nos primeiros testes utilizando a rede híbrida, os *outliers* gerados estão associados novamente a qualidade das imagens utilizadas e ao desbalanceamento dos dados. Novos testes estão sendo previstos de forma a corrigir os *outliers* e melhorar a arquitetura da rede.

Para a predição das petrofácies reservatório foram realizados dois testes diferentes utilizando o mesmo método de predição (*Decision Tree*) para o mesmo *dataset* de dados petrográficos ([Planilha Dados Petrográficos](#)).

O primeiro teste foi realizado separando os dados petrográficos planilhados em dois grupos correspondentes a duas classes (*cutoffs*) de permeabilidades, uma baixa e outra alta, esta última com *cutoff* acima de 100 mD. Esse primeiro teste obteve uma acurácia de 0.91 para os valores de baixas permeabilidade e de 0.80 para os valores de alta permeabilidade.


O segundo teste para a predição das petrofácies utilizou os dados petrográficos e cinco classes (*cutoffs*) de permeabilidades definidas a partir das relações entre os diferentes atributos descritos na petrografia e as variações das permeabilidades de



laboratório. De acordo com as correlações petrográficas os *cutoffs* das permeabilidades ( $K$ ) foram:

- $K$  até 50 mD - petrofácies 1;
- $K$  de 60 mD até 100 mD – petrofácies 2;
- $K$  de 200 mD até 500 mD – petrofácies 3;
- $K$  de 600 mD até 1000 mD – petrofácies 4;
- $K > 1000$  mD – petrofácies 5.

Foram excluídos do treinamento os parâmetros cuja categorização é qualitativa e não quantitativa como a litologia, os tipos contatos entre grãos (fácies retrabalhadas), a ocorrência de *vugs*, as conexões e as feições amalgamadas. Esse teste obteve uma acurácia de 0.92 entre os valores reais e os valores preditos (Figura 16).



**Figura 16.** Gráfico de correlação entre as petrofácies reais e as petrofácies preditas para os poços 02, 14 e 19.

### 6.3 Contribuições da Tese

As principais contribuições desta tese são:

- Descrição petrográfica de lâminas delgadas da Formação Barra Velha no campo de Sapinhoá na Bacia de Santos, classificando-as e descrevendo a mineralogia, diagênese, porosidade, ocorrência de microfósseis e sugerindo uma proposição para a gênese das rochas;
- Ineditismo do uso de dados puramente petrográficos do pré-sal para gerar anotações passíveis de serem utilizadas em processos de predição de atributos permo-porosos;
- Construção de um *dataset* com dados petrográficos quantitativos associado a imagens micrográficas e fotomontagens;
- Desenvolvimento de uma metodologia para predição de porosidade e permeabilidades de rochas carbonáticas através de dados petrográficos sem o uso de dados geofísicos;
- Construção de uma arquitetura específica para a predição de porosidade e permeabilidade através de imagens 2D;
- Trabalhos em desenvolvimento relacionados a predição de petrofácies através de dados petrográficos e através de uma abordagem multimodal para a predição de porosidade e permeabilidade através de uma rede híbrida.

### 6.4 Considerações Finais

O uso de imagens digitais micrográficas como conjunto de dados de entrada para uma rede neural convolucional aplicada à predição da porosidade e da permeabilidade parece ser bastante promissor, mostrando bons resultados mesmo

para rochas cujo arcabouço se mostra heterogêneo, como as rochas da Formação Barra Velha. Com os novos testes que estão sendo gerados, confirmando-se os bons resultados, essa metodologia poderá minimizar a necessidade de uso de dados geofísicos, agilizando o processo preditivo e ampliando a possibilidade de predição da porosidade e da permeabilidade para outras áreas da geologia.

Entretanto, considerando a representatividade dos dados de uma lâmina delgada em relação a escala de reservatório, o *upscaling* dos dados deve ser considerado posteriormente, bem como o uso de outros tipos de imagens para compor o *dataset*, como imagens obtidas de microtomografia computadorizada de raios-x (micro-CT), imagens de testemunhos de sondagem ou mesmo imagens tomográficas.

## Referências Bibliográficas

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Zheng, X. (2016). {TensorFlow}: a system for {Large-Scale} machine learning. In 12th USENIX symposium on operating systems design and implementation (OSDI 16) (pp. 265-283).
- Abed, R.M., Dobrestov, S., Al-Kharusi, S., Schramm, A., Jupp, B. and Golubic, S. (2011). Cyanobacterial diversity and bioactivity of inland hypersaline microbial mats from a desert stream in the Sultanate of Oman. *Fottea*, 11(1), pp.215-224.
- Adriano, M. S., Figueiredo, J. P., Coelho, P. H. G. R., & Borghi, L. (2022). Tectonic and stratigraphic evolution of the Santos Basin rift phase: New insights from seismic interpretation on Tupi oil field area. *Journal of South American Earth Sciences*, 116, 103842.
- Aggarwal, C.C. (2018). Neural networks and deep learning. *Springer*, 10, pp.978-3.
- Akbar, M., Vissapragada, B., Alghamdi, A.H., Allen, D., Herron, M., Carnegie, A., Dutta, D., Olesen, J.R., Chourasiya, R.D., Logan, D. and Stief, D. (2000). A snapshot of carbonate reservoir evaluation. *Oilfield review*, 12(4), pp.20-21.
- Al-Kharusi, A.S. & Blunt, M.J. (2007). Network extraction from sandstone and carbonate pore space images, *Journal of Petroleum Science and Engineering*, Volume 56, Issue 4, pages 219-231.
- Alqahtani, N., Alzubaidi, F., Armstrong, R.T., Swietojanski, P. and Mostaghimi, P. (2020). Machine learning for predicting properties of porous media from 2d X-ray images. *Journal of Petroleum Science and Engineering*, 184, p.106514.
- Alvarenga, R. S., Iacopini, D., Kuchle, J., Scherer, C. M. S., & Goldberg, K. (2016). Seismic characteristics and distribution of hydrothermal vent complexes in the Cretaceous offshore rift section of the Campos Basin, offshore Brazil. *Marine and Petroleum Geology*, 74, 12-25.

- Andrew, M. (2020). Permeability prediction using multivariant structural regression. In: E3S Web of Conferences. EDP Sciences, p. 04001.
- Araya-Polo, M., Alpak, F.O., Hunter, S., Hofmann, R. and Saxena, N. (2018). September. Deep learning-driven pore-scale simulation for permeability estimation. In *ECMOR XVI-16th European conference on the mathematics of oil recovery* (Vol. 2018, No. 1, pp. 1-14). European Association of Geoscientists & Engineers.
- Arel, I., Rose, D.C. and Karnowski, T.P. (2010). Deep machine learning-a new frontier in artificial intelligence research [research frontier]. *IEEE computational intelligence magazine*, 5(4), pp.13-18.
- Arienti, L. M., Souza, R. S., Viana, S., Cuglieri, M. A., Silva, R. P., Tonietto, S., ... & Gil, J. A. (2018). Facies association, depositional systems, and paleophysiographic models of the Barra Velha Formation, pre-salt sequence—Santos Basin, Brazil. In AAPG ACE 2018.
- Asmus, H. E., Baisch, P. H. (1983). Geological evolution of the Brazilian Continental Margin. *Episodes: Journal of International Geoscience*, v. 4, p. 3-9.
- Azerêdo, A.C., Duarte, L.V. and Silva, A.P. (2021). The challenging carbonates from the Pre-Salt reservoirs offshore Brazil: facies, palaeoenvironment and diagenesis. *Journal of South American Earth Sciences*, 108, p.103202.
- Bardola, T.P. (2015). Caracterizacão paleoambiental dos carbonatos microbiais do Membro Crato, Formação Santana, Aptiano-Albiano da Bacia do Araripe. M.Sc. Thesis, Universidade Federal do Rio Grande do Sul, Brazil. 147pp.
- Barili, R., Marconatto, L., Oliveira, D.M. and De Ros, L.F. (2019). Colloid microfossils (cyanobacteria?) from Brazil Pre-Salt. Bathurst Meeting Mallorca. 16th International Meeting of Carbonate Sedimentologists. Theme 4: South Atlantic Pre-Salt Carbonates and Potential Analogs. pp. 164.

- Basso, M., Belila, A.M.P., Chinelatto, G.F., Souza, J.P.D.P. and Vidal, A.C. (2021). Sedimentology and petrophysical analysis of pre-salt lacustrine carbonate reservoir from the Santos Basin, southeast Brazil. *International Journal of Earth Sciences*, 110(7), pp.2573-2595.
- Bernabé, Y., Mok, U., & Evans, B. (2003). Permeability-porosity relationships in rocks subjected to various evolution processes. *Pure and Applied Geophysics*, 160, 937-960.
- Berryman, J. G., & Wang, H. F. (2000). Elastic wave propagation and attenuation in a double-porosity dual-permeability medium. *International Journal of Rock Mechanics and Mining Sciences*, 37(1-2), 63-78.
- Bordignon, F., Figueiredo, L.P.D., Exterkoetter, R., Rodrigues, B.B. and Correia, M.D. (2019, August). Deep learning for grain size and porosity distributions estimation on micro-CT images. In *Proceedings of the 16th International Congress of the Brazilian Geophysical Society & Expogef* (pp. 1-6).
- Brownfield ME, Charpentier RR (2006) Geology and total petroleum systems of the West-Central Coastal Province (7203), West Africa. *US Geol Surv Bull* 2207:52
- Bueno, G. V. (2004). Diacronismo de eventos no rifte Sul-Atlântico. *Boletim de Geociências da Petrobras*, v. 12, n. 2, p. 203-229.
- Burne, R. V., & Moore, L. S. (1987). Microbialites: organosedimentary deposits of benthic microbial communities. *Palaios*, 241-254.
- Buryakovsky, L., Chilingar, G.V., Rieke, H.H. and Shin, S. (2012). *Fundamentals of the petrophysics of oil and gas reservoirs*. John Wiley & Sons.
- Cainelli, C. e Mohriak, W. U. (1999). General evolution of the eastern Brazilian continental margin. *The Leading Edge*, v. 18, n. 7, p. 800-805.
- Carramal, N.G., Oliveira, D. M., Cacela, A.S.M., Cuglieri, M.A.A., Rocha, N.P. Viana, S.M.

- Toledo, S.L.V., Pedrinha, S. and De Ros, L.F. (2022). "Paleoenvironmental insights from the deposition and diagenesis of Aptian pre-salt magnesium silicates from the Lula Field, Santos Basin, Brazil." *Journal of Sedimentary Research* 92, no. 1: 12-31.
- Carvalho, A., Faceli, K., Lorena, A., Gama, J. 2011. *Inteligência Artificial – uma abordagem de aprendizado de máquina*. Rio de Janeiro: LTC, p. 45, 2011.
- Carvalho, A. M. A., Hamon, Y., De Souza Jr, O. G., Carramal, N. G., & Collard, N. (2022). Facies and diagenesis distribution in an Aptian pre-salt carbonate reservoir of the Santos Basin, offshore Brazil: A comprehensive quantitative approach. *Marine and Petroleum Geology*, 141, 105708.
- Catto, B., Jahnert, R.J., Warren, L.V., Varejao, F.G. and Assine, M.L., 2016. The microbial nature of laminated limestones: Lessons from the Upper Aptian, Araripe Basin, Brazil. *Sedimentary Geology*, 341, pp.304-315
- Crispino & Sant'Anna, 2006
- Ceraldi, T.S. & Green, D. (2016). Evolution of the South Atlantic lacustrine deposits in response to Early Cretaceous rifting, subsidence and lake hydrology. In: Ceraldi TS, Hodgkinson RA, Backe G (eds) *Petroleum geoscience of the West Africa Margin*, vol 438. Geological Society, London, p 77.
- Chafetz, H. S., & Guidry, S. A. (1999). Bacterial shrubs, crystal shrubs, and ray-crystal shrubs: bacterial vs. abiotic precipitation. *Sedimentary Geology*, 126(1-4), 57-74.
- Chai, T. & Draxler, R.R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), pp.1247-1250.
- Chang, H. K., Kowsmann, R. O., Figueiredo, A. M. F., & Bender, A. (1992). Tectonics and stratigraphy of the East Brazil Rift system: an overview. *Tectonophysics*, 213(1-2), 97-138.

- Charlaftis, D., Jones, S. J., Grimm, L., & Kappler, A. (2023). Interdependence between bacterial EPS and early grain coat development. *Terra Nova*, 35(4), 241-249.
- Chilingar, G. V., Bissell, H. J., & Fairbridge, R. W. (2011). *Carbonate rocks*. Elsevier.
- Chollet, F. (2017). *Deep learning with Python*. Simon and Schuster. Company. ISBN 9781617294433.
- Choquette, P. W., & Pray, L. C. (1970). Geologic nomenclature and classification of porosity in sedimentary carbonates. *AAPG bulletin*, 54(2), 207-250.
- Clevert, D.A., Unterthiner, T. & Hochreiter, S. (2015). Fast and accurate deep network learning by exponential linear units (elus). *arXiv preprint arXiv:1511.07289*.
- Crispino, L.M.B. & Sant'Anna, C.L. (2006). Cianobactérias marinhas bentônicas de ilhas costeiras do Estado de São Paulo, Brasil. *Brazilian Journal of Botany*, 29, pp.639-656.
- De Ros, L. F. & Goldberg, K. 2007. Reservoir Petrofacies: A Tool for Quality Characterization and Prediction. *Search and Discovery Article #50055*.
- Dehler, N., Magnavita, L., Gomes, L., Rigoti, C., Oliveira, J., Sant'anna, M. & Costa, F. (2016). The '*Helmut*' geophysical anomaly: A regional left-lateral transtensional shear zone system connecting Santos and Campos basins, southeastern Brazil. *Marine and Petroleum Geology*. 72. 10.1016/j.marpetgeo.2016.01.012.
- Dias, J. L., 2005. Tectônica, estratigrafia e sedimentação no Andar Aptiano da margem leste brasileira. *Boletim de Geociências da Petrobras*, v. 13, n. 1, p. 7 -25.
- Dorobek, Steve, Leo Piccoli, Brian Coffey, & Aaron Adams. (2012) "Carbonate rock-forming processes in the Pre-salt "sag" successions of Campos Basin, offshore Brazil: evidence for seasonal, dominantly abiotic carbonate precipitation, substrate controls, and broader geologic implications." In AAPG Hedberg Conference "Microbial Carbonate Reservoir Characterization" Houston Texas.



- Duarte-Coronado, D., Tellez-Rodriguez, J., Pires de Lima, R., Marfurt, K., Slatt, R. (2019). Deep convolutional neural networks as an estimator of porosity in thin-section images for unconventional reservoirs. In: SEG Technical Program Expanded Abstracts 2019. Society of Exploration Geophysicists, p. 3181-3184.
- Esmaeili, B., Hosseinzadeh, S., Kadkhodaie, A., Wood, D. A., & Akbarzadeh, S. (2024). Simulating reservoir capillary pressure curves using image processing and classification machine learning algorithms applied to petrographic thin sections. *Journal of African Earth Sciences*, 209, 105098.
- Erofeev, A., Orlov, D., Ryzhov, A. & Koroteev, D. (2019). Prediction of porosity and permeability alteration based on machine learning algorithms. *Transport in Porous Media*, 128(2), pp.677-700.
- Faceli, K., Lorena, A.C., Gama, J. and Carvalho, A.C.P.D.L.F.D. (2011). *Inteligência artificial: uma abordagem de aprendizado de máquina*. ISBN 9788521618805.
- Fairchild, T.R., Rohn, R. and Dias-Brito, D. (2015). *Microbialitos do Brasil do Pré-Cambriano ao Recente: um atlas*.
- Falcão, L. C. (2015). *Estudo faciológico de um intervalo aptiano do poço SB-1 (Bacia de Santos) e sua comparação com travertinos quaternários de San Juan, Argentina*. 2015. 118 f. Dissertação (Mestrado) – Instituto de Geociências, Universidade Federal Fluminense, Niterói.
- Flügel E. (2010). *Microfacies of carbonate rocks: analysis, interpretation and application*. Springer, Berlin, p 983.
- Foster, J. B. (1964). Evolution of mammals on islands. *Nature*, 202(4929), 234-235.
- Fouke, B. W. (2011). Hot-spring Systems Geobiology: abiotic and biotic influences on travertine formation at Mammoth Hot Springs, Yellowstone National Park, USA. *Sedimentology*, 58(1), 170-219.

- García-del-Cura, M. Á., Benavente, D., Martínez-Martínez, J., & Cueto, N. (2012). Sedimentary structures and physical properties of travertine and carbonate tufa building stone. *Construction and Building Materials*, 28(1), 456-467.
- García Ruiz, J.M. (1998). Carbonate precipitation into alkaline silica-rich environments. *Geology*, 26(9), 843-846.
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. " O'Reilly Media, Inc.". ISBN 9781492032595.
- Gierlowski-Kordesch E.H. (2010). Lacustrine carbonates. In: Alonzo-Zarza AM, Tanner LH (eds) *Carbonates in continental settings*. Developments in sedimentology. Elsevier, Amsterdam, pp 1–10161.
- Gomes, J.P., Bunevich, R.B., Tedeschi, L.R., Tucker, M.E. and Whitaker, F.F. (2020). Facies classification and patterns of lacustrine carbonate deposition of the Barra Velha Formation, Santos Basin, Brazilian Pre-salt. *Marine and Petroleum Geology*, 113, p.104176.
- Goodfellow, I., Bengio, Y., Courville, A. (2016). Machine learning basics. *Deep learning*, v. 1, n. 7, p. 98-164.
- Harbaugh, J.W. (1967). Carbonate oil reservoir rocks. In *Developments in sedimentology* (Vol. 9, pp. 349-398). Elsevier.
- He, K., Zhang, X., Ren, S. and Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision* (pp. 1026-1034).
- Heaton, J. (2015). *Artificial Intelligence for Humans, Volume 3: Neural Networks and Deep Learning*. sl: Heaton Research. Inc.: *Chesterfield, UK*.

- Heine, C., Zoethout, J.; Muller, R. D. (2013). Kinematics of the South Atlantic rift. *Solid Earth*, v. 4, n. 2, p. 215-253, 2013.
- Herlinger Jr, R., Zambonato, E.E. and De Ros, L.F. (2017). Influence of diagenesis on the quality of Lower Cretaceous pre-salt lacustrine carbonate reservoirs from northern Campos Basin, offshore Brazil. *Journal of Sedimentary Research*, 87(12), pp.1285-1313.
- Hinton, G.E., Srivastava, N., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R.R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.
- Holland, P.W. & Welsch, R.E. (1977). Robust regression using iteratively reweighted least-squares. *Communications in Statistics-theory and Methods*, 6(9), pp.813-827.
- Hosa, A., Wood, R. A., Corbett, P. W. M., de Souza, R. S., & Roemers, E. (2020). Modelling the impact of depositional and diagenetic processes on reservoir properties of the crystal-shrub limestones in the 'Pre-Salt' Barra Velha Formation, Santos Basin, Brazil. *Marine and Petroleum Geology*, 112, 104100.
- Ionescu, D., Volland, J. M., Contarini, P. E., & Gros, O. (2023). Genomic Mysteries of Giant Bacteria: Insights and Implications. *Genome Biology and Evolution*, 15(9), evad163.
- Jamshidi Gohari, M. S., Emami Niri, M., & Ghiasi-Freez, J. (2021). Improving permeability estimation of carbonate rocks using extracted pore network parameters: a gas field case study. *Acta Geophysica*, 69, 509-527.
- Joel, L. (2016). How did fragile early microbes become fossils? *Eos*, 97, <https://doi.org/10.1029/2016EO057519>.
- Kingma, D.P. & Ba, J.L. (2017). Adam: A method for stochastic optimization, conference paper at the 3rd International Conference for Learning Representations.

- Klambauer, G., Unterthiner, T., Mayr, A. & Hochreiter, S. (2017). Self-normalizing neural networks. *Advances in neural information processing systems*, 30.
- Keshari, N., Zhao, Y., Das, S. K., Zhu, T., & Lu, X. (2022). Cyanobacterial community structure and isolates from representative hot springs of Yunnan Province, China using an integrative approach. *Frontiers in microbiology*, 13, 872598.
- Krizhevsky, A., Sutskever, I. & Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Kubat, M., & Kubat, J. A. (2017). An introduction to machine learning (Vol. 2, pp. 321-329). Cham, Switzerland: Springer International Publishing.
- Lavier, L. L., Manatschal, G. (2006). A mechanism to thin the continental lithosphere at magma-poor margins. *Nature*, v. 440, n. 7082, p. 324-328.
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *nature*, 521(7553), pp.436-444.
- LeCun, Y., Bottou, L., Bengio, Y. & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp.2278-2324.
- Lima, B.E.M. & De Ros, L.F. (2019). Deposition, diagenetic and hydrothermal processes in the Aptian Pre-Salt lacustrine carbonate reservoirs of the northern Campos Basin, offshore Brazil. *Sedimentary Geology*, 383, pp.55-81.
- Lucia, F. J. (1983). Petrophysical parameters estimated from visual descriptions of carbonate rocks: a field classification of carbonate pore space. *Journal of petroleum technology*, 35(03), 629-637.
- Lucia, F. J., & Lucia, F. J. (1999). Rock-Fabric, Petrophysical Parameters, and Classification. *Carbonate Reservoir Characterization*, 23-57.
- Maas, A.L., Hannun, A.Y. & Ng, A.Y. (2013). Rectifier nonlinearities improve neural network acoustic models. In *Proc. icml* (Vol. 30, No. 1, p. 3).

- Macedo, J. M. (1989). Evolução tectônica da Bacia de Santos e áreas continentais adjacentes. *Boletim de Geociências da Petrobras*, v. 3, n. 3, p. 159-173.
- Mareš, J., Johansen, J.R., Hauer, T., Zima Jr, J., Ventura, S., Cuzman, O., Tiribilli, B. and Kaštovský, J. (2019). Taxonomic resolution of the genus *Cyanothece* (Chroococcales, Cyanobacteria), with a treatment on *Gloeothece* and three new genera, *Crocospaera*, *Rippkaea*, and *Zehria*. *Journal of Phycology*, 55(3), pp.578-610.
- Matheus, G. F., Basso, M., da Ponte Souza, J. P., & Vidal, A. C. (2023). Digital Rock Analysis Based on X-ray Computed Tomography of a Complex Pre-salt Carbonate Reservoir from the Santos Basin, SE Brazil. *Transport in Porous Media*, 150(1), 15-44.
- Mckenzie, D. (1978). Some remarks on the development of sedimentary basins. *Earth and Planetary science letters*, v. 40, n. 1, p. 25-32.
- Meisling, K. E., Cobbold, P. R., Mount, V. S. (2001). Segmentation of an obliquely rifted margin, Campos and Santos basins, southeastern Brazil. *AAPG bulletin*, v. 85, n. 11, p. 1903-1924.
- Meister, P., Reyes, C., Beaumont, W., Rincon, M., Collins, L., Berelson, W., ... & Nealson, K. H. (2011). Calcium and magnesium-limited dolomite precipitation at Deep Springs Lake, California. *Sedimentology*, 58(7), 1810-1830.
- Milani, E., Oliveira, J., Dias, Jefferson & Szatmari, Peter & Cupertino, José. (2018). Basement control on structural styles and sediment pathways of SE Brazil Atlantic margin basins - AAPG International Conference, Paris, 2005.
- Mitchell, T.M. (1997). *Machine learning* (Vol. 1, No. 9). New York: McGraw-hill.
- Mizusaki, A. M. P., Petrini, R., Bellieni, P., Comin-Chiaramonti, P., Dias, J., De Min, A., & Piccirillo, E. M. (1992). Basalt magmatism along the passive continental margin of SE Brazil (Campos Basin). *Contributions to Mineralogy and Petrology*, 111, 143-160.

- Mio, E., Chang, H. K., Corrêa, F. S. (2005). Integração de métodos geofísicos na modelagem crustal da Bacia de Santos. *Revista brasileira de Geofísica*, v. 23, n. 3, p. 275-284.
- Mohri, M., Rostamizadeh, A. & Talwalkar, A. (2018). *Foundations of machine learning*. MIT press.
- Moreira, J.L.P., Madeira, C.V., Gil, J.A. & Machado, M.A.P. (2007). Bacia de Santos. Boletim de Geociências da PETROBRAS, 15(2), pp.531-549.
- Moore, C.H. and Wade, W.J. (2013). *Carbonate reservoirs: Porosity and diagenesis in a sequence stratigraphic framework*. Newnes.
- Moulin, M., Aslanian, D. Unternehr, P. (2010). A new starting point for the South and Equatorial Atlantic Ocean. *Earth-Science Reviews*, v. 98, n. 1-2, p. 1-37.
- Mohriak W, Nemčok M, Enciso G (2008) South Atlantic divergent margin evolution: rift-border uplift and salt tectonics in the basins of SE, Brazil, vol 294. Geological Society, London, pp 365–398
- Muniz, M.C. and Bosence, D.W.J. (2015). Pre-salt microbialites from the Campos Basin (offshore Brazil): image log facies, facies model and cyclicity in lacustrine carbonates. Geological Society, London, Special Publications, 418(1), pp.221-242.
- Nair, V. and Hinton, G.E. (2010, January). Rectified linear units improve restricted boltzmann machines. In *icml*.
- Nakano CMF, Pinto ACC, Marcusso JL, Minami K (2009) Pre-salt Santos Basin-extended well test and Production Pilot in the Tupi area-the planning phase. In: Offshore technology conference pp 1–8
- Nielsen, M.A. (2015). *Neural networks and deep learning* (Vol. 25). San Francisco, CA, USA: Determination press.

- Nwankpa, C., Ijomah, W., Gachagan, A. and Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- Peate, D. W. (1997). The Paraná-Etendeka Province. In: MAHONEY, J. J.; COFFIN, M. F. (Eds.) *Large Igneous Provinces: Continental, Oceanic, and Planetary Flood Volcanism*. Washington, DC: American Geophysical Union. p. 217-245. ISBN 0-87590-082-8.
- Pereira, M. J. e Macedo, J. M. (1990). A Bacia de Santos: perspectivas de uma nova província petrolífera na plataforma continental sudeste brasileira. *Boletim de Geociências da Petrobras*, v. 4, n. 1, p. 3-11.
- Pereira, M. J. e Feijó, F. J. (1994). Bacia de Santos. *Boletim de Geociências da Petrobras*, v. 8, n. 1, p. 219-234.
- Peron-Pinvidic, G., Manatschal, G., Osmundsen, P. T. (2013). Structural comparison of archetypal Atlantic rifted margins: A review of observations and concepts. *Marine and Petroleum Geology*, v. 43, p. 21-47.
- Pia, G. and Sanna, U. (2014). An intermingled fractal units model and method predict permeability in porous rock. *International Journal of Engineering Science* 75. 31–39.
- Pietzsch, R., Oliveira, D.M., Tedeschi, L.R., Neto, J.V.Q., Figueiredo, M.F., Vazquez, J.C. and de Souza, R.S. (2018). Palaeohydrology of the Lower Cretaceous pre-salt lacustrine system, from rift to post-rift phase, Santos Basin, Brazil. *palaeogeography, Palaeoclimatology, Palaeoecology*, 507, pp.60-80.
- Pietzsch, R., Tedeschi, L. R., Oliveira, D. M., dos Anjos, C. W. D., Vazquez, J. C., & Figueiredo, M. F. (2020). Environmental conditions of deposition of the Lower

Cretaceous lacustrine carbonates of the Barra Velha Formation, Santos Basin (Brazil), based on stable carbon and oxygen isotopes: a continental record of pCO<sub>2</sub> during the onset of the Oceanic Anoxic Event 1a (OAE 1a) interval?. *Chemical Geology*, 535, 119457.

Pozo, M., & Casas, J. (1999). Origin of kerolite and associated Mg clays in palustrine-lacustrine environments. The Esquivias deposit (Neogene Madrid Basin, Spain). *Clay Minerals*, 34(3), 395-418.

Rabbani, A., Assadi, A., Kharrat, R., Dashti, N., Ayatollahi, S. (2017). Estimation of carbonates permeability using pore network parameters extracted from thin section images and comparison with experimental data. *Journal of Natural Gas Science and Engineering*, v. 42, p. 85-98.

Ramachandran, P., Zoph, B. & Le, Q.V. (2017). Searching for activation functions. *arXiv preprint arXiv:1710.05941*.

Rehim, H. A. A. A., Mizusaki, A. M. P., Carvalho, M. D., & Monteiro, M. (1986, October). Talco e estevensita na Formação Lagoa Feia da bacia de Campos-possíveis implicações no ambiente deposicional. In *Anais XXXIV Congresso Brasileiro de Geologia* (Vol. 1, pp. 416-422).

Rezende, M.F. & Pope, M.C. (2015). Importance of depositional texture in pore characterization of subsalt microbialite carbonates, offshore Brazil. *Geological Society, London, Special Publications*, 418(1), pp.193-207.

Riccomini, C., Sant, L.G. and Tassinari, C.C.G. (2012). Pré-sal: geologia e exploração. *Revista Usp*, (95), pp.33-42.

Riding, R. (2006). Microbial carbonate abundance compared with fluctuations in metazoan diversity over geological time. *Sedimentary Geology*, 185(3-4), 229-238.



- Rigoti, C. A. (2015). *Evolução tectônica da Bacia de Santos com ênfase na geometria crustal: Interpretação integrada de dados de sísmica de reflexão e refração, gravimetria e magnetometria*. 2015. 134 f. Dissertação (Mestrado) – Faculdade de Geologia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro.
- Rodrigues, K.C. (2015). Caracterização petrográfica dos “carbonatos” laminados do Membro Crato, Bacia do Araripe, Nordeste do Brasil. Senior Thesis, Universidade Federal do Rio Grande do Sul, Brazil. 167pp.
- Rossetti, L. M., Lima, E. F., Waichel, B. L., Scherer, C. M., & Barreto, C. J. (2014). Stratigraphical framework of basaltic lavas in Torres Syncline main valley, southern Parana-Etendeka Volcanic Province. *Journal of South American Earth Sciences*, 56, 409-421.
- Rumelhart, D.E., Hinton, G.E. & Williams, R.J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), pp.533-536.
- Russel, S. & Norvig, P. (2012). Artificial intelligence - a modern approach 3rd Edition. *The Knowledge Engineering Review*, 11(1), pp.78-79.
- Saikia, P., Baruah, R.D., Singh, S.K. & Chaudhuri, P.K. (2020). Artificial Neural Networks in the domain of reservoir characterization: A review from shallow to deep models. *Computers & Geosciences*, 135, p.104357.
- Schrank, A. B. S., Dos Santos, T., Altenhofen, S. D., Freitas, W., Cembrani, E., Haubert, T., ... & De Ros, L. F. (2024). Interactions between Clays and Carbonates in the Aptian Pre-Salt Reservoirs of Santos Basin, Eastern Brazilian Margin. *Minerals*, 14(2), 191.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, pp.85-117.

- Sharma, M. & Shukla, Y. (2012). Occurrence of helically coiled microfossil *Obruchevella* in the Owk Shale of the Kurnool Group and its significance. *Journal of earth system science*, 121(3), pp.755-768.
- Sharma, S. (2020). Activation functions in neural networks. *towards data science*, 6(12), pp.310-316.
- Schulz-Vogt, H. N., Angert, E. R., & Garcia-Pichel, F. (2007). Giant bacteria. *eLS*.
- Skansi, S. (2018). *Introduction to Deep Learning: from logical calculus to artificial intelligence*. Springer.
- Salman, V., Bailey, J. V., & Teske, A. (2013). Phylogenetic and morphologic complexity of giant sulphur bacteria. *Antonie Van Leeuwenhoek*, 104, 169-186.
- Saller, A., Rushton, S., Buambua, L., Inman, K., McNeil, R. and Dickson, J.T. (2016). Presalt stratigraphy and depositional systems in the Kwanza Basin, offshore Angola. *Aapg Bulletin*, 100(7), pp.1135-1164.
- Sallun Filho, W. (1999). Análise dos estromatólitos do Grupo Itaiacoca (Proterozóico), ao sul de Itapeva, SP. Unpublished M. Sc. Dissertation, Instituto de Geociências, Universidade de São Paulo, São Paulo, SP, Brazil.
- Silva, F. N. 2020. Regra das Ilhas e genética quantitativa evolutiva do tamanho corporal em *Elephas maximus borneensis*. Dissertação (Mestrado em Genética e Biologia Molecular) – UFG. 40 p.
- Silva, AA, Tavares, MW, Carrasquilla, A., Misságia, R., Ceia, M. 2020. Petrofacies classification using machine learning algorithms. *Geophysics*, v. 85, n. 4, p. WA101-WA113.

- Souza-Egipsy, V., Wierzchos, J., Ascaso, C., & Nealson, K. H. (2005). Mg–silica precipitation in fossilization mechanisms of sand tufa endolithic microbial community, Mono Lake (California). *Chemical Geology*, 217(1-2), 77-87.
- Song, Z. Q., Wang, F. P., Zhi, X. Y., Chen, J. Q., Zhou, E. M., Liang, F., ... & Li, W. J. (2013). Bacterial and archaeal diversities in Yunnan and Tibetan hot springs, China. *Environmental microbiology*, 15(4), 1160-1175.
- Sudakov, O., Burnaev, E. and Koroteev, D., 2019. Driving digital rock towards machine learning: Predicting permeability with gradient boosting and deep neural networks. *Computers & geosciences*, 127, pp.91-98.
- Strugale, M., Cartwright, J., Robb, L., Roberts, N., & Bouch, J. (2023, June). Ages and Diagenetic Settings of Tectonic Events in the Presalt Succession in the North Campos Basin. In 84th EAGE Annual Conference & Exhibition (Vol. 2023, No. 1, pp. 1-5). European Association of Geoscientists & Engineers.
- Tahmasebi, P., Kamrava, S., Bai, T. and Sahimi, M., 2020. Machine learning in geo-and environmental sciences: From small to large scale. *Advances in Water Resources*, 142, p.103619.
- Tembely, M. and AlSumaiti, A., 2019, November. Deep learning for a fast and accurate prediction of complex carbonate rock permeability from 3D micro-CT images. In *Abu Dhabi International Petroleum Exhibition & Conference*. OnePetro.
- Tembely, M., AlSumaiti, A.M. and Alameri, W., 2020. A deep learning perspective on predicting permeability in porous media from network modeling to direct simulation. *Computational Geosciences*, 24(4), pp.1541-1556.
- Tembely, M., AlSumaiti, A.M. and Alameri, W.S., 2021. Machine and deep learning for estimating the permeability of complex carbonate rock from X-ray micro-computed tomography. *Energy Reports*, 7, pp.1460-1472

- Terra, G., Spadini, A., França, A., Sombra, C., Zambonato, E., Juschaks, L., Arienti, L., Erthal, M., Blauth, M., Franco, M., Matsuda, N., Carramal da Silva, N., Moretti, P., Davila, R., Souza, R., Tonietto, S., Anjos, S., Campinho, V., Winter, W. (2010). Classificação de rochas carbonáticas aplicável às bacias sedimentares brasileiras. *Boletim de Geociencias - Petrobras*. 18. 9-29.
- Tian, J., Qi, C., Sun, Y., Yaseen, Z. M., Pham, B. T. 2020. Permeability prediction of porous media using a combination of computational fluid dynamics and hybrid machine learning methods. *Engineering & Computers*, v. 2020.
- Thiede, D.S. e Vasconcelos, P.M., 2010. Paraná flood basalts: rapid extrusion hypothesis confirmed by new  $40\text{Ar}/39\text{Ar}$  results. *Geology*, 38(8), pp.747-750.
- Torsvik, T. H., Rousse, S., Labails, C., & Smethurst, M. A. (2009). A new scheme for the opening of the South Atlantic Ocean and the dissection of an Aptian salt basin. *Geophysical Journal International*, 177(3), 1315-1333.
- Tosca, N. & Wright, V. (2015). Diagenetic pathways linked to labile Mg-clays in lacustrine carbonate reservoirs: A model for the origin of secondary porosity in the Cretaceous pre-salt Barra Velha Formation, offshore Brazil. *Geological Society, London, Special Publications*. 435. 10.1144/SP435.1.
- Tritlla, J., Esteban, M., Loma, R., Mattos, A., Sánchez, V., Boix, C., & Levresse, G. (2018). Carbonates that are no more: Silicified pre-salt oil reservoirs in Campos Basin (Brazil). *AAPG ACE*, 106-108.
- Tritlla, J., Esteban, M., Loma, R., Mattos, A., Sanders, C., Vieira De Luca, P. H., ... & Carballo, J. (2019, July). Where have most of the carbonates gone? Silicified Aptian pre-salt microbial (?) carbonates in South Atlantic basins (Brazil and Angola). In *Proceedings*

of the Bathurst Meeting Mallorca 2019 16th International Meeting of Carbonate Sedimentologists, Palma de Mallorca, Spain (pp. 9-11).

Unternehr, P., Péron-Pinvidic, G., Manatschal, G., & Sutra, E. (2010). Hyper-extended crust in the South Atlantic: in search of a model. *Petroleum Geoscience*, 16(3), 207-215.

Valentin, M.B., Bom, C.R., Coelho, J.M., Correia, M.D., Márcio, P., Marcelo, P. and Faria, E.L. (2019). A deep residual convolutional neural network for automatic lithological facies identification in Brazilian pre-salt oilfield wellbore image logs. *Journal of Petroleum Science and Engineering*, 179, pp.474-503.

Van Der Land, C; Wood, R.; Wu, K.; Van Duke, M.I.; Jiang, Z.; Corbett, O.W.; Couples, G. (2013). Modelling the permeability Evolution of carbonate rocks. *Marine and Petroleum Geology*, 48. P. 1-7.

Vieira, A.O. (2021). Syn- and post-depositional silicification in a pre-salt carbonate reservoir: a case study in the Santos Basin (SE Brazil). Monography. Masters dissertation. University of Vale do Rio dos Sinos (UNISINOS), Brazil.

Vonshak, A. (1997). *Spirulina Platensis (Arthrospira)* (pp. 43-65). London: Taylor & Francis.

Xia, Y., Cai, J., Wei, W., Hu X., Wang, X., Ge, X. (2018). A new method for calculation fractal dimensions of porous media based on pore size distribution. *Fractais*, Vol. 26, No.01, 1850006.

Yalamanchi, P., & Datta Gupta, S. (2024). Estimation of pore structure and permeability in tight carbonate reservoir based on machine learning (ML) algorithm using SEM images of Jaisalmer sub-basin, India. *Scientific Reports*, 14(1), 930.

Yang, L., Wang, S., Chen, X., Chen, W., Saad, O.M., Zhou, X., Pham, N., Geng, Z., Fomel, S. and Chen, Y., 2022. High-Fidelity Permeability and Porosity Prediction Using

DeepLearning With the Self-Attention Mechanism. *IEEE Transactions on Neural Networks and Learning Systems*.

Yang, S. 2017. Fundamentals of Petrophysics – Second Edition – Book Springer Geophysics. 502p.

Wason, R., 2018. Deep learning: Evolution and expansion. *Cognitive Systems Research*, 52, pp.701-708.

Wernicke, B. (1985). Uniform-sense normal simple shear of the continental lithosphere. *Canadian Journal of Earth Sciences*, v. 22, n. 1, p. 108-125.

Wright, V.P. and Barnett, A.J. (2015). An abiotic model for the development of textures in some South Atlantic early Cretaceous lacustrine carbonates. Geological Society, London, Special Publications, 418(1), pp.209-219.

Wu, J., Yin, X. and Xiao, H., 2018. Seeing permeability from images: fast prediction with convolutional neural networks. *Science bulletin*, 63(18), pp.1215-1222.

Wu, H., Fang, W.Z., Kang, Q., Tao, W.Q., Qiao, R. (2019). Predicting Effective Diffusivity of Porous Media from Images by Deep Learning. Scientific Reports, Nature Publishing Group, v. 9, n. 1, p. 1–12.

Zalán, P., Severino, M.C.G, Rigoti, C., Magnavita, L., Oliveira, J.A.B. & Viana, A. (2011). An Entirely New 3-D View of the Crustal and Mantle Structure of a South Atlantic Passive Margin – Santos, Campos and Espírito Santo Basins, Brazil.

Zhang, Z., & Cai, Z. (2021). Permeability prediction of carbonate rocks based on digital image analysis and rock typing using random forest algorithm. *Energy & Fuels*, 35(14), 11271-11284.