

RAFAEL ANDRELLO RUBO

**Petrografia Digital: quantificação e caracterização de minerais,
poros, texturas e litofácies com base em inteligência artificial**

Santos

2022

RAFAEL ANDRELLO RUBO

**Petrografia Digital: quantificação e caracterização de minerais,
poros, texturas e litofácies com base em inteligência artificial**

Versão Corrigida

**Tese apresentada à Escola Politécnica
da Universidade de São Paulo para
obtenção do título de Doutor em
Ciências**

Área de Concentração:
Engenharia Mineral

Orientador:
Prof. Dr. Cleyton de Carvalho Carneiro

Santos
2022

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 05 de agosto de 2022

Assinatura do autor: Rafael Andrello Rubo

Assinatura do orientador: Cleiton de C. Carneiro

Catálogo-na-publicação

Rubo, Rafael Andrello

Petrografia Digital: quantificação e caracterização de minerais, poros, texturas e litofácies com base em inteligência artificial / R. A. Rubo -- versão corr. -- São Paulo, 2022.

200 p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Minas e de Petróleo.

1.Petrografia Digital 2.Inteligência Artificial 3.Aprendizado de Máquina
I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Minas e de Petróleo II.t.

Nome: RUBO, Rafael Andrello.

Título: Petrografia Digital: quantificação e caracterização de minerais, poros, texturas e litofácies com base em inteligência artificial.

Tese apresentada à Escola Politécnica da Universidade de
São Paulo para obtenção do título de Doutor em Ciências.

Aprovado em: 08/06/2022

Banca Examinadora

Prof. Dr. Cleyton de Carvalho Carneiro

Instituição: Escola Politécnica da Universidade de São Paulo

Julgamento: Aprovado

Prof. Dr. Alexandre Campana Vidal

Instituição: Universidade Estadual de Campinas

Julgamento: Aprovado

Prof. Dra. Lena Virginia Soares Monteiro

Instituição: Instituto de Geociências da Universidade de São Paulo

Julgamento: Aprovado

Prof. Dr. Afonso Paiva Neto

Instituição: Instituto de Ciências Matemáticas e de Computação da Universidade de
São Paulo

Julgamento: Aprovado

Prof. Dr. Pedro Tupã Pandava Aum

Instituição: Universidade Federal do Pará

Julgamento: Aprovado

DEDICATÓRIA

*À minha amada esposa, Nicole.
Às filhas preciosas, Isabela e Beatriz.
Aos queridos pais, Elisabete e Eduardo.*

AGRADECIMENTOS

Agradeço ao orientador desta pesquisa, Prof. Dr. Cleyton de Carvalho Carneiro. Foi muito além da orientação, incentivou e impulsionou a pesquisa, transformando minha vida profissional e pessoal. Tornou-se um grande amigo.

Ao colega e amigo Dr. Mateus Fontana Michelin, que foi o orientador Petrobras nesta pesquisa. Este trabalho foi muito enriquecido com sua perspectiva e direcionamento.

Aos professores Dr. Rafael Gioria e Dr. Afonso Paiva. Ambos contribuíram com etapas fundamentais de minha formação para o desenvolvimento da pesquisa.

Aos professores que contribuíram como avaliadores do trabalho, atuando como banca e suplentes dos exames de qualificação e defesa: Dra. Carina Ulsen, Dra. Lena Monteiro, Dr. Pedro Aum, Dr. Guilherme Barreto, Dr. Alexandre Vidal, Dra. Anna Reali, Dr. Caetano Juliani e Dra. Michelle Kuroda.

À Escola Politécnica da Universidade de São Paulo, em especial ao Departamento de Engenharia Mineral e de Petróleo. Agradeço aos professores Dra. Ana Carolina Chieregati, Dr. Giorgio Cesare de Tomi, Dr. Marcio Sampaio, Dr. Carlos Frederico Almeida, Dr. Ronaldo Carrion, Dr. Ricardo Cabral de Azevedo. Aos funcionários: Regiane, Patrícia, Beleza e Olga.

À Petrobras, pela anuência e interesse nesta pesquisa, em particular aos gestores André Henrique, Jorge Polônia, Mariana Torquato, Celso Murakami, Otaviano Neto, Roberto D'Ávila, Laura Mastella, Francisco Aquino, Jeferson Kinzel e Mário Carminatti.

À ANP, pela regulamentação e autorização de uso de dados públicos em pesquisa acadêmica, devidamente comunicada para este trabalho através de sua Superintendência de Dados Técnicos.

À NVidia, por ter doado à Universidade de São Paulo uma placa *Titan Xp*, através de *GPU Grant*, no contexto desta pesquisa. Em particular, ao Dr. Pedro Mário Cruz e Silva, pelo incentivo e orientação.

Agradecimento especial aos amigos e colegas de trabalho Edgar Bronizeski e Hugo Saar. Este trabalho foi discutido diariamente com eles, ao longo das Rodovias Anchieta e Imigrantes, no percurso entre a Grande São Paulo e Santos. Também ao Wilson Nakamura, que me recebeu tão bem nos dias em que fiquei em Santos.

Ainda vinculados à Petrobras, agradeço aos colegas Yaro Parizek Silva, Rodrigo Surmas, Cristiano Gonçalves, Lucas Blanes, Saulo Bertolino, Felipe Gorla, Maurílio Salgado, Reinaldo Tavares, Marcelus Glaucus, Tiago Leviski, Paulo Lee, Paulo Zanconato, Matheus Cuglieri, Sandra Tonietto, Paloma Guimarães, Bruno de Paula, Bruno Rodrigues, Nilo Matsuda, Marcelo Rezende, Marcelo Albuquerque, William Trevizan, Marcelo Abbehusen, Marcelo Amaral, Paulo Moretti, Eveline Zambonato, Sofia Correia, Manuel Bonnet, Diogo Buck, Leandro Thomaz, Kayo Dias, José Marcelo Bueno, Cláudia Moré, Sirlene Coelho, Julice Santos, Pascoal Perrella, Michelsen Wurdig, Diego Bortholoto, Felipe Garcia da Costa, Bruno Jeiss.

Aos colegas do Programa de Pós-Graduação, pesquisadores do InTra e orientandos do Prof. Cleyton: Luiz Felipe, Rodrigo, Nathalia, Mayara e Bruno.

Por fim, agradeço à minha família, pela compreensão, dedicação e incentivo para realização desta etapa tão significativa de minha formação. Especialmente à minha esposa Nicole, filhas Isabela e Beatriz, pais Elisabete e Eduardo. De forma complementar, contribuindo com minha formação como cidadão, estendo o agradecimento aos avós: Geraldo e Iracema, Maria (*in memoriam*) e José (*in memoriam*); tios: José Henrique, Lúcia, Jeferson, Luciano e Lalau; primos: Antonio, Giovanna, Letícia, Gustavo, João Pedro e Antonio; sogros: Maga, Oma Lene (*in memoriam*) e Richard; cunhados: Tephi, Lipi e Bárbara; sobrinha e afilhada: Marcela. Agradeço a todos os demais familiares e amigos que marcaram minha trajetória com amor e alegria.

RESUMO

RUBO, Rafael Andrello. **Petrografia Digital: quantificação e caracterização de minerais, poros, texturas e litofácies com base em inteligência artificial**. 2022. 197 f. Tese (Doutorado em Ciências) – Departamento de Engenharia de Minas e de Petróleo, Escola Politécnica, Universidade de São Paulo, São Paulo, 2022.

Imagens petrográficas representam uma grande e eficiente fonte de informação geológica. No contexto da exploração e produção de petróleo, estas imagens obtidas por microscopia óptica permitem a descrição dos atributos mineralógicos, texturais e porosos das amostras de rochas, tais como aquelas coletadas nos poços de petróleo. Estas informações são fundamentais à caracterização dos reservatórios de petróleo. Neste trabalho, métodos computacionais de inteligência artificial são utilizados para identificação e classificação de texturas, porosidades e litofácies observadas por petrografia de lâminas delgadas, ocasionando incremento do caráter quantitativo para interpretações referentes ao ambiente deposicional e alterações diagenéticas a que as rochas foram submetidas. As lâminas petrográficas delgadas foram confeccionadas a partir de amostras laterais carbonáticas da seção Pré-Sal de poços da Bacia de Santos. Imagens adquiridas de luz transmitida das lâminas serviram como dado de treinamento para modelos de: (i) segmentação, (ii) detecção de objeto e (iii) classificação, com diferentes configurações. Os modelos são baseados em algoritmos de aprendizado de máquina que permitem interpretar dados de maneira padronizada e eficiente. São precedidos por uma etapa de aplicação de filtros convolucionais que prevê extrair uma grande quantidade de atributos, capazes de representar as feições de interesse. Os algoritmos classificadores utilizados foram *random forest*, redes neurais artificiais e redes neurais convolucionais. Associados à segmentação, foram treinados modelos de mapeamento mineralógico e de porosidade. Estes modelos foram avaliados através da correlação com dados de análise química – R^2 com medidas de microanálise = 0,82 – e petrofísica – RMSE de densidade de sólidos = $0,031 \text{ g/cm}^3$ –, além da obtenção da acurácia utilizando validação cruzada – 98,78% para modelos de segmentação mineralógica e 99,97% para modelos de segmentação de porosidade. O modelo de detecção de fragmentos fosfáticos foi treinado aplicando o conceito de detecção de objetos – apresentou 97,16% de acurácia na validação cruzada. Modelos de classificação foram treinados, precedidos por diferentes técnicas de *data augmentation*, incluindo transformações espectrais, geométricas e a confecção de imagens sintéticas auxiliada por redes generativas adversariais. O melhor modelo para identificação automática de litofácies apresentou acurácia de 86,34% nos dados de teste. Para classificar tipos de porosidade, o melhor modelo obtido apresentou 95,70% de acurácia para dados de teste. Além das métricas de avaliação dos modelos, as predições foram comparadas às interpretações de petrógrafos, obtidas por meio de entrevistas. Esta etapa evidenciou particularidades associadas à incerteza na definição dos rótulos dos dados utilizados para treinamento dos modelos, derivada de diferentes vieses interpretativos. Os resultados demonstram que técnicas de inteligência artificial aumentam o caráter quantitativo da análise petrográfica, auxiliando os processos de descrição, tornando-os mais ágeis, padronizados e destacando ambiguidades na interpretação.

Palavras-chave: Petrografia; Inteligência Artificial; Aprendizado de Máquina.

ABSTRACT

RUBO, Rafael Andrello. **Digital Petrography: quantification and characterization of minerals, pores, textures and lithofacies based on artificial intelligence**. 2022. 197 f. Tese (Doutorado em Ciências) – Departamento de Engenharia de Minas e de Petróleo, Escola Politécnica, Universidade de São Paulo, São Paulo, 2022.

Petrographic images represent a large and efficient source of geological information. In the context of oil exploration and production, these microscope-obtained images allow the description of mineralogical, textural and porous features from rock samples, such as the ones collected from oil wells. These are vital information for the reservoir characterization. Artificial intelligence techniques are applied to identify and classify textures, porosity and lithofacies observed in thin section petrography, in order to increase quantitative characteristics for interpretations of depositional environment and diagenetic alterations to which the rocks may have been submitted. Petrographic thin sections were prepared from carbonatic lateral rock samples of the Pre-Salt section of wells, Santos Basin. Images acquired from transmitted light of the thin sections served as training data to: (i) segmentation, (ii) object detection, and (iii) classification models, with different configurations. The models are based on machine learning algorithms that allow interpreting data in a standard and efficient manner. They are preceded by the application of convolutional filters that extract a great number of attributes which are able to represent the features of interest. Artificial neural networks, convolutional neural networks and random forest were the classifier algorithms. Mineralogical mapping and porosity models were trained segmentation models. These models were evaluated through correlations with chemical – R^2 with microanalysis measures = 0.82 – and petrophysical data – RMSE of density of solids = 0.031 g/cm³. Accuracies – 98.78% for mineralogical segmentation models and 99.97% for porosity segmentation models – were obtained through cross validation. A phosphatic fragments detection model was trained according to the concept of object detection – 97.16% of accuracy in cross validation. Classification models were trained, preceded by different data augmentation techniques, including spectral and geometric transformations and preparation of synthetic images using generative adversarial networks. The best model for automatic identification of lithofacies had an accuracy of 86.34% in the test data. For classifying porosity types, the best model had 95.70% accuracy in the test data. Beyond regular evaluation metrics, model predictions were compared to petrographers' interpretations, obtained through interviews. These interviews highlighted issues related to the uncertainty in tagging data, due to a number of interpretative biases. Results show that the use of artificial intelligence techniques increase the quantitative features from the petrographic analysis, assisting description processes to be faster, standardized and highlighting ambiguities in interpretation.

Keywords: Petrography; Artificial Intelligence; Machine Learning.

PRÓLOGO

Desde a utilização do conceito de algoritmos no contexto da máquina universal proposta por Turing (1937) e do neurônio artificial proposto por McCulloch e Pitts (1943), o desenvolvimento da inteligência artificial tornou-se inevitável. Desenvolvimento este auxiliado por computadores e baseado em interações que simulam o cérebro de organismos inteligentes. Ainda na década de 1950, Samuel (1959) desenvolve o primeiro programa que utiliza conceitos fundamentais em inteligência artificial e introduz o termo *machine learning* – traduzido nesta tese como aprendizado de máquina.

O desenvolvimento da inteligência artificial é um tema que carrega forte relação emocional com a sociedade. Uma das perspectivas que causa grande apreensão é a substituição da mão de obra humana por máquinas e dispositivos no âmbito do trabalho e produção. A perda de função, seguida pela perda do emprego, gera ressentimentos, muitas vezes dirigidos às máquinas. Estes ressentimentos vêm sendo alimentados desde o século XVIII, com o início da Revolução Industrial.

Em um primeiro momento, a energia a vapor começa a substituir a força humana para realização de atividades de movimentação e transporte. O desenvolvimento das atividades produtivas associados aos motores movidos a vapor ficou conhecido como a Primeira Revolução Industrial. Outros dois marcos tecnológicos caracterizam as duas fases subsequentes: a descoberta da eletricidade associada à implementação da linha de montagem, no século XIX – Segunda Revolução Industrial; e o desenvolvimento de computadores associados à automação parcial, na segunda metade do século XX – Terceira Revolução Industrial.

O quarto marco tecnológico que define o início da próxima fase trata-se da integração dos sistemas de produção auxiliados por computador, através de conexões de rede. Esta fase, frequentemente chamada de “Indústria 4.0”, inicia-se ainda no final do século XX, mas ganha proporções mais significativas no início do século XXI, com a utilização massiva de dispositivos inteligentes que, além de estarem conectados, utilizam redes neurais artificiais e outros conceitos de aprendizado de máquina para a tomada de decisão. Trata-se da expansão da utilização de inteligência artificial em diversos setores da sociedade, simplificando ou eliminando processos.

O momento histórico atual é marcado pelo aparecimento de novos produtos e serviços, como o desenvolvimento de meios de transporte autônomos e

compartilhados, levantamentos aéreos por drones, conexão direta entre fornecedores e clientes de uma grande quantidade de serviços através de aplicativos, desenvolvimento de gêmeos digitais, além da criação de diversos metaversos, que visam atender a uma demanda de digitalização pressionada pela pandemia de Covid-19.

Até então, a sociedade tem assimilado estas mudanças e a forma como as pessoas vivem tornou-se modificada pela tecnologia. Entretanto, houve pouca evolução do ponto de vista social. As desigualdades sociais permanecem fortemente consolidadas. Alguns escritores preveem mudanças sociais impulsionadas por alguns marcos tecnológicos futuros, principalmente relacionados à inteligência artificial. Há uma linha que tende a ser mais otimista, prevendo o desenvolvimento de uma inteligência artificial benevolente, em oposição ao desenvolvimento de uma inteligência artificial aniquiladora que iria causar transformações negativas e que aprofundariam as desigualdades.

A linha otimista é representada pelo pai da ficção científica, H. G. Wells, além de outros ilustres escritores de outras gerações, como Isaac Asimov, Gene Rodenberry e Arthur C. Clark. Nem sempre a inteligência artificial é retratada de forma benevolente, ainda assim, as transformações na sociedade impulsionadas por eventuais conflitos tendem a ser positivas. Já a linha pessimista é representada por autores como George Orwell, Phillip K. Dick e Frank Herbert. Mesmo atrelados a uma visão pessimista, associada à ascensão de Estados totalitários e máquinas inteligentes violentas, estes autores muitas vezes se utilizam de alegorias e de um enredo satírico como crítica sociopolítica. Portanto, o pessimismo em questão deve ser observado considerando o viés irônico e crítico dos autores.

Em um contexto global de pandemia, guerras e negacionismo científico, esta Tese foi desenvolvida com uma perspectiva de visão de futuro otimista, assemelhando-se às defendidas por Rodenberry. Apesar da motivação associada ao desenvolvimento da indústria de Óleo e Gás como pano de fundo deste trabalho, há a expectativa de que os modelos e conclusões obtidos extrapolem ambições financeiras, entre outras falhas da sociedade atual, e possam servir de base científica para a construção de novas interações igualitárias na humanidade. Ainda que restrita à análise quantitativa de rochas, acredita-se que esta contribuição possa integrar um projeto futuro mais amplo de criação de um cérebro artificial treinado em geologia, capaz de integrar um androide que atuará em uma comunidade de indivíduos –

humanos, alienígenas e sintéticos – explorando o universo em um sentimento de colaboração e união.

O desenvolvimento da Petrografia Digital ainda enfrentará diversos paradigmas, como a utilização de métodos estatísticos convencionais. Associado aos ressentimentos acumulados pela incerteza de função da mão de obra especializada, atividades como contagem de pontos em lâminas petrográficas ainda serão realizadas por alguns anos até que a aplicação de modelos de aprendizado de máquina seja popularizada. A superação destes paradigmas deve ser abordada através da utilização de validação e do método científico. Este trabalho tem como ambição contribuir com esta superação. Citando Sagan (1995), “a Ciência é como uma vela na escuridão”.

Além da óbvia influência de alguns autores em minha formação, este espírito otimista de contribuição para uma sociedade mais igual está associado ao exemplo que observo em minha família, principalmente pais e esposa. Ao longo do desenvolvimento desta Tese, tive a oportunidade de me tornar pai de duas meninas. Com o coração carregado de amor e alegria, peço licença à rigidez da forma para apresentar este capítulo de reflexão científica, social e, até mesmo, religiosa, uma vez que atribuo estes fortes sentimentos a uma influência divina.

SUMÁRIO

AGRADECIMENTOS	5
RESUMO	7
ABSTRACT	8
PRÓLOGO	9
1. ASPECTOS INTRODUTÓRIOS	15
1.1. Apresentação	15
1.2. Motivação	16
1.3. Objetivos	18
1.4. Origem das amostras e contexto geológico	19
1.5. Hipótese	21
2. FUNDAMENTOS TEÓRICOS	22
2.1. Rochas carbonáticas	22
2.2. Petrografia Óptica	27
2.2.1. Principais conceitos	27
2.2.2. Preparação das lâminas e equipamentos utilizados	28
2.2.3. Análise petrográfica e resposta óptica das rochas	31
2.3. Espaço de cor e segmentação por limiar (<i>threshold</i>)	32
2.4. Convolução e extração de atributos	34
2.5. Algoritmos de aprendizado de máquina	34
2.5.1. <i>Random Forest</i>	35
2.5.2. Redes Neurais Artificiais	36
2.5.3. Redes Neurais Convolucionais	38
2.5.4. Redes Adversárias Geradoras	40
2.6. <i>Data Augmentation</i>	41
3. MÉTODOS	43
3.1. Modelos de Segmentação	44
3.2. Modelos de Detecção de Objetos	51
3.3. Modelos de Classificação	53
3.3.1. Classificação de litofácies	53
3.3.2. Classificação do tipo de porosidade	67
3.4. Subjetividade interpretativa relacionada aos Petrógrafos	74
4. RESULTADOS	75
4.1. Modelos de Segmentação	75
4.2. Modelos de Detecção de Objetos	83
4.3. Modelos de Classificação	85
4.3.1. Classificação de litofácies	85
4.3.2. Classificação do tipo de porosidade	90
4.4. Subjetividade interpretativa relacionada aos Petrógrafos	94

5. DISCUSSÕES	104
5.1. Modelos de Segmentação.....	104
5.2. Modelos de Detecção de Objetos.....	109
5.3. Modelos de Classificação.....	110
5.3.1. Classificação de litofácies.....	110
5.3.2. Classificação do tipo de porosidade.....	115
5.4. Subjetividade interpretativa relacionada aos Petrógrafos.....	116
6. CONSIDERAÇÕES FINAIS	119
REFERÊNCIAS BIBLIOGRÁFICAS	122
APÊNDICE A – Compressão de arquivos de imagens de lâminas petrográficas delgadas	136
ANEXO A – Artigo no <i>Journal of Petroleum Science and Engineering</i>	142
ANEXO B – Manuscrito submetido ao <i>Earth Science Informatics</i>	156
ANEXO C – Formulário de registro das entrevistas com petrógrafos	188

1. ASPECTOS INTRODUTÓRIOS

1.1. Apresentação

A caracterização de reservatórios de óleo e gás tem como um de seus principais objetivos a descrição da distribuição espacial de parâmetros petrofísicos (LUCIA, 1995). A utilização de variáveis mais próximas da realidade nos modelos de reservatório orienta uma exploração com maior assertividade relacionada ao modelo geológico e viabiliza a otimização do desenvolvimento da produção.

A definição dos melhores parâmetros a serem utilizados nos modelos está vinculada a integração de estudos de rocha, perfis e sísmica. A partir de estudos de rocha, são realizados *upscales* para perfis e, finalmente, para sísmica, extrapolando e correlacionando os dados às respostas dos métodos indiretos.

Além da descrição macroscópica de amostras laterais auxiliada por lupa petrográfica, são realizadas medidas de petrofísica básica com o auxílio de porosímetro e permeâmetro. Estas medidas são complementadas por estudos microscópicos de lâminas petrográficas delgadas, embasados nas propriedades ópticas dos minerais.

A análise microscópica possibilita a obtenção de dados muito peculiares relacionados às condições do ambiente deposicional e diagenéticas. São analisadas características como textura, evidências de processos diagenéticos (cimentação, substituição, compressão, percolação de fluidos, entre outros), sistema poroso e ocorrência de argilominerais. Entretanto, os resultados de tais análises microscópicas são, em grande parte, qualitativos e dependentes da experiência do petrógrafo. Eventualmente, podem ser aplicados métodos estatísticos, como a descrição por pontos da lâmina em intervalos regulares de espaçamento. Porém, estas análises costumam ser demoradas e, apesar de apresentarem um componente quantitativo, ainda dependem em grande parte de fatores qualitativos.

Muitos trabalhos abordam a aplicação de métodos quantitativos alternativos na descrição de lâminas petrográficas através de análise espacial auxiliada por computador com a aplicação de processamento sequencial tradicional (EHRlich; DAVIES, 1984; MAINWARING; PETRUCK, 1989; TOMUTSA; BRINKMEYER; RAIBLE, 1990; ANJOS et al., 1995; ANSELMETTI; LUTHI; EBERLI, 1998; entre outros). Estas técnicas têm se mostrado muito úteis, principalmente na identificação e

quantificação de atributos muito distintos em lâminas, como a porosidade petrográfica total. Entretanto, não foram encontradas abordagens específicas relacionadas à aplicação de funções mais complexas, como a caracterização e classificação de texturas e minerais.

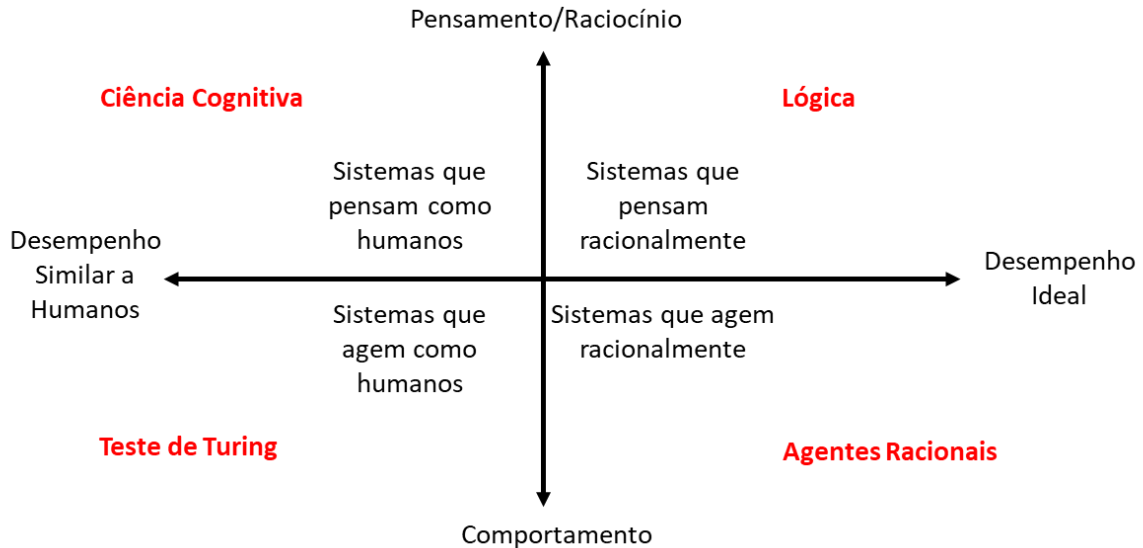
Com o avanço de técnicas de análise espacial e com o aumento na capacidade de processamento dos computadores, além da aplicação do processamento em paralelo utilizando múltiplos núcleos (*Graphics Processing Unit*, GPU), modelos baseados na aplicação de algoritmos de aprendizado de máquina estão sendo aplicados em análise de imagens (GURGEL, 2014; ŁADNIAK E MŁYNARCZUK, 2015; BUDENNYI et al., 2017; IZADI; SADRI; BAYATI, 2017).

O termo Petrografia Digital está sendo proposto para identificar esta nova área da Ciência que agrega a aplicação de técnicas de inteligência artificial e análise de imagens à atividade de petrografia microscópica clássica. Neste contexto, foram treinados modelos preditivos baseados em algoritmos de aprendizado de máquina que auxiliam o processo de descrição de lâminas petrográficas delgadas, tornando as análises mais quantitativas, confiáveis, padronizadas e rápidas.

1.2. Motivação

Existem diversas definições para Inteligência Artificial. Russel e Norvig (2009) lidam com o termo como sendo uma área de estudo da ciência e da engenharia que pode ser abordada por diferentes aspectos. Tais autores apresentam definições que se enquadram em quatro diferentes categorias: 1. sistemas que pensam como humanos; 2. sistemas que agem como humanos; 3. sistemas que pensam racionalmente; e 4. sistemas que agem racionalmente (Figura 01). Esta percepção leva em consideração uma distinção entre o comportamento humano e o comportamento racional. Apesar disso, não sugere que humanos sejam necessariamente irracionais. Além disso, propõe uma distinção entre sistemas que imitam comportamentos (sistemas programáveis) e sistemas que utilizam a mesma abordagem do aprendizado de seres racionais, utilizando a estrutura neural de organismos inteligentes como referência (sistemas de aprendizado de máquina).

Figura 01. Categorias de abordagem do termo Inteligência Artificial.



Fonte: Adaptado de Russel e Norvig (2009).

O desenvolvimento de algoritmos de aprendizado de máquina trata-se, assim, de uma subárea da Inteligência Artificial. Diversos setores vêm aplicando conceitos de aprendizado de máquina desenvolvidos pela ciência nas últimas décadas devido a popularização da capacidade de processamento dos computadores. Alguns exemplos são ferramentas como assistentes virtuais, tradutores automáticos, carros autônomos, reconhecimento facial como chave de segurança em dispositivos eletrônicos, sistemas de recomendação para compras e entretenimento, entre outros.

A aplicação de modelos de inteligência artificial tem ocorrido de forma intensiva em diferentes campos do conhecimento. Esse movimento está criando profundas transformações na sociedade e na forma com que as atividades humanas são realizadas. As transformações digitais ocorrem inicialmente nas atividades com maior demanda. Entretanto, as mesmas técnicas podem ser aplicadas em práticas tradicionalmente realizadas em setores muito específicos do conhecimento e da indústria.

Nas geociências aplicadas à indústria de óleo e gás, modelos preditivos são treinados para melhor caracterização dos reservatórios e para o direcionamento das atividades exploratórias. Em geral, os dados utilizados pelo exploracionista são

provenientes do tripé rocha-perfil-sísmica (THOMAS, 2004). Dentre os dados obtidos de amostras de rocha, as lâminas petrográficas delgadas apresentam-se como sendo o mais detalhado, possibilitando interpretações relacionadas ao ambiente deposicional e processos diagenéticos (PERKINS; HENKE, 2004). Para que esta interpretação seja realizada de forma objetiva e assertiva, a atividade de descrição detalhada das lâminas petrográficas é essencial. Entretanto, a descrição pode ser demorada, repetitiva e sujeita a inconsistências associadas à falta de experiência do petrógrafo. Além disso, a diversidade de conhecimentos e o viés humano fazem com que as descrições não sejam padronizadas, o que pode inviabilizar interpretações integradas de uma região ou campo de produção.

1.3. Objetivos

Motivados pela perspectiva de aplicar técnicas transformadoras em uma atividade consolidada e fundamental, tanto para a academia quanto para a indústria, delimitou-se como objetivo geral deste trabalho a criação de modelos de inteligência artificial que auxiliem na descrição quantitativa de lâminas petrográficas delgadas de rochas carbonáticas. A utilização destes modelos permite mais agilidade e padronização na descrição.

Como objetivos específicos, pretende-se comparar a utilização de diferentes algoritmos de aprendizado de máquina para os mesmos tipos de problemas, além de delimitar os melhores parâmetros para cada aplicação, gerando resultados confiáveis.

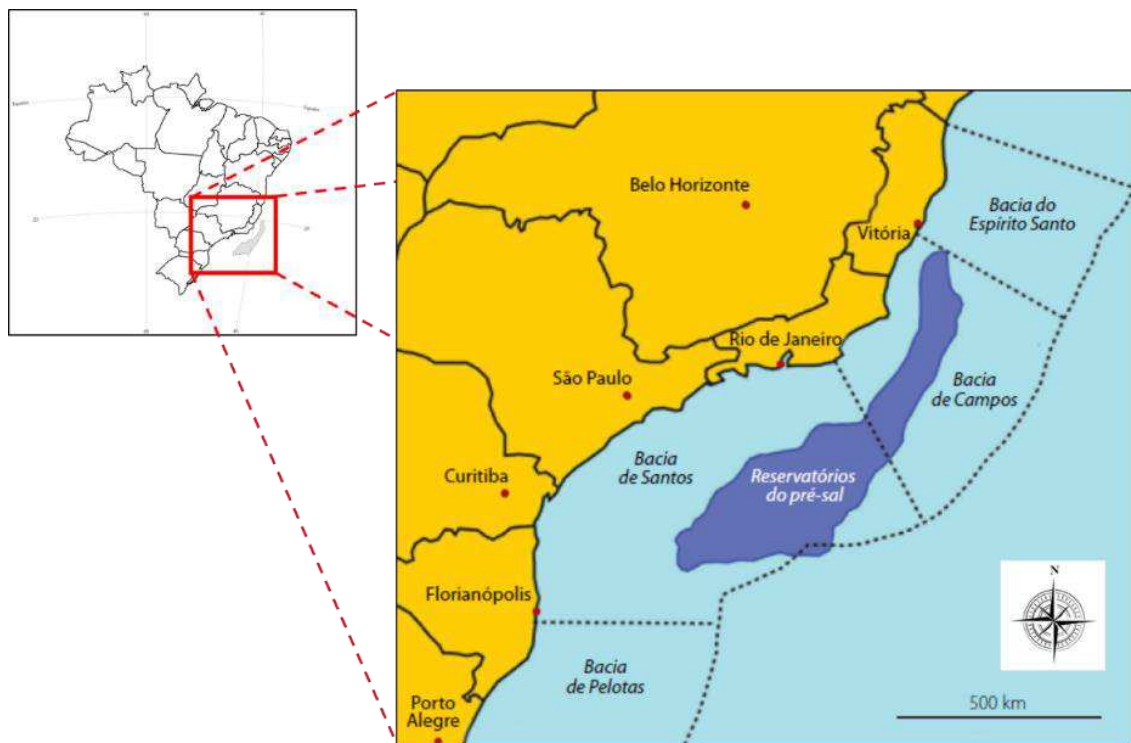
Estes resultados envolvem a obtenção de mineralogia e porosidade das imagens de lâminas petrográficas, através de mapas mineralógicos gerados por modelos de segmentação. Além disso, é possível identificar e localizar feições específicas, compostas por um grupo de *pixels* das imagens, como o modelo de detecção de fragmentos fosfáticos. Classificando, ainda, toda uma imagem em uma determinada categoria, foram criados modelos que viabilizam a classificação de litofácies e do tipo de porosidade presente em uma imagem. O conjunto de diferentes tipos de modelos treinados – segmentação, detecção de objetos e classificação – viabiliza a produção de resultados descritivos de forma rápida e padronizada. A criação de um pacote de modelos que auxiliem a análise petrográfica é um objetivo específico do trabalho.

1.4. Origem das amostras e contexto geológico

Os reservatórios carbonáticos apresentam-se como a principal frente exploratória das bacias sedimentares marginais brasileiras (PAPATERRA, 2010; RICCOMINI; SANT'ANNA; TASSINARI, 2012; HERLINGER; ZAMBONATO; DE ROS, 2017; LIMA; DE ROS, 2019; LIMA et al., 2020; LIMA, 2020). Este direcionamento está relacionado à exploração da seção denominada “Pré-Sal” das Bacias de Santos e Campos, iniciada pela Petrobras ao realizar as primeiras perfurações exploratórias na seção Rifte, em águas ultraprofundas da Bacia de Santos.

A poligonal que delimita geograficamente a área do Pré-Sal é definida pela Lei nº 12.351/2010 (Figura 02). A partir dela, um prisma vertical de profundidade indeterminada define a região do subsolo que caracteriza a seção, tornando-a sujeita a regulamentação específica, dada por um conjunto instrumentos jurídicos.

Figura 02. Mapa com a poligonal do Pré-Sal definida pela Lei nº 12.351/2010.




Fonte: Adaptado de Oliveira e Carneiro (2020) e Riccomini, Sant'Anna e Tassinari (2012).

As amostras de rocha carbonáticas que deram origem às lâminas petrográficas utilizadas neste trabalho são provenientes de amostras laterais coletadas durante a perfuração de poços em campos de produção que se localizam neste contexto, e são provenientes da seção denominada Pré-Sal da Bacia de Santos. Por demandas de sigilo, os poços não serão identificados.

Moreira *et al.* (2007) estabelecem o arcabouço cronolitoestratigráfico da bacia com base em estratigrafia de seqüências. Apresentam uma proposta de carta estratigráfica amplamente utilizada (Figura 03). As amostras são provenientes dos reservatórios da Formação Barra Velha, Grupo Guaratiba. Esta unidade é composta por depósitos de águas muito rasas e um lago/mar epicontinental, caracterizada por calcários estromatolíticos, laminitos, microbiolitos e folhelhos carbonáticos, com ocorrência subordinada de coquinas.

Figura 03. Carta estratigráfica da Bacia de Santos, Fm. Barra Velha destacada em vermelho.



Fonte: Adaptado de Moreira *et al.* (2007).

1.5. Hipótese

Esta tese parte da hipótese de que **modelos de aprendizado de máquina podem aprimorar o processo de descrição de lâminas petrográficas, alcançando resultados quantitativos mais confiáveis, padronizados e rápidos do que a descrição tradicional.** Tal hipótese é testada e validada a partir de ferramentas estatísticas e de ciência de dados, de forma a avaliar as acurácias e erros dos modelos. Adicionalmente, a hipótese é avaliada a partir de entrevistas com petrógrafos. As interpretações consolidadas possibilitam a visualização de um panorama geral da atividade descritiva, comparando-a com a utilização dos modelos obtidos por inteligência artificial.

2. FUNDAMENTOS TEÓRICOS

2.1. Rochas carbonáticas

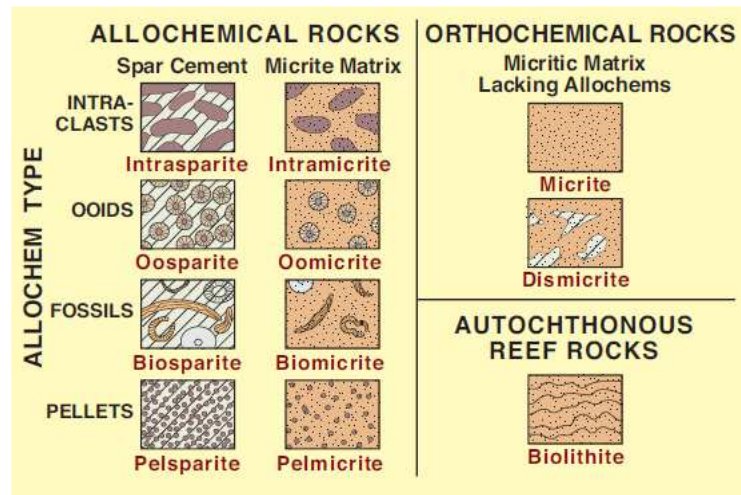
As rochas carbonáticas depositam-se, geralmente, em ambientes marinhos rasos, mas também em cavernas, lagos e ambientes marinhos profundos (NICHOLS, 1999). Nesses ambientes, os íons carbonato (CO_3^{2-}) são transportados dissolvidos em água até sua precipitação. São comuns processos de biomineralização no qual os íons CO_3^{2-} passam a compor parte de organismos vivos e, posteriormente, são depositados. Precipitação química sem a intermediação de organismos vivos também ocorre com menor frequência.

As rochas carbonáticas são constituídas, predominantemente, por minerais carbonáticos que podem apresentar grãos de diversos tamanhos, desde a fração argila (que dá origem aos micritos) até grandes partículas e cristais (textura esparítica), além de estruturas formadas por organismos como colônias de coral em um recife. Além da presença de uma matriz carbonática, é comum a ocorrência de partículas carbonáticas ou aloquímicas (bioclastos, oóides, pisóides, oncóides, pelóides e intraclastos).

O estudo de rochas carbonáticas e suas propriedades é repleto de desafios, a começar pela classificação. Devido à complexidade das rochas, variabilidade (heterogeneidade espacial) e modificações ocasionadas pelos processos diagenéticos, diversas classificações foram propostas, umas de caráter estritamente descritivo, enquanto outras englobam aspectos genéticos e diagenéticos (SCHOLLE; ULMER-SCHOLLE, 2003).

Folk (1959, 1962) utiliza percentuais relativos de grãos e matriz. O nome da partícula carbonática presente na rocha é associado ao material intersticial, originando as categorias observadas na Figura 04. Além disso, os termos podem ser combinados para descrever uma rocha que apresente mais de uma partícula carbonática ou material tanto micrítico quanto esparítico na matriz. Há, ainda, a possibilidade da classificação de uma rocha sem partículas aloquímicas, somente com matriz micrítica chamada de micrito, ou dismicrito quando o micrito apresenta cavidades preenchidas por cimento. Os biolitos representam os carbonatos formados *in situ*.

Figura 04. Sistema de classificação proposto por Folk (1962) para rochas carbonáticas.



Fonte: Adaptado por Scholle e Ulmer-Scholle (2003).

Uma classificação textural é proposta ainda por Folk (1962), em que cada estágio de seleção e arredondamento refletem uma determinada condição energética associada ao ambiente de deposição (Figura 05).

Figura 05. Sistema de classificação textural de Folk (1962). As condições de baixa energia estão à esquerda e as condições de alta energia estão à direita.

	> 2/3 LIME MUD MATRIX				SUBEQUAL SPAR and LIME MUD	> 2/3 LIME SPAR CEMENT		
	0-1%	1-10%	10-50%	> 50%		SORTING POOR	SORTING GOOD	ROUNDED and ABRADED
Percent allochems								
Textural name	MICRITE and DIS-MICRITE	FOSSILIFEROUS MICRITE	SPARSE BIO-MICRITE	PACKED BIO-MICRITE	POORLY-WASHED BIO-SPARITE	UN-SORTED BIO-SPARITE	SORTED BIO-SPARITE	ROUNDED BIO-SPARITE
Typical fabric								
Terri-genous analogs	Claystone		Sandy claystone	Clayey or immature sandstone	Sub-mature sandstone	Mature sandstone	Super-mature sandstone	

Fonte: Adaptado por Scholle e Ulmer-Scholle (2003).

Simultaneamente, Dunham (1962) apresenta uma classificação baseada na caracterização da trama das rochas (Figura 06), podendo ser classificadas em matriz suportadas ou grão suportadas. Apresenta as seguintes categorias: grainstone, para rocha constituída por grãos (partículas carbonáticas) sem matriz; packstone, para grãos em contato com matriz; wackstone, para grãos espalhados dispersos em matriz; mudstone, para rochas micríticas com poucos grãos; e boundstone, quando ocorrem

componentes originais carbonáticos que eram organicamente ligados durante a deposição.






Nesse último caso, foram sugeridos por Embry e Klovan (1971) novos termos para distinguir litotipos associados à ação de organismos que agem de forma discordante (bafflestone), que conectam e ligam (bindstone) ou que constroem estruturas corpóreas rígidas (framestone). Esses autores também adicionaram as categorias rudstone e floatstone, para conglomerados clasto-suportados e conglomerados matriz-suportados, respectivamente (Figura 07).

Figura 06. Sistema de classificação de Dunham (1962) para rochas carbonáticas.

DEPOSITIONAL TEXTURE RECOGNIZABLE				Original Components Bound Together During Deposition	DEPOSITIONAL TEXTURE NOT RECOGNIZABLE
Original Components Not Bound Together During Deposition					
Contains mud		Grain-supported	Lacks mud and is grain-supported	Boundstone	Crystalline carbonate (Subdivisions based on texture or diagenesis)
Mud-supported	> 10% grains				
< 10% grains	> 10% grains	Packstone	Grainstone		
Mudstone	Wackestone				

Fonte: Adaptado por Scholle e Ulmer-Scholle (2003).

Figura 07. Modificações propostas por Embry e Klovan (1971) ao sistema de classificação de Dunham (1962), incorporando componentes esqueléticos.

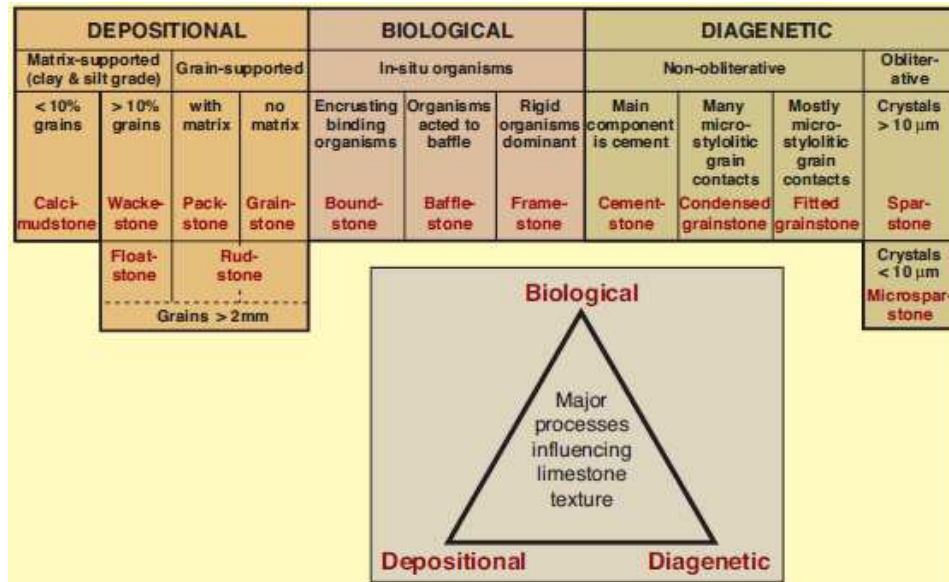
Original Components Not Organically Bound During Deposition		Original Components Organically Bound During Deposition		
> 10% grains > 2 mm		Organisms acted as baffles	Organisms encrusted and bound	Organisms built a rigid framework
Matrix-supported	Supported by components larger than 2 mm			
Floatstone	Rudstone	Bafflestone	Bindstone	Framestone
				

Fonte: Adaptado por Scholle e Ulmer-Scholle (2003).

Com foco na gênese e diagênese das rochas carbonáticas, Wright (1992) propõe a subdivisão das tramas em biológica, diagenética e deposicional (Figura 08). Embora muitos dos nomes tenham sido derivados de Dunham (1962) ou Embry e

Klovan (1971), introduz termos úteis para a descrição de rochas cujos processos diagenéticos obliteram as texturas deposicionais originais (rochas muito cimentadas, recristalizadas ou com compactação química).

Figura 08. Sistema de classificação proposto por Wright (1992).
























Fonte: Adaptado por Scholle e Ulmer-Scholle (2003).

Para este trabalho, a classificação proposta por Terra *et al.* (2010) é utilizada. Os autores apresentam uma opção aplicável às bacias sedimentares brasileiras, em particular para as bacias em que ocorrem exploração e produção de petróleo, já considerando as descobertas dos campos gigantes da seção Pré-Sal (Figura 09). As rochas são divididas em quatro grupos, segundo sua textura deposicional: 1. elementos não ligados durante a formação (retrabalhos); 2. elementos ligados durante a formação (*in situ*); 3. elementos ligados ou não durante a formação (laminitos); e 4. textura deposicional irreconhecível (obliteradas por processos diagenéticos).


O estudo de sistemas porosos em carbonatos é mais complexo do que em siliciclásticos devido às características relacionadas à origem biológica e à alta reatividade química. Muitas classificações de porosidade para rochas carbonáticas foram propostas (JODRY, 1972; LUCIA, 1983; EHRLICH *et al.*, 1991; LUCIA, 1995; entre outras), mas a classificação de Choquette e Pray (1970) consolidou-se como a mais utilizada pela academia e indústria (Figura 10).

Figura 09. Classificação aplicável às bacias sedimentares brasileiras.

	NOMENCLATURA PRINCIPAL	TEXTURA	DEFINIÇÃO
Elementos não ligados durante a formação	MUDSTONE		Rocha suportada pela matriz com menos de 10% de grãos (tamanho areia ou maior).
	WACKSTONE		Rocha suportada pela matriz com mais de 10% de grãos (tamanho areia ou maior).
	PACKSTONE		Rocha suportada pelos grãos com matriz.
	GRAINSTONE		Rocha suportada pelos grãos, sem matriz (< 5% de matriz).
	FLOATSTONE		Rocha suportada pela matriz com mais de 10% dos grãos maiores que 2 mm.
	RUDSTONE		Rocha suportada pelos grãos com mais de 10% dos grãos maiores que 2 mm.
	BIOACUMULADO		Rocha constituída pela dominância de um tipo de organismo sem retrabalhamento (<i>in situ</i>) e granulometria areia ou maior.
	BRECHA		Rocha suportada pelos grãos com mais de 50% dos grãos angulosos maiores que 2 mm.
Elementos ligados durante a formação - <i>in situ</i>	BOUNDSTONE		Rocha formada <i>in situ</i> cujos componentes da trama original (fábrica original) foram ligados durante a deposição.
	ESTROMATOLITO Depósito de estrutura laminada e, em geral, convexa, podendo apresentar feições de crescimento/ramificações internas para o topo. Na maioria das vezes de origem microbial. Pode ser observado em diferentes escalas.		ESTROMATOLITO
			ESTROMATOLITO ARBORESCENTE - os componentes internos se organizam de forma ramificada divergente e possuem comprimento maior que a largura.
			ESTROMATOLITO ARBUSTIFORME - os componentes internos se ramificam ou não desde a base e a razão altura/largura é aproximadamente 1:1.
			ESTROMATOLITO DENDRIFORME - os componentes internos se organizam de forma intensamente ramificada divergente em que o comprimento é muito maior que a largura.
	TROMBOLITO		Depósito com textura macroscópica coagulada (clotted) , maciça e dômica. Na maioria das vezes de origem microbial.
	DENDROLITO		Depósito microbial de estrutura dendrítica formada por cianobactérias esqueléticas.
	LEIOLITO		Carbonato microbial dômico, sem laminação ou coágulos.
	ESFERULITO		Rocha composta por partículas de formas esféricas ou subsféricas de contornos lisos ou lobados (esferulitos) de tamanho geralmente inferior a 2 mm e que podem ocorrer de forma amalgamada ou isolados.
	TRAVERTINO & (TUFA)		Rocha carbonática bandeada formada pela precipitação em superfície de soluções concentradas em CaCO ₃ ao redor de fontes (em geral quentes) devido a perda de CO ₂ por evaporação. A variedade mais esponjosa e menos compacta é denominada TUFA .
Elementos ligados ou não	LAMINITO		Rocha carbonática de granulação fina (lamosa e/ou peloidal) formada pela recorrência de laminações delgadas. As laminações tendem a ser plano-paralelas, com superfície lisa (origem microbial ou não) ou crenulada (origem microbial).
Textura original não reconhecível	CALCÁRIO CRISTALINO		Rocha carbonática totalmente recrystalizada não sendo possível identificar sua textura original (deposicional). CALCÁRIO MICROCRISTALINO : cristais entre 5 e 50 µm
	DOLOMITO		Rocha carbonática totalmente dolomitizada não sendo possível identificar sua textura original (deposicional). MICRODOLOMITO : cristais entre 5 e 50 µm

Fonte: Terra et al. (2010).

Figura 10. Sistema de classificação de porosidade de rochas carbonáticas proposto por Choquette e Pray (1970).



Fonte: Adaptado por Scholle e Ulmer-Scholle (2003).

Neste sistema de classificação de porosidade, a mesma é subdividida em seletiva pela trama, não seletiva pela trama, e que pode ou não ser seletiva pela trama. Esta subdivisão está relacionada com a perspectiva de a porosidade ser ou não controlada por fronteiras primárias delimitadas por grãos, cristais ou outras estruturas físicas na rocha.

2.2. Petrografia Óptica

2.2.1. Principais conceitos

A petrografia óptica estuda a interação dos minerais com a luz e as propriedades dos minerais em lâmina delgada. As propriedades ópticas dos minerais variam de acordo com sua composição e estrutura cristalina (NESSE, 2004). Um princípio fundamental da mineralogia óptica é que muitos dos minerais transmitem luz se cortados em fatias muito finas, inclusive os mais escuros e outros que parecem opacos em amostras de mão (FLEISCHER; WILCOX; MARZKO, 1984; PERKINS; HENKE, 2004). Para o estudo destes minerais, é utilizado o microscópio petrográfico óptico de luz transmitida (Figura 11).

Os minerais de brilho metálico, e alguns outros, são chamados minerais opacos, pois não transmitem luz mesmo que cortados em fatias finas. Para o estudo destes minerais é utilizado o microscópio óptico de luz refletida. Muitas vezes, o mesmo microscópio petrográfico tem as opções de luz transmitida e refletida, podendo diferentes minerais serem analisados no mesmo equipamento.

2.2.2. Preparação das lâminas e equipamentos utilizados

As lâminas de amostras de rocha derivadas da perfuração de poços de petróleo são confeccionadas a partir de parte das amostras laterais (chamada de “tijolinho”), em que é realizado processo de limpeza e extração de óleo e sais, auxiliados por solventes (tolueno para óleo e metanol para sais). Este processo tem como objetivo eliminar fluidos remanescentes do sistema poroso da amostra de tal forma a viabilizar o estudo do mesmo através das propriedades ópticas da rocha, comumente realizado para o estudo de rochas sedimentares com ênfase na exploração de óleo e gás.

Figura 11. Imagem de um microscópio petrográfico óptico.



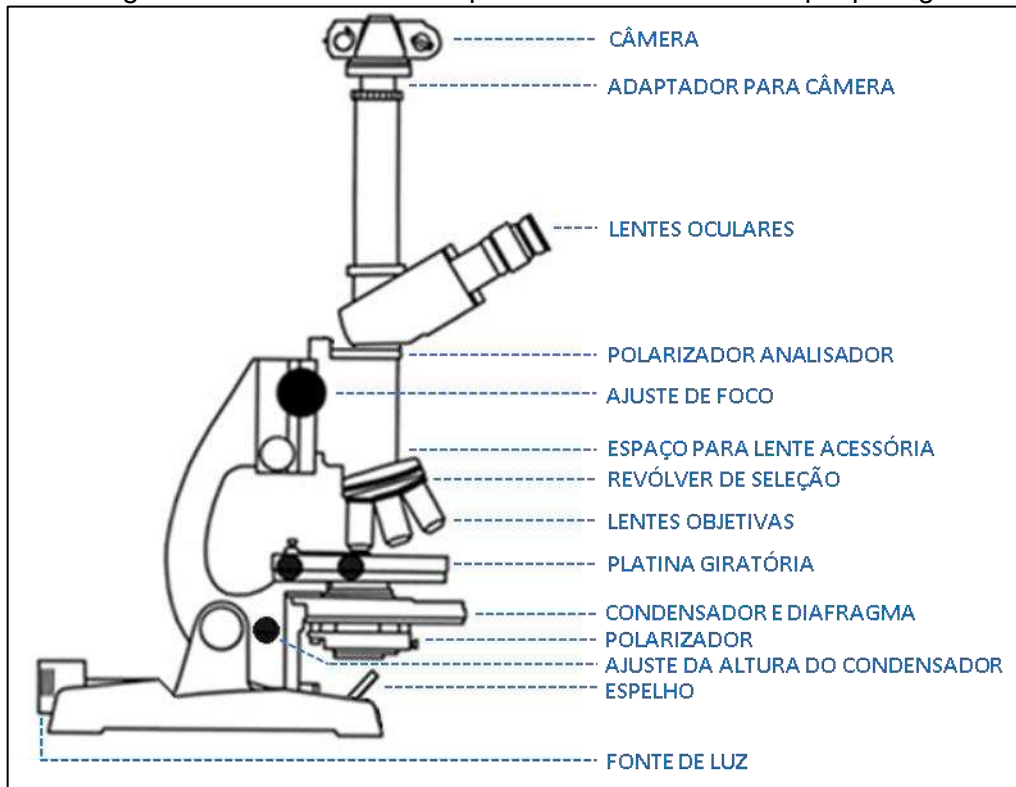
Fonte: Elaborada pelo autor.

Após esta etapa, a amostra é impregnada por resina e catalisador epóxi, juntamente com corante azul de ceres que irá representar o sistema poroso na lâmina petrográfica. A cor azul de ceres é escolhida uma vez os minerais observados na natureza não apresentam esta coloração quando submetidos à luz branca, distinguindo o sistema poroso da lâmina de qualquer mineral.

A amostra impregnada é, então, colada à lâmina de vidro, cortada e desbastada até atingir a espessura de 30 a 35 μm . A lâmina é analisada em microscópio petrográfico de luz transmitida (para estudo das propriedades ópticas de minerais translúcidos) e refletida (para estudo das propriedades ópticas de minerais opacos).

Além das etapas relacionadas à confecção das lâminas delgadas, a atividade de petrografia óptica é viabilizada através do uso do microscópio petrográfico óptico, que é composto pelos seguintes componentes principais: fontes de luz, espelhos, condensador, ajustes da altura do condensador, diafragma, polarizador (prisma Nicol), lente condensadora auxiliar, platina giratória, lentes objetivas, revólver de seleção da objetiva, espaço para lente acessória com diferentes comprimentos de onda, polarizador analisador (prisma Ahrens), ajustes de foco, lentes Amici-Bertrand, lentes oculares, e câmera (Figura 12).

Figura 12. Diagrama destacando os componentes de um microscópio petrográfico óptico.



Fonte: Modificado de Davidson e Lofgren (1991).

Os microscópios podem ter uma ou mais fontes de luz. Estas fontes proporcionam uma iluminação estável que são ligadas e desligadas conforme a necessidade. A mesma fonte pode ser utilizada para análise de luz transmitida e refletida, ou cada tipo de análise pode ter uma fonte própria. Neste caso, normalmente a fonte para luz transmitida é localizada na base do microscópio e a fonte para luz refletida é localizada um pouco acima da platina. É comum a ocorrência de microscópios que utilizam fontes externas para análise de luz refletida.

O condensador consiste em duas ou mais lentes que têm o objetivo de concentrar a luz proveniente da fonte de luz na amostra a ser colocada na platina. Conforme são trocadas as objetivas a serem utilizadas na análise, o condensador precisa ser ajustado para otimizar a qualidade das imagens geradas. O diafragma reduz a quantidade de luz que chega na amostra restringindo a área pela qual a luz pode passar. Pode ser ajustado para múltiplas aberturas, controladas de forma contínua, e não discreta.

A luz proveniente da fonte de luz produz ondas em todas as direções perpendiculares à direção de propagação da luz e, por esse motivo, é chamada de não polarizada. Já a luz plano polarizada apresenta ondas perpendiculares à direção de propagação somente em uma específica direção no espaço. Os polarizadores têm o objetivo de filtrar as ondas perpendiculares à propagação, permitindo que somente uma polarização específica seja transmitida. Fazem isso através de longas moléculas alinhadas em uma direção que fazem parte de sua composição. O eixo de um filtro de polarização é a direção pela qual o filtro permite que um campo elétrico de uma onda eletromagnética passe. O polarizador (prisma Nicol) e o polarizador analisador (prisma Ahrens) de um microscópio petrográfico apresentam orientação relativa de 90 graus um ao outro, o que permite a visualização de diferentes texturas das rochas quando utilizados conjuntamente.

A platina é a plataforma na qual as lâminas delgadas são posicionadas para análise. Um orifício na platina permite que a luz passe pela amostra, viabilizando a análise petrográfica microscópica de luz transmitida. Microscópios petrográficos comumente apresentam platinas giratórias com uma escala em graus: 360 graus ao redor de uma platina circular.

As objetivas são as principais lentes de magnificação em um microscópio. Normalmente, para a atividade de petrografia, são utilizadas objetivas com aumento de 1,25 vez até 50 vezes (apesar de existirem objetivas de magnificação maiores disponíveis no mercado). Elas são acopladas em uma peça chamada revólver, que permite modificar a objetiva a ser utilizada na análise.

Placas com lentes auxiliares acessórias podem ser inseridas no microscópio com o objetivo de determinar o sinal óptico, por exemplo, além de outros testes avançados. O espaço para utilização destas lentes costuma ser logo acima do revólver das objetivas.

As lentes Amici-Bertrand permitem alterar o plano e foco de tal forma que o


petrógrafo possa observar figuras de interferência. Já as lentes oculares permitem que o usuário possa observar a amostra com seus olhos. Os microscópios mais modernos costumam ser binoculares, apresentando duas oculares que podem ser ajustadas de forma independente. Podem apresentar, ainda, câmeras digitais com diferentes resoluções acopladas e ligadas a um computador capaz de capturar e salvar as imagens. A composição de diferentes imagens obtidas das lâminas permite confecção de fotomosaicos. Microscópios específicos para a aquisição destas imagens apresentam platinas automáticas, que apresentam seus parâmetros de aquisição controlados por computador.

2.2.3. Análise petrográfica e resposta óptica das rochas

No caso de rochas carbonáticas, a mineralogia costuma ser muito simples, constituindo-se principalmente de calcita (carbonato de cálcio - CaCO_3) e dolomita (carbonato de cálcio e magnésio - $\text{CaMg}(\text{CO}_3)_2$). Podem ocorrer outros minerais de forma subordinada, tais como grãos siliciclásticos (quartzo, muscovita, feldspatos, entre outros), fragmentos de rochas vulcânicas e diferentes tipos de argilas. Devido à esta simplicidade mineralógica, o estudo das texturas em rochas carbonáticas é fundamental para a interpretação de ambientes deposicionais e evolução diagenética, assim como a avaliação das características do sistema poroso.

Em feixes de luz não polarizados, as ondas de luz vibram em muitas direções diferentes. Um polarizador filtra o feixe de luz para que todas as ondas vibrem em uma única direção (polarizadores paralelos – Figura 13A). Com o auxílio de um segundo polarizador, algumas das texturas analisadas no estudo de petrografia óptica somente são evidenciadas (polarizadores cruzados – Figura 13B). Existem diversos outros filtros e lentes que podem ser utilizados na atividade de descrição microscópica de lâminas delgadas, que serão utilizados de forma subordinada na pesquisa.

Figura 13. Fotomicrografias obtidas com microscópio óptico petrográfico. Esferulítico com argila proveniente da Fm. Barra Velha, Cretáceo da Bacia de Santos, com polarizadores paralelos (A) e polarizadores cruzados (B). Notar a textura fibro-radial dos esferulitos evidenciadas em luz polarizada.



Fonte: Terra et al. (2010).

2.3. Espaço de cor e segmentação por limiar (*threshold*)

As propriedades ópticas dos minerais estudadas pela petrografia são interpretadas pelos seres humanos através da visão a cores. Com base nas imagens adquiridas a partir de lâminas petrográficas delgadas, filtros são aplicados de tal forma que sejam mantidas as cores de interesse e excluídas todas as demais. Esta é a forma mais simples de segmentação de uma imagem, através do limiar (*threshold*) de cores. A delimitação dos limiares é realizada através dos parâmetros dos espaços de cor.

Na literatura de computação gráfica, os termos modelos de cor e espaços de cor são frequentemente utilizados como sinônimos. Entretanto, Naiman (1985) explicita a diferença entre eles aplicando o conceito de percepção da visão humana de cores para modelos, e de sistema tridimensional de representação de cores para espaços.

Existe uma grande quantidade de espaços de cor, ou seja, diversas formas de representar espacialmente as cores percebidas pelo olho humano. Podem ser divididos em três categorias (IBRAHEEM *et al.*, 2012), conforme suas aplicações em processamento de imagem: 1. com foco nos dispositivos (também chamados de dependentes do dispositivo); 2. com foco no usuário; e 3. independentes do dispositivo (Tabela 01).

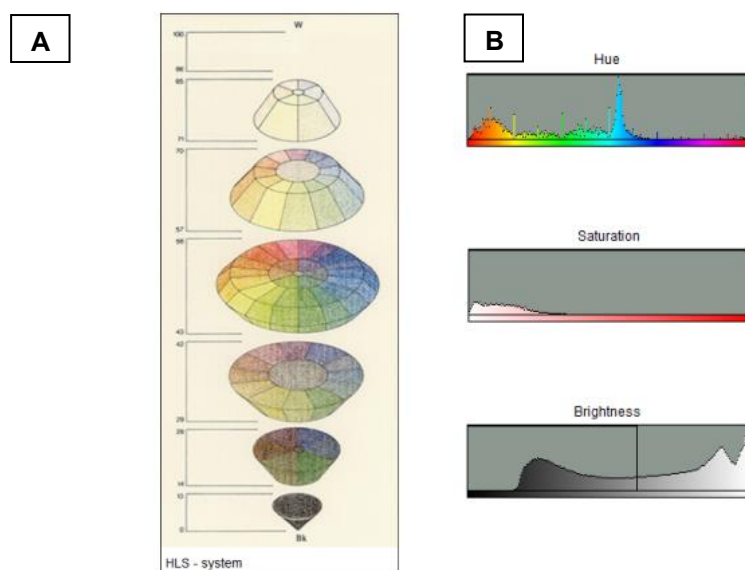
Tabela 01. Classificação dos espaços de cor.

Espaço de cor	Classificação
Munsell	Independente do dispositivo
RGB, CMY(K)	Dependentes do dispositivo
YIQ, YUV, YCbCr	Dependentes do dispositivo
HSI, HSV, HSL	Foco no usuário - dependentes do dispositivo
CIE XYZ, CIE L*U*V*, CIE L*a*b*	Independente do dispositivo

Fonte: Modificado de Ibraheem *et al.* (2012).

O espaço de cor HSL utiliza o conceito de variação de matiz (*hue*), luminância (*luminance*), e saturação (*saturation*), representados através de dois cones posicionados com a base em contato (Figura 14). A delimitação de limiares com base nos histogramas de cada um dos canais deste espaço de cor permite a realização de uma segmentação com base exclusivamente nestes critérios.

Figura 14. A) Representação do espaço de cor HLS e B) exemplo de histogramas para matiz, saturação e luminância.



Fontes: A) Silvestrini e Baumann (1994); B) Schindelin *et al.* (2012).

Se a feição de interesse apresentar características de coloração muito marcantes, é possível que a segmentação através da delimitação de limiares apresente resultados adequados. Entretanto, a qualidade da segmentação pode ser muito melhorada adicionando informação referente aos vizinhos de cada *pixel*. Nestes casos, ao invés de obter a delimitação de limiares com base em somente três canais de um espaço de cor, são acrescentadas n dimensões para cada *pixel* através do uso de

filtros convolucionais. A forma de armazenamento de imagens considerando seus espaços de cor, perdas e compressão foi avaliada e é discutida no Apêndice A.

2.4. Convolução e extração de atributos

A operação de convolução em imagens permite o acréscimo de informação à um *pixel* referente aos seus *pixels* vizinhos. Tem como objetivo extrair feições das imagens a partir de operações matemáticas entre funções, representadas pela Eq. 1.

$$g(x) = f(x) * h(x) = \int_{-\infty}^{\infty} f(s)h(x - s)ds \dots \dots \dots \text{Eq. 1}$$

A operação de convolução também pode ser representada através de matrizes. A matriz convolvida resultante é a soma da multiplicação de uma matriz maior por uma matriz menor, também chamada de filtro convolucional (DUMOULIN; VISIN, 2016). Cada canal de cor de uma imagem colorida pode ser representado por uma matriz. Estas matrizes seriam equivalentes à matriz maior de uma operação de convolução. Há um grande número de filtros convolucionais discretos (a matriz menor) que podem ser aplicados à uma imagem, cada um evidenciando diferentes características, tais como as bordas de feições (KHAN *et al.*, 2018).

Uma vez que diferentes filtros convolucionais tenham sido aplicados à uma imagem, cada *pixel* passa a conter muito mais informação do que somente os três canais de um espaço de cor. Eles passam a expressar sua relação com os *pixels* vizinhos através de novos atributos. Estes atributos convolucionais representam nova informação adicionada ao dado original referente à sua relação espacial. Desta forma, uma classificação *pixel a pixel* pode gerar uma imagem segmentada com base em muito mais dimensões e considerando o contexto espacial do dado.

Entretanto, para processar esta grande quantidade de informação adicionada juntamente com o dado original e obter a melhor classificação, algoritmos de aprendizado de máquina de classificação são utilizados.

2.5. Algoritmos de aprendizado de máquina

Existem diversos algoritmos de aprendizado de máquina, cada um projetado para analisar dados com diferentes características (WITTEN; FRANK, 2005; HASTIE;


TIBSHIRANI; FRIEDMAN, 2009; RUSSELL; NORVIG, 2009). Estes algoritmos podem ser mais simples demandando menores custos computacionais, ou mais complexos demandando computação de alta performance. Geralmente, quanto mais complexo um algoritmo, maior sua capacidade de analisar não-linearidades entre as variáveis analisadas.

A natureza é repleta de comportamentos e respostas não-lineares, sendo que as propriedades ópticas das rochas não são exceção. Os modelos desenvolvidos nesta pesquisa utilizaram algoritmos de aprendizado de máquina, a saber: algoritmo baseado em processos decisórios *random forest*; redes neurais artificiais (*multi-layer perceptron*); redes neurais convolucionais (*convolutional neural networks*); e também as redes adversárias geradoras (*generative adversarial networks*). Os fundamentos teóricos dos algoritmos utilizados, baseados em aprendizado supervisionado, serão abordados a seguir.

2.5.1. Random Forest

Estes são algoritmos baseados em processos decisórios, chamados de classificadores de conjunto (*ensemble*). Isto porque são, na realidade, uma coleção de árvores de decisão, consideradas como classificadores mais simples. Árvores de decisão são sequências de premissas estruturadas de uma maneira organizada (BREIMAN *et al.*, 1984). Se o dado de entrada estiver em concordância com a primeira premissa (nó raiz), ele segue para a próxima premissa (nó interno), até o momento em que passa a ser classificado (folhas). Se o dado não estiver em concordância com uma das premissas pelo caminho, ele segue por uma ramificação diferente na árvore, alcançando uma posição em que é rotulado como uma classe diferente do que a da ramificação alternativa (Figura 15).

Figura 15. Exemplo de árvore de decisão.




Fonte: Elaborada pelo autor.

A estrutura nas quais as árvores de decisão são organizadas depende da impureza de uma premissa. Os fatores de impureza são especificados para cada premissa e são chamados impureza Gini. São calculados de acordo com a Eq. 2 e são uma medida do quanto decisiva uma premissa é para a classificação de um dado de entrada.

$$\text{Impureza Gini} = 1 - (\text{probabilidade de "sim"})^2 - (\text{probabilidade de "não"})^2 \dots \text{Eq. 2}$$

Para analisar os dados de entrada, os algoritmos *random forest* criam um grande número de árvores de decisão com estruturas aleatórias (Figura 16). Estes algoritmos também selecionam parte dos dados aleatoriamente para servirem como entrada de cada árvore criada, em um processo chamado de *bootstrap aggregation*, ou *bagging* (BREIMAN, 1996). A classe que recebe mais votos das árvores com estruturas aleatórias é a classe que será selecionada pelo algoritmo *random forest* (BREIMAN, 2001). Segundo Hastie, Tibshirani e Friedman et al. (2009), algoritmos *random forest* estabilizam o erro de classificação com cerca de 200 árvores, ao menos para os dados de treinamento que eles utilizaram.

Figura 16. Exemplo de árvores de decisão com diferentes estruturas criadas aleatoriamente.



Fonte: Elaborada pelo autor.


2.5.2. Redes Neurais Artificiais

As redes neurais artificiais (*artificial neural network* - ANN) são técnicas computacionais que propõem um modelo matemático baseado na estrutura neural de organismos inteligentes, mais especificamente o cérebro humano (TAFNER; XEREZ;

FILHO, 1995). Apresentam, como principais características, as capacidades de aprendizado, generalização e abstração, que obtêm através da procura por relacionamentos, construção automática de modelos e correção destes modelos de modo a diminuir seus próprios erros.

De forma análoga ao cérebro humano, são criados neurônios artificiais (MCCULLOCH; PITTS, 1943) que irão funcionar em paralelo, recebendo dados de entrada complexos e calculando determinadas funções matemáticas (Figura 17). Os dados (x_i) são recebidos através de terminais de entrada correspondentes aos dendritos de um neurônio biológico, nos quais são aplicados pesos distintos (w_i) que simulam as sinapses.

Figura 17. Primeira proposta de um neurônio artificial.




Fonte: McCulloch e Pitts (1943).

O corpo do neurônio é representado pela chamada “função de ativação”, dada pela Eq. 3, onde n é o número de entradas, w_i é o peso associado à entrada x_i e θ é o limiar (*threshold*) do neurônio. É realizada a soma ponderada das entradas (considerando os pesos) e, caso esta ultrapasse o limiar de ativação, o neurônio emite ou não um sinal (saída igual a 1 ou 0).

$$\sum_{i=1}^n x_i \times w_i \geq \theta \dots\dots\dots \text{Eq. 3}$$

Os neurônios artificiais, quando combinados, viabilizam a solução de diferentes tipos de problemas, a depender da arquitetura de rede neural artificial (Figura 18). A arquitetura estabelece parâmetros como o número de camadas de neurônios, o número de nodos em cada camada, o tipo de conexão entre os nodos e a topologia da rede (BRAGA; CARVALHO; LUDERMIR, 2001).

Figura 18. Exemplos de arquiteturas de redes neurais artificiais. Podem ser classificadas quanto ao número de camadas (redes de camada única: A, E; redes de múltiplas camadas: B, C, D), quando ao tipo de conexões dos nodos (*feedforward* ou acíclica: A, B, C; *feedback* ou cíclica: D, E), e quando à sua conectividade (rede fracamente ou parcialmente conectada: B, C, D; rede completamente conectada: A, E).



Fonte: BRAGA; CARVALHO; LUDERMIR, 2001.

2.5.3. Redes Neurais Convolucionais

Um tipo especial de rede neural com arquitetura de múltiplas camadas é a rede neural convolucional (*convolutional neural network* – CNN). Esse tipo de rede neural artificial possui arquiteturas de neurônios artificiais desenhadas especificamente para reconhecimento de padrões estruturados, diretamente dos *pixels* das imagens digitais (LECUN et al., 1989; LECUN E BENGIO, 1995; LECUN et al., 1998).

Existem quatro operações principais em uma rede neural convolucional: convolução, não linearidade (ReLU), *pooling* (agrupamento) e classificação (camadas totalmente conectadas).

O objetivo principal da convolução para as redes neurais convolucionais é extrair feições da imagem de entrada. Trata-se de uma operação linear de multiplicação e soma de duas funções ou, de forma aplicada, de duas matrizes, sendo uma dada pela imagem de entrada e outra por um determinado filtro que pode ressaltar diferentes feições. Considerando que uma imagem pode ser representada por matrizes, ou seja, cada canal da imagem corresponde a uma matriz, a operação de convolução irá percorrer a matriz de entrada (imagem) com uma matriz menor, chamada de filtro ou *kernel*. A multiplicação dessas matrizes irá gerar uma matriz de saída com a soma dos elementos da multiplicação que resalta feições de acordo com os valores da matriz menor (filtro). São aplicados filtros que detectam ou ressaltam curvas e limites dos objetos nas imagens. Para cada filtro aplicado é gerado um mapa de feições.

A profundidade (*depth*) da operação de convolução corresponde ao número de filtros utilizados. Os passos (*strides*) correspondem ao número de *pixels* que atuarão como intervalo entre cada operação de multiplicação da matriz de entrada pelo filtro. Desta forma, quanto maior o passo, menor o tamanho do mapa de feições. O preenchimento por zeros ao redor das bordas da matriz correspondente à imagem é conveniente pois permite aplicar o filtro nos elementos das bordas, além de possibilitar o controle do tamanho do mapa de feições. Este procedimento é chamado de convolução ampla, enquanto que a convolução sem o preenchimento por zeros é chamada de estreita.

Os mapas de feições obtidos da operação de convolução são submetidos à operação de não linearidade, que tem o objetivo de aumentar as propriedades não lineares do modelo, uma vez que os dados do mundo real que alimentarão a rede neural convolucional são não lineares. Diversas funções podem ser aplicadas aos mapas de feições, entretanto a função chamada *Rectified Linear Unit* (ReLU) tem sido a mais utilizada devido à sua simplicidade computacional sem apresentar diferença significativa de precisão em relação à outras funções mais demandantes, como tangente hiperbólica ou sigmoide (NAIR; HINTON, 2010). A função ReLU substitui todos os valores de *pixel* negativos por zero e mantém os positivos iguais: $f(x) = \max(0, x)$.

O agrupamento (*pooling*, também chamado de sub amostragem) reduz as dimensões de cada mapa de feições retendo a informação mais importante. São definidas vizinhanças espaciais da matriz (por exemplo, sub matrizes de 2x2) e extrai-se um valor único representativo de cada vizinhança, que pode ser uma média, a soma ou, mais comumente, o valor máximo. A aplicação da operação de agrupamento progressivamente reduz o tamanho espacial da representação de entrada, deixando-as menores e mais facilmente gerenciáveis. Também reduz o número de parâmetros e deixa a rede menos sensível à transformações, distorções e translações da imagem de entrada.

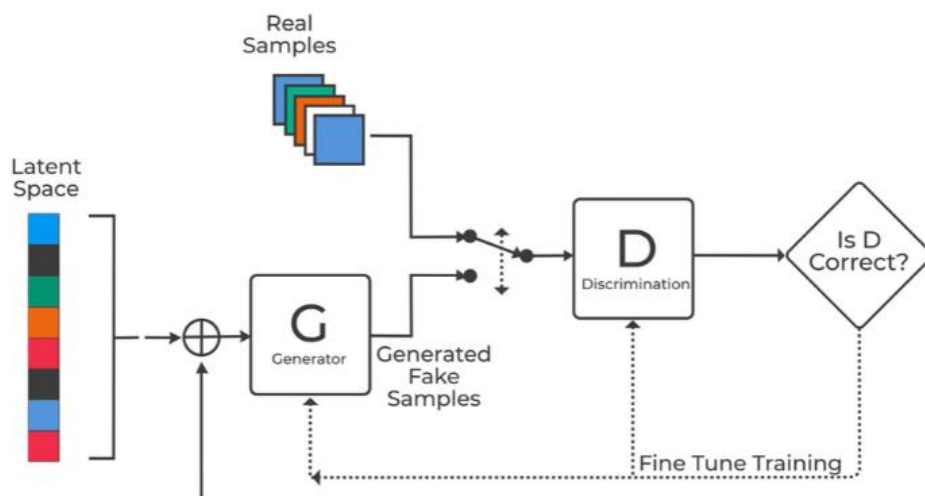
A última operação de uma rede neural convolucional é a classificação, auxiliada por uma arquitetura de rede neural multicamada em que todos os neurônios da camada anterior são conectados a todos os neurônios da camada seguinte. Os mapas de feições gerados pelas camadas anteriores de convolução-ReLU-agrupamento são as entradas para este sistema. As camadas utilizam as feições para criar classes

baseadas em um *dataset* de treinamento, além de possibilitarem a obtenção de combinações não lineares entre as feições dos diferentes mapas de feições. A camada de saída apresenta o número definido de classes pelo treinamento. Cada classe é representada por uma probabilidade de ocorrência, cuja soma é 1. A imagem carregada inicialmente na rede neural convolucional é interpretada como sendo pertencente à classe que obtiver maior probabilidade, ou seja, um valor mais próximo de 1.

2.5.4. Redes Adversárias Geradoras

As redes adversárias geradoras (*generative adversarial network* – GAN) são algoritmos que utilizam aprendizado não supervisionado que possibilitam gerar dados sintéticos (popularmente conhecidos como *deepfakes*), imitando as distribuições estatísticas e relações obtidas de um dado de treinamento real (GOODFELLOW et al., 2014). O treinamento de dois modelos é realizado em paralelo, um gerador e outro discriminador. O gerador aprende a criar dados sintéticos a partir de um vetor aleatório em um espaço latente. O discriminador aprende a distinguir o dado real do dado sintético criado pelo gerador. Os pesos são atualizados alternadamente, de forma que cada modelo aprende com a melhora do outro (Figura 19).

Figura 19. Esquema de funcionamento de uma rede adversária geradora.



Fonte: Chaudhari, Agrawal e Kotecha (2019).

Para este trabalho, foi utilizado uma implementação de rede adversária geradora chamada de *Auxiliary Classifier GAN* – ACGAN, proposta por Odena, Olah e Shlens (2017). A perspectiva desta aplicação é criar dado sintético através do uso de redes adversárias geradoras que auxiliem na complementação de um *dataset* de proporções reduzidas, ou que apresente desbalanceamento entre as classes (MORENO-BAREA; JEREZ; FRANCO, 2020). Esta é uma das técnicas que pode ser utilizada para ampliação dos *datasets*. Outras técnicas mais comumente utilizadas serão detalhadas na próxima seção (*data augmentation*).

Existem diversos questionamentos estatísticos relacionados à utilização de redes adversárias geradoras para este objetivo. Uma vez que as redes adversárias geradoras imitam as distribuições e relações do dado de treinamento original, a ampliação do *dataset* utilizando este dado sintético, em teoria, não seria capaz de melhorar a acurácia dos modelos. Entretanto, esta perspectiva somente seria aplicável à dados cuja distribuição espacial – variáveis regionais – não é relevante, pois estaria limitado a distribuição dos valores. Ao lidar com imagens, o comportamento espacial das variáveis regionais importa. O valor de cada ponto no espaço está relacionado aos valores obtidos de pontos situados a certa distância, sendo a influência tanto maior quanto menor for a distância entre os pontos (SOARES, 2006). Esta relação é expressa, estatisticamente, através do variograma (ou semivariograma, há uma confusão na literatura geoestatística quanto à terminologia – YAMAMOTO; LANDIM, 2013).

2.6. Data Augmentation

Os algoritmos de aprendizado de máquina foram desenvolvidos para treinar modelos preditivos com base na premissa do chamado *big data*. Utilizam um grande volume de dados estruturados, gerados por diversos usuários de forma simultânea através da utilização de serviços oferecidos pela Internet, tais como *streaming* (transmissão de conteúdo em tempo real), redes sociais, ou armazenamento em nuvem. Entretanto, em muitas ocasiões, não há acesso a grandes bases de dados estruturadas que possibilitam a utilização destes algoritmos, especialmente ao lidarmos com dados científicos, adquiridos em laboratório, por exemplo.

Este é o caso para imagens de lâminas petrográficas. Mesmo com a confecção de uma grande quantidade de lâminas, não é possível gerar dados na mesma

proporção e velocidade que os serviços para os quais estes algoritmos foram desenvolvidos geram. Além disso, as imagens de lâminas, em geral, são adquiridas a partir de diferentes microscópios, o que implica em diferentes condições de iluminação e conjunto de lentes.

Para minimizar o impacto de uma base de dados pequena ao aplicar estes algoritmos, existe uma alternativa chamada de *data augmentation* (aumento de dados). Existem diversas técnicas para ampliar a quantidade de dados de um *dataset*. Na seção anterior, foi apresentada uma alternativa de criação de dado sintético através do uso de redes adversárias geradoras – criação das imagens conhecidas por *deepfakes*. Entretanto, existem outras técnicas mais consolidadas e estabelecidas para a realização de *data augmentation*.

Uma delas é chamada de *augmentation* de cores (WU et al., 2015). A proposta é a realização de transformações no espaço de cor nas imagens do *dataset* original. Neste trabalho, está sendo proposto a utilização da terminologia *augmentation* espectral para este tipo de transformações, uma vez que elas estão relacionadas à uma variação da janela de absorção espectral das imagens de lâminas petrográficas por parte dos sensores das câmeras.

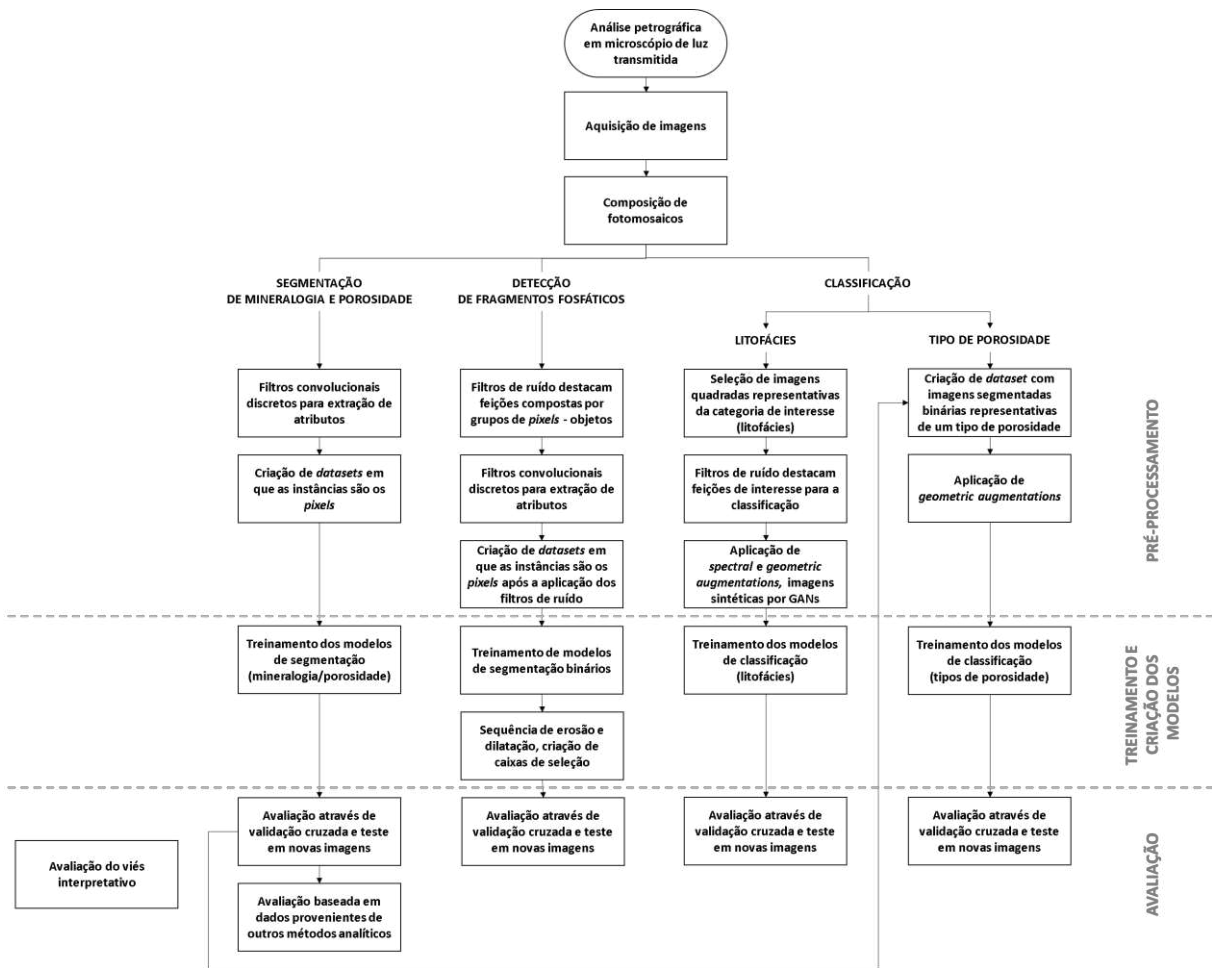
Outra técnica muito difundida e aplicada são transformações geométricas das imagens (PEREZ; WANG, 2017; MORENO-BAREA; STRAZZERA; JEREZ, 2018). Esta técnica é tão difundida que, por vezes, pode ser encontrada como sinônimo de *data augmentation* na literatura de aprendizado de máquina. Para este trabalho, são denominadas *augmentations* geométricas.

3. MÉTODOS

A partir da análise petrográfica de lâminas delgadas provenientes da seção Pré-Sal da Bacia de Santos, são obtidas imagens que compõem um fotomosaico de toda a extensão da lâmina. Estes fotomosaicos alimentam as fontes de dados de treinamento (*datasets*) utilizadas para criar diferentes modelos baseados em algoritmos de aprendizado de máquina: 1. modelos de segmentação, 2. modelos de detecção de objetos, e 3. modelos de classificação.

Cada tipo de modelo apresenta especificidades para sua criação, discutidas e detalhadas nas próximas seções deste capítulo. Para a pesquisa, os valores dos canais RGB das imagens foram convertidos para HSL, considerando que a definição de uma determinada cor neste espaço é mais simples. Todos os modelos são precedidos por uma etapa de convolução das imagens. A Figura 20 apresenta uma síntese das etapas realizadas. Os dados de treinamento (*pixels* de uma imagem e imagens inteiras) são rotulados e seus atributos (relacionados aos canais de cor, juntamente com atributos convolucionais) alimentam modelos de segmentação, classificação e detecção de objetos.

Figura 20. Síntese da sequência metodológica aplicada nesta pesquisa.




Fonte: Elaborada pelo autor.

3.1. Modelos de Segmentação

Para criar os modelos de segmentação de imagens, lâminas petrográficas foram confeccionadas a partir de amostras laterais de três poços de petróleo. Parte das lâminas foram analisadas quimicamente. Imagens de todas as lâminas foram adquiridas em microscópio petrográfico e serviram como fonte para seleção e criação dos *datasets* de treinamento. Filtros convolucionais acrescentaram atributos provenientes dos *pixels* vizinhos aos dados de treinamento. Algoritmos de aprendizado de máquina foram utilizados para treinar modelos supervisionados. Os modelos foram aplicados em dados novos e suas capacidades de generalização foram avaliadas. A sequência metodológica aplicada é sintetizada na Figura 21.

Figura 21. Síntese da sequência metodológica aplicada.



Fonte: Elaborada pelo autor.

As lâminas petrográficas utilizadas para criação dos modelos de segmentação foram obtidas a partir de amostras laterais. Para confeccioná-las, as amostras foram, inicialmente, submetidas a um processo de extração de óleo e sal auxiliado por solventes – tolueno para óleo e metanol para sais. Estes processos são necessários para remoção de fluidos remanescentes no sistema poroso da amostra. Este é um procedimento padrão ao estudar rochas de bacias sedimentares, especialmente na exploração de óleo e gás, considerando a importância de uma melhor compreensão das relações entre poros e o arcabouço da rocha. Então, as amostras são impregnadas por uma resina e catalisador epoxy, juntamente com um corante azul que preenche os poros. São coladas ao vidro de uma lâmina delgada, cortados e polidos a uma espessura de 30 a 35 μm . Dois conjuntos de lâminas petrográficas foram preparados. O primeiro é proveniente de 75 amostras laterais de dois poços de petróleo. O segundo é um conjunto menor, lâminas de 14 amostras laterais, todas de um terceiro poço.

Embora o segundo conjunto de lâminas petrográficas seja menor, uma análise mais completa foi obtida: todas as 14 lâminas petrográficas do segundo conjunto foram analisadas quimicamente utilizando um equipamento QEMSCAN 650 FEI com dois detectores EDS/Bruker acoplados. Para ambos os conjuntos, todas as lâminas foram analisadas em um microscópio petrográfico óptico, onde imagens coloridas com três canais – RGB – foram adquiridas com lentes objetivas de magnificação 1,25x. Diversas imagens com sobreposições de uma mesma lâmina foram utilizadas para criar fotomosaicos das mesmas, utilizando o método de atributos locais invariáveis proposto por Brown e Lowe (2007), de tal forma a evitar distorções durante a composição da imagem. Cada *pixel* das imagens do primeiro conjunto de lâminas petrográficas apresenta 4,90 μm de lado. O segundo conjunto de imagens foi adquirido com uma resolução melhor, cada *pixel* apresenta 2,55 μm de lado.

Os estágios iniciais dos modelos criados são convolucionais. *Pixels* selecionados a partir dos fotomosaicos serviram como dados de entrada, juntamente

com a extração de atributos realizada pelas operações de convolução. A própria convolução pode ser considerada uma técnica simples de *data augmentation*, pois através de filtros discretos, agrega informação em um *pixel* derivada de seus *pixels* vizinhos. A aplicação dos filtros foi auxiliada pelo plugin *Trainable Weka Segmentation* do ImageJ Fiji 1.51S (SCHINDELIN et al., 2012).

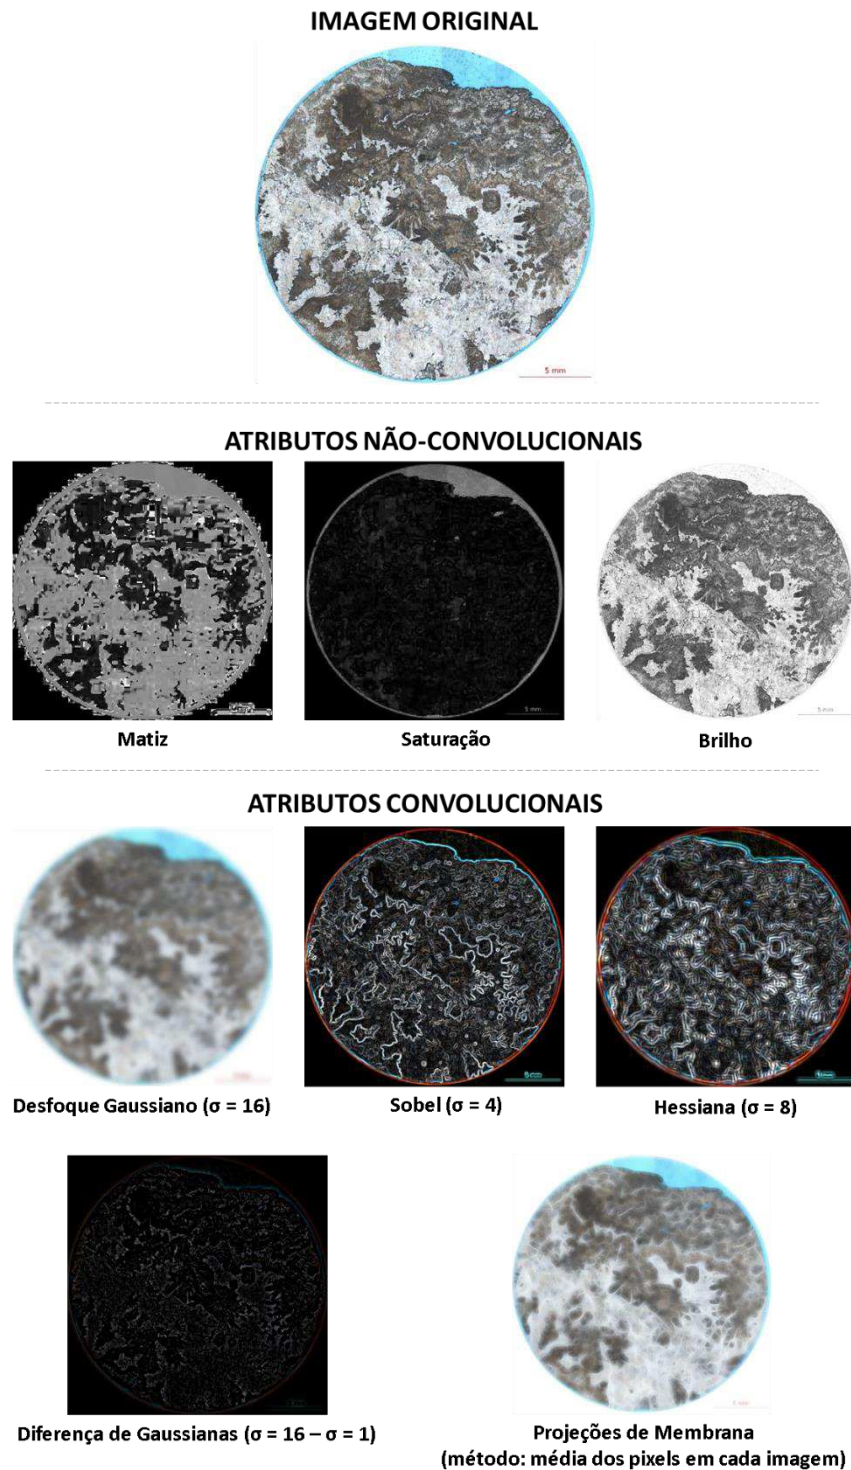
Originalmente, cada *pixel* de uma imagem RGB contém apenas três atributos, todos relacionados à cor. Estes atributos originais são expressos como matiz, saturação e brilho. Antes de aplicar os filtros convolucionais, um atributo extra é acrescentado obtido da conversão da imagem RGB para uma imagem colorida de 8-bit com 256 cores. Também é acrescentado um atributo rotulando uma classe mineral ou poro para cada *pixel* selecionado, um passo essencial considerando que o algoritmo de aprendizado utilizado para criar os modelos é supervisionado. Desta forma, existem cinco atributos não-convolucionais para cada *pixel*.

Os filtros convolucionais são aplicados com o objetivo de agregar informação espacial a uma imagem adicionando a relação de um *pixel* com seus vizinhos, destacando características específicas, tais como contrastes e bordas de feições, dependendo do filtro. A seleção de quais filtros convolucionais utilizar foi baseada na literatura de visão computacional (CAO; MUSÉ; SUR, 2005; SZELISKI, 2010; LECUN; KAVUKCUOGLU; FARABET, 2010; SPONTÓN; CARDELINO, 2015; WIATOWSKI et al., 2016; HAN et al., 2018; KOBAYASHI, 2018). Os seguintes filtros discretos foram escolhidos: desfoque gaussiano, sobel, hessiana, diferença de gaussianas e projeções de membrana. Para cada filtro, atributos são gerados considerando parametrizações diferentes para desvio padrão (σ) e tamanho da janela de membrana.

Filtros de desfoque gaussiano são dependentes de σ . Quanto maiores seus valores, mais borradas as imagens se tornam, ou seja, maior o raio de atuação do filtro em relação ao *pixel* central. Camadas convolucionais dos modelos aplicam filtros de desfoque gaussiano considerando $\sigma_{\min} = 1$ e $\sigma_{\max} = 16$, sendo aplicados filtros para σ_{\min} , $2\sigma_{\min}$, $4\sigma_{\min}$, ..., $2^{n-1}\sigma_{\min}$, onde $2^{n-1}\sigma_{\min} \leq \sigma_{\max}$ e, portanto, $n = 5$. Filtros sobel e hessiana são aplicados a partir das imagens – mapas de atributos – derivadas do desfoque gaussiano para cada σ . Filtros de diferenças de gaussianas são aplicados baseados em duas imagens resultantes de desfoque gaussiano, obtidas por dois σ diferentes. Filtros de projeções de membrana são ajustados utilizando uma matriz zero de 19×19 (tamanho da janela), com as entradas da coluna do meio ajustadas para 1. Rotações deste padrão totalizam 30 filtros que são convolidos com a imagem

original. Os resultados são projetos em uma única imagem utilizando seis métodos diferentes, cada método retorna um atributo. Alguns dos atributos gerados por diferentes filtros, utilizando parametrizações diferentes, são mostrados na Figura 22.

Figura 22. Exemplos de atributos obtidos utilizando filtros convolucionais discretos com diferentes parâmetros.



Fonte: Elaborada pelo autor.

Após as operações de convolução, 75 atributos convolucionais são acrescentados para cada *pixel*. Assim, existem 80 atributos por *pixel* utilizados como entrada para treinar modelos de aprendizado de máquina. Para processar todos esses dados e classificar cada *pixel*, diferentes algoritmos classificadores foram testados.

A natureza é repleta de comportamentos e respostas não-lineares. As propriedades das rochas não é exceção. Para classificar os *pixels* de uma imagem de lâmina petrográfica em uma classe mineral ou poro, os algoritmos classificadores redes neurais artificiais e *random forest* foram utilizados nos dados aumentados por convolução de forma a treinar os modelos com aprendizado supervisionado.

Especificar os parâmetros corretos para ambos algoritmos, somado à qualidade dos dados de treinamento, define a habilidade de eles apresentarem resultados acurados ao problema. Há muitas abordagens para análise de sensibilidade para investigar os melhores parâmetros a serem utilizados (AL-BULUSHI et al., 2012), tanto para redes neurais quanto para *random forest*. Especificamente, para redes neurais, para determinar a arquitetura da rede, uma abordagem é iniciar com a menor rede possível e gradualmente aumentar seu tamanho (HUSH, 1989). Métodos similares são aplicados para *random forest*, entretanto, ao invés de aumentar o tamanho da rede, é o número de árvores que aumenta (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Modelos de teste, utilizando diferentes números de árvore, foram treinados para confirmar o uso deste parâmetro. Todos os modelos de segmentação finais que utilizam *random forest* foram treinados com 200 árvores.

Enquanto *random forest* demanda custos computacionais mais baixos, uma análise de sensibilidade de redes neurais não seria prática, especialmente considerando o número de variáveis a serem avaliadas. Uma abordagem diferente foi escolhida: variações no número de camadas escondidas e seus neurônios foram testadas com base no número de classes e atributos dos dados de treinamento. Embora, em teoria, uma camada escondida seria suficiente para modelar funções contínuas (HORNIK; STINCHCOMBE; WHITE, 1989; IRIE E MIYAKE, 1988), é demonstrado que pode ser necessário um grande número de neurônios (HUANG; HUANG, 1991; HUSH; HORNE, 1993). Acrescentar uma segunda camada auxiliaria em problemas com maiores complexidades e naqueles em que o número de neurônios em uma camada escondida torna-se muito alto (HUSH; HORNE, 1993; THOMAS et al., 2017). Considerando a natureza altamente complexa e comportamento não-linear das imagens de lâminas petrográficas, foi escolhido utilizar

três camadas escondidas em todos os modelos treinados que utilizam redes neurais. Em relação ao número de neurônios de cada camada, uma opção intermediária proposta por Frank, Hall e Witten (2016) sugere somar o número de atributos ao número de classes e dividir por dois. Após as camadas convolucionais, as observações de todos os *datasets* apresentam 80 atributos. Os modelos mineralógicos têm sete classes, portanto seriam necessários 43,5 neurônios. Modelos de porosidade têm duas classes, portanto precisariam de 41 neurônios. Considerando estes números, foi escolhido que todos os modelos de segmentação treinados utilizando redes neurais apresentem três camadas escondidas, cada uma com 45 neurônios.

Um dos parâmetros mais relevantes para uma rede neural é sua função de ativação (MERCIONE; TIRON; HOLBAN, 2019). Elas funcionam como filtros que definem como a informação passa para a próxima camada. Em todos os modelos de segmentação baseados em redes neurais, foi utilizada uma função sigmoide, uma das mais comuns em redes neurais *multilayer perceptron*. Especificamente, foi utilizada uma função logística. O algoritmo de aprendizado foi o gradiente descendente *backpropagation*, considerando uma taxa de aprendizado de 0,3 e 500 épocas. Este algoritmo modifica os pesos dos neurônios nas camadas escondidas com base na força da contribuição de cada neurônio para a predição (WITTEN; FRANK, 2005; ANEMANGELY; RAMEZANZADEH; BEHBOUD, 2019). Uma taxa de aprendizado ideal foi obtida a partir da estabilização com um menor número de épocas.

Cinco modelos de aprendizado de máquina foram treinados: quatro para o primeiro conjunto de lâminas petrográficas e um para o segundo conjunto. Eles segmentam os fotomosaicos em diferentes classes minerais e porosidade. Para o primeiro conjunto, dois dos modelos foram treinados com o objetivo de segmentar fases minerais e os outros dois com o objetivo de segmentar especificamente porosidade. Para o segundo conjunto, um modelo que segmenta fases mineralógicas foi treinado. O *Waikato Environment for Knowledge Analysis* (WEKA) é uma interface gráfica desenvolvida por Witten et al. (1999), atualizada por Hall et al. (2009) e Frank, Hall e Witten (2016). Foi utilizada para aplicar diferentes implementações em Java de algoritmos de aprendizado de máquina, cada um com diferentes ajustes de parâmetros. Particularmente, redes neurais artificiais e *random forest* foram comparados.

Os modelos classificam *pixel a pixel* as imagens de entrada, criando imagens

de saída segmentadas, onde cada *pixel* representa uma classe mineral ou poro. Sete classes foram definidas para os modelos mineralógicos: calcita, dolomita, quartzo, minerais opacos, argilas, outros e poros. Estas classes foram escolhidas com base no contexto mineralógico e estratigráfico dos reservatórios estudados (MOREIRA et al., 2007; AHR, 2008; TERRA et al., 2010; DIAS-BRITO; TIBANA, 2015; WRIGHT; TOSCA, 2016; LIMA; DE ROS, 2019). Também foram considerados os resultados de microanálises químicas obtidos do segundo conjunto de lâminas petrográficas e limitações da análise de microscopia óptica, como a definição da classe minerais opacos. Considerando que os algoritmos classificam duas classes melhor do que sete, a escolha de criar modelos especificamente para análise de poros é uma tentativa de obter resultados mais acurados.

A partir dos 75 fotomosaicos do primeiro conjunto de lâminas petrográficas, 310.549 *pixels* (instâncias) foram selecionados e rotulados em uma das sete classes minerais para treinar os dois modelos mineralógicos – *dataset* 1. Modelos de porosidade foram treinados com 640.965 *pixels*, considerando somente duas classes: poro e não-poro – *dataset* 2. Dois modelos foram criadas para cada um dos *datasets*: um utilizando redes neurais artificiais e o outro, *random forest*. Utilizando o segundo conjunto de lâminas – 14 fotomosaicos –, 479.380 *pixels* foram selecionados – *dataset* 3. Foram utilizados para treinar um modelo mineralógico validado por microanálises químicas, utilizando *random forest* (Tabela 02).

Tabela 02. Modelos treinados e os respectivos algoritmos utilizados, conjunto de lâminas correspondente e dados de treinamento.


Modelos	Algoritmos	Lâminas Petrográficas	Dados de Treinamento
1 Modelo mineralógico	Redes Neurais Artificiais	Conjunto 1 (75 fotomosaicos)	Dataset 1 (310.549 instâncias)
2 Modelo mineralógico	Random Forest	Conjunto 1 (75 fotomosaicos)	Dataset 1 (310.549 instâncias)
3 Modelo de porosidade	Redes Neurais Artificiais	Conjunto 1 (75 fotomosaicos)	Dataset 2 (640.965 instâncias)
4 Modelo de porosidade	Random Forest	Conjunto 1 (75 fotomosaicos)	Dataset 2 (640.965 instâncias)
5 Modelo mineralógico	Random Forest	Conjunto 2 (14 fotomosaicos)	Dataset 3 (479.380 instâncias)

Fonte: Elaborada pelo autor.

A maioria dos classificadores, incluindo redes neurais e *random forest* focam na melhoria da acurácia na predição da classe majoritária de um *dataset* de treinamento, minimizando a taxa de erro total (CHEN; LIAW; BREIMAN, 2004). Os três *datasets* criados a partir dos dois conjuntos de lâminas petrográficas apresentam desbalanceamento das ocorrências de minerais e poros (Figura 23). Embora o

random forest crie árvores que forcem as classes menos representativas a serem levadas em consideração, todos os *datasets* foram normalizados segundo um algoritmo que ajusta o peso das instâncias (WITTEN et al., 1999), impedindo que a classificação seja enviesada pelo desbalanceamento.

Figura 23. Distribuição dos três *datasets* de treinamento de acordo com suas classes, evidenciando o desbalanceamento.



Fonte: Elaborada pelo autor.

3.2. Modelos de Detecção de Objetos


Quando a feição de interesse passa a ser maior do que um *pixel*, como uma estrutura formada por uma composição de *pixels*, esta feição é denominada um objeto. Para análise de feições de interesse que podem ser caracterizadas como um objeto, são criados modelos de detecção de objetos. Novos dados de treinamento são selecionados e rotulados a partir das imagens de fotomosaicos, utilizando as imagens obtidas pelo modelo de segmentação como referência. Foram criados modelos de detecção de fragmentos fosfáticos.

Inicialmente, foi aplicado um filtro de ruído nas imagens, com o objetivo de destacar somente as feições mais relevantes para a identificação do fragmento fosfático. Foi utilizado um filtro proposto por Buades e Morel (2005) que é chamado *Non-Local Means* (NLM). A aplicação deste filtro é realizada com o uso de funções custo para agrupamento de *pixels* similares em segmentos homogêneos, minimizando heterogeneidades médias. O filtro é aplicado antes da etapa de seleção dos dados de treinamento.

Foram selecionadas 675.798 instâncias categorizadas em apenas duas classes: fragmentos fosfáticos e outros (Figura 24). Assim como os modelos de segmentação de porosidade, a classificação binária proposta nestes modelos permite maior acurácia na identificação de um elemento de interesse. Neste tipo de modelo, é

comum observar *datasets* muito desbalanceados, pois, em geral, os objetos de interesse para identificação ocorrem de forma mais restrita do que outros elementos da imagem. Para prevenir uma classificação enviesada, novamente, o método utilizado pelos modelos de segmentação foi reproduzido: o *dataset* de treinamento foi normalizado ajustando-se o peso das instâncias (WITTEN et al., 1999).

Figura 24. *Dataset* utilizado para treinamento do modelo de detecção de fragmentos fosfáticos. Os dados foram normalizados através do ajuste do peso das instâncias.




Fonte: Elaborada pelo autor.

Ainda antes de treinar um classificador, são aplicados filtros convolucionais, com a intenção de adicionar novos atributos aos dados de treinamento, ampliando o número de atributos de cada *pixel* (originalmente, cada *pixel* apresenta três atributos, um para cada canal de cor). São aplicados os mesmos filtros discretos utilizados nos modelos de segmentação, utilizando os mesmos parâmetros: desfoque gaussiano, sobel, hessiana, diferença de gaussianas e projeções de membrana. Cada observação do *dataset* de treinamento passa a ter 80 atributos, sendo 75 convolucionais e 5 não convolucionais (três canais de cor, conversão para 8-bit e categoria anotada). Os dados de treinamento alimentam um algoritmo classificador *random forest* com 200 árvores.

A imagem de saída deste modelo é binária. Entretanto, é comum a ocorrência de falsos positivos, com um número total de *pixels* por agrupamento baixo, que não corresponde ao elemento de interesse. Operadores morfológicos são, então, utilizados para eliminar estes falsos positivos. Uma sequência de operações de erosão e dilatação foi criada a partir de algoritmo disponibilizado por Schindelin *et al.*, 2012.

O resultado final do modelo não é, entretanto, uma imagem binária. Após a eliminação dos falsos positivos, são geradas caixas de seleção (*bounding boxes*) ao redor dos grupos de *pixels* remanescentes da sequência de erosão e dilatação. O posicionamento espacial das caixas de seleção em relação à imagem binária é registrado. Como a distribuição espacial da imagem original é a mesma da imagem binária, são criadas novas caixas de seleção sobre a imagem original com base no registro realizado anteriormente. Esta é a saída do modelo. A Figura 25 apresenta os métodos aplicados de forma simplificada.

Figura 25. Sequência para a criação do modelo de detecção de fragmentos fosfáticos.



Fonte: Elaborada pelo autor.

3.3. Modelos de Classificação


A análise integrada de uma imagem como um todo, ou seja, a avaliação da ocorrência de diferentes objetos em uma imagem, assim como as características de feições de interesse em escala de grupos de *pixel*, permite rotular toda a imagem como pertencente a uma classe. Os dados de treinamento passam a ser um conjunto de imagens rotuladas, que alimentam modelos de classificação. Ao aplicar os modelos em imagens novas, eles rotulam a imagem em uma das classes. Foram criados modelos de classificação de litofácies, além de modelos de classificação para o tipo de porosidade.

3.3.1. Classificação de litofácies

O *dataset* original utilizado no treinamento dos modelos de classificação de litofácies foi construído com base na aquisição de 96 imagens de fotomosaicos correspondentes a lâminas delgadas confeccionadas a partir de amostras laterais. As amostras utilizadas para treinamento e teste foram todas obtidas das paredes de um poço específico, perfurado baseado em um alto estrutural identificado em dado sísmico. Seleções quadradas de tamanhos variados foram utilizadas para criar 801 instâncias a partir destes fotomosaicos (Figura 26). Então, elas foram redimensionadas para imagens de 256 x 256 *pixels*. Seis categorias de litofácies

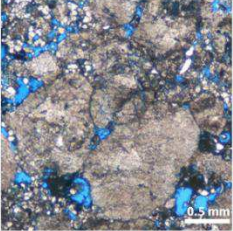
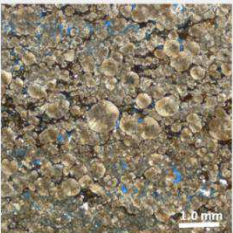
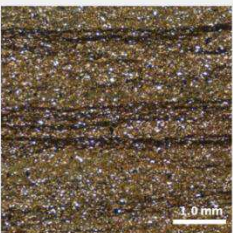
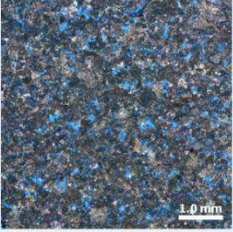
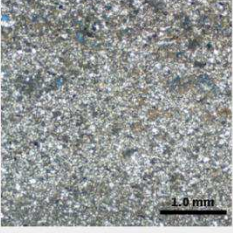
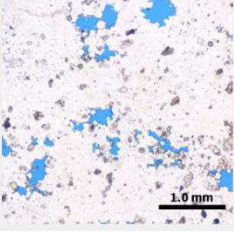
foram definidas para treinamento dos modelos: estromatólito, esferulítico, laminito, grainstone, dolomito e silexito. Apesar da utilização da proposta de Terra et al. (2010) como referência de classificação de rochas carbonáticas, considerando o contexto das amostras, a última categoria definida não foi apresentada por estes autores. Trata-se de uma adaptação vinculada ao grupo cujas texturas originais não podem ser reconhecidas devido à atuação de processos diagenéticos. A Figura 27 apresenta as principais características de cada classe, junto com uma observação correspondente para cada classe retirada do *dataset* original.

Figura 26. Representação do corte das imagens de fotomosaicos das lâminas petrográficas delgadas em tamanho 2000 x 2000 *pixels*. O *dataset* é composto por cortes de 1000 x 1000 a 3000 x 3000 *pixels*.



Fonte: Elaborada pelo autor.

Figura 27. Categorias de litofácies selecionadas para treinamento dos modelos de classificação, a descrição de suas características principais e um exemplo de uma observação do *dataset* original. As escalas no canto inferior direito das imagens foram acrescentadas posteriormente, não fazer parte do *dataset*.


Litofácies	Descrições	Imagens de exemplo
Estromatólito	Litofácies caracterizada pela presença de estruturas de crescimento de calcita in situ, podendo apresentar padrões fibrosos ou colunar. Estas estruturas são interpretadas como sendo de origem química ou microbial. Altas porosidades são observadas em padrões no arcabouço de crescimento, mas também podem ocorrer em espaço interelemento. A porosidade pode ser ampliada por processos diagenéticos - como a dissolução - ou reduzida pelos mesmos - devido à cimentação, geralmente dolomítica.	
Esferulítico	Estas rochas consistem de agregados calcíticos esféricos a subsféricos - esferulitos - geralmente menores do que 2 mm, podendo ocorrer de forma amalgamada ou isolada. Podem ser homogêneos em termos de tamanho ou apresentarem gradação. Esferulititos são a combinação de esferulitos ocorrendo dispersos em material de origem singenética - minerais argilomagnesianos - ou dolomitas no espaço interelemento. Porosidade é baixa, ocasionalmente associada à filmes de dissolução de matéria orgânica.	
Laminito	Litofácies de grãos finos com estruturas laminadas paralelizadas que podem estar suavizadas ou crenuladas. A laminação é destacada por diferenças composicionais, alternando calcita cristalina, dolomitas, minerais argilomagnesianos e matéria orgânica. Porosidade é baixa, podendo ocorrer como microporos ou em um padrão fenestral, associado a processos de dissolução e degradação de matéria orgânica. Laminações silicificadas são resultados diagenéticos comuns.	
Grainstone	Rochas com componentes que não são ligados durante a formação - retrabalhados - com muito pouco (abaixo de 5%) ou nenhuma matriz. Sua trama é suportada pelos grãos. Estes grãos feitos de fragmentos de estromatólitos, laminitos, esferulititos, esferulititos e bioclastos. Eles apresentam granulometria variada, com seleção moderada a boa. São geralmente associados a alta porosidade interpartícula, que pode ser ampliada por processos diagenéticos de dissolução.	
Dolomito	Texturas deposicionais originais não identificadas devido a processos diagenéticos de dolomitização. Porosidade é geralmente baixa, restrita ao espaço intercrystalino e, eventualmente, ampliada por vugs.	
Silexito	Litofácies de alteração hidrotermal onde o acamamento de calcita foram obliterados durante a diagenese e substituição por sílica. Eventualmente, é possível identificar texturas residuais da rocha protólito, mas estas são insuficientes para caracterizar uma litofácies deposicional. A porosidade é variável. Microporos geralmente estão presentes, mas vugs e fraturas podem mudar a maior parte do arcabouço poroso.	

Fonte: Elaborada pelo autor.

O tamanho da seleção utilizada para criar as instâncias a partir de fotomosaicos é definida pelo contexto da rocha, considerando feições mínimas que permitem a identificação de litofácies. A escolha de permitir seleções com tamanhos variados está associada à capacidade de generalização dos modelos: ao treinar os modelos sem um parâmetro de escala, qualquer imagem de entrada pode ser avaliada pelo melhor modelo, permitindo maior flexibilidade em sua utilização. Entretanto, os modelos perdem a habilidade de prever classes que são distintas exclusivamente por tamanho de partículas, como as diferenças entre as categorias grainstone e rudstone. Essas litofácies são diferenciadas pelos diâmetros dos grãos: ambas são suportadas por grãos com pouca ou nenhuma matriz, mas com diâmetro maior que 2 mm em mais de 10% dos grãos, quando caracterizando rudstones. Se rudstones fossem incluídos como uma categoria nos modelos preditivos, considerando o tamanho variável das seleções, as instâncias não seriam diferentes das observadas na classe grainstone. Por isso, a classe rudstone não foi incluída. Ao invés disso, a classe grainstone foi escolhida para representar rochas carbonáticas retrabalhadas. Se os modelos fossem prever uma imagem correspondente a um rudstone, a expectativa é de que a imagem seja classificada como um grainstone.

Como apresentado na Figura 28, o *dataset* é altamente desbalanceado, devido a um viés de amostragem. Aproximadamente 20% do *dataset* original foi utilizado como conjunto de validação, o que corresponde a 159 imagens. Para o conjunto de validação, a proporção entre as classes foi respeitada. Esta divisão deixou o *dataset* de treinamento somente com 642 imagens. As mesmas proporções desbalanceadas foram mantidas no *dataset* de teste, que foi criado baseado nas dimensões do *dataset* de validação. O *dataset* de teste também foi criado utilizando seleções quadradas de tamanhos variáveis e, então redimensionados para 256 x 256 *pixels*. Entretanto, a fonte das seleções foram imagens de fotomosaicos obtidas de lâminas delgadas provenientes de amostras laterais coletadas em outros dois poços adjacentes, ambos ocorrendo no mesmo contexto geológico do poço utilizado para a criação do *dataset* original. A escolha de dados de teste a partir de poços adjacentes garante que a avaliação dos modelos considere suas capacidades preditivas no contexto de um campo de petróleo. Parte do desbalanceamento do *dataset* original é minimizado através da geração de imagens sintéticas com o uso de redes adversárias geradoras. Estas imagens sintéticas são, então, adicionadas para treinamento.

Figura 28. Distribuição do *dataset* original, destacando os conjuntos de treinamento e validação. A distribuição do *dataset* de teste também é mostrada. Seu tamanho corresponde a aproximadamente 20% do *dataset* original e mantém a mesma proporção de desbalanceamento. Posteriormente, o *dataset* de treinamento foi enriquecido com imagens sintéticas geradas por redes adversárias geradoras e o desbalanceamento foi reduzido.

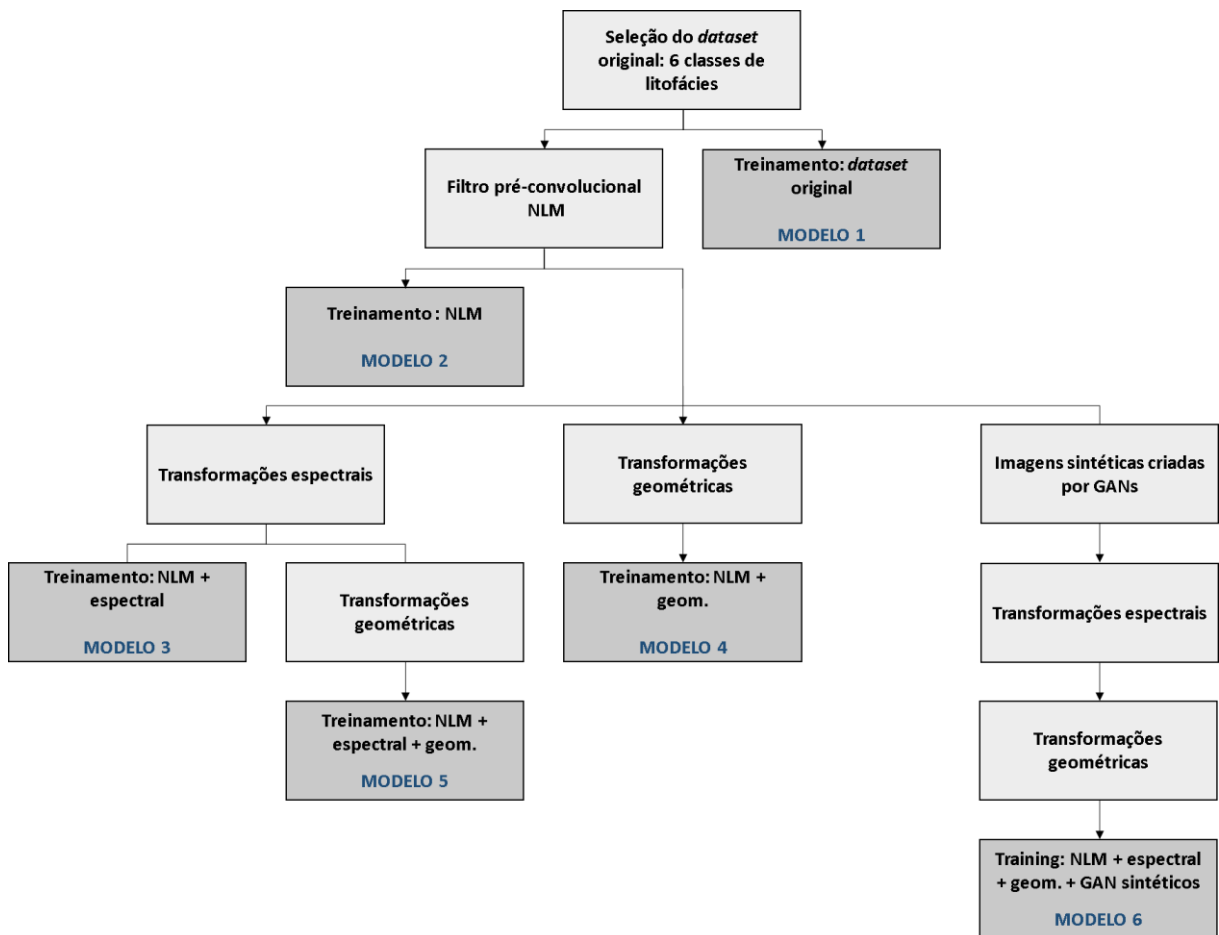


Fonte: Elaborada pelo autor.

Após a aquisição de imagens de fotomosaicos de amostras provenientes de três poços utilizando microscopia óptica, *datasets* de treinamento e validação foram construídos baseados em seleções quadradas de imagens obtidas de um dos poços. Imagens dos outros dois poços foram utilizadas para criar um *dataset* de teste utilizando a mesma seleção quadrada de tamanho variável, com a perspectiva de avaliar a capacidade de generalização dos modelos. Enquanto o *dataset* de teste permanece preservado de qualquer alteração, as seguintes transformações são gradualmente implementadas no *dataset* de treinamento: 1. um filtro pré-convolucional é aplicado de forma a reduzir ruídos; 2. considerando a natureza das imagens de microscopia, a nomenclatura “transformações espectrais” está sendo proposta para alterações baseadas no deslocamento de uma janela através da região visível do espectro eletromagnético, geralmente referenciadas como transformações de cor; 3.

transformações geométricas são aplicadas: rotações, espelhamento, deslocamento, corte e deformação das imagens; 4. imagens sintéticas são geradas utilizando GANs e ampliam o *dataset* de treinamento original. Após cada etapa de transformação, um modelo de rede neural convolucional é treinado e avaliado com base no *dataset* de teste intocado, como detalhado na Figura 29.

Figura 29. Fluxo geral para treinamento dos modelos após cada passo de transformação dos dados. As seguintes abreviações foram utilizadas: Non-Local Means (NLM), técnicas de augmentation espectral (espectral), técnicas de *augmentation* geométrico (geom.), e imagens sintéticas geradas por redes adversárias geradoras (GAN sintéticos).




Fonte: Elaborada pelo autor.

A aplicação de um filtro pré-convolucional nas imagens originais tem a intenção de destacar feições de interesse e eliminar o que seria considerado ruído para o reconhecimento de litofácies. Estes tipos de filtros foram discutidos e utilizados de forma bem-sucedida por muitos anos (GEMAN et al., 1990; JAIN; FARROKHANIA, 1991; MAO; JAIN, 1992; HOFMANN; PUZICHA; BUHMANN, 1998; entre outros). O

mesmo filtro NLM utilizado no modelo de detecção de fragmentos fosfáticos é utilizado para o modelo de classificação de litofácies, proposto por Buades e Morel (2005).

A Figura 30 destaca a importância da aplicação do NLM. Um filtro convolucional discreto *sobel* é aplicado em uma instância original, e então novamente na mesma instância após a aplicação do filtro NLM. A comparação entre os resultados revela a ocorrência de muitos elementos texturais que apresentam baixa relevância para a classificação de litofácies. Após aplicar NLM para as imagens do *dataset* original, feições de interesse são destacadas e feições consideradas ruídos para a classificação de litofácies são eliminadas.

Figura 30. Aplicação do filtro convolucional discreto *sobel* em uma das instâncias do *dataset* original – classe esferulítico –, antes e depois da filtragem NLM. Feições destacadas após a aplicação do filtro pré-convolucional são mais relevantes para a classificação de litofácies.




Fonte: Elaborada pelo autor.

O *dataset* de treinamento criado para o modelo de classificação de litofácies apresenta apenas 642 instâncias para 6 classes diferentes. Estas imagens foram obtidas por diferentes petrógrafos, a partir de microscópios e câmeras diferentes, e sob condições de iluminação distintas. É um *dataset* bastante reduzido e heterogêneo, comumente observado em aplicações originadas de dados reais provenientes de diversas indústrias (PALEYES; URMA; LAWRENCE, 2020). Problemas relacionados à quantidade e qualidade de dados ocasionam um descompasso entre a aplicação de arquiteturas de redes neurais mais complexas e a utilização de dados verdadeiros. As arquiteturas de redes neurais convolucionais foram sugeridas nos últimos anos com base em *datasets* criados de forma padronizada e massiva, como os obtidos através de interações em redes sociais, serviços de *streaming* e armazenamento em nuvem. Para solucionar este descompasso, a arquitetura utilizada nos diferentes modelos treinados é mantida fixa e uma abordagem centrada no dado é priorizada, através da utilização de transformações e da criação de imagens sintéticas.

O primeiro conjunto de transformações utilizado é uma técnica de *augmentation* dos dados normalmente referenciada como *augmentation* de cor – *color augmentation* (WU et al., 2015). Considerando que as imagens obtidas a partir dos microscópios são adquiridas na região do visível do espectro eletromagnético, o termo *augmentation* espectral – *spectral augmentation* – está sendo proposto por este trabalho como referência a estas transformações. Consiste em criar novas imagens a partir do deslocamento de uma janela reduzida através da região visível do espectro eletromagnético. Considerando variações nos sensores dos diferentes fabricantes de câmeras, esta técnica possibilita que os modelos realizem previsões de imagens originadas de diferentes equipamentos. Sua aplicação também tem por objetivo compensar uma eventual falta de partes do espectro visível na fonte de luz dos microscópios. As seguintes configurações pré-ajustadas, disponibilizadas por Schindelin et al. (2012), foram utilizadas para ampliar o *dataset*: equalização de histograma, ampliação de contraste, nitidez, ampliação RGB, priorização do canal vermelho, priorização do canal verde, priorização do canal azul, dicromacia deuteranopia, e dicromacia tritanopia. A Figura 31 mostra um exemplo de cada uma destas configurações aplicadas em uma das instâncias do *dataset* de treinamento. Aplicar este conjunto de transformações implica em instantaneamente ampliar o *dataset* original em dez vezes.

Figura 31. Instância original da classe grainstone – no topo, à esquerda – seguida pelo resultado da aplicação de configurações pré-ajustadas de augmentation espectrais: equalização de histograma, ampliação de contraste, nitidez, ampliação RGB, priorização do canal vermelho, priorização do canal verde, priorização do canal azul, dicromacia deuteranopia, e dicromacia tritanopia.

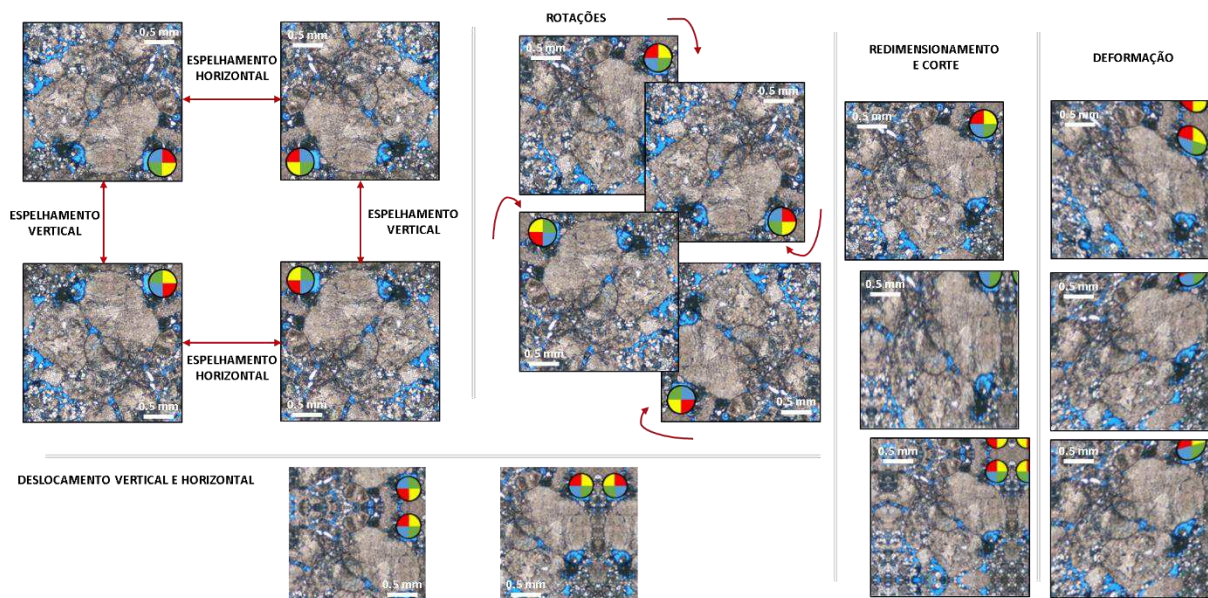


Fonte: Elaborada pelo autor.

O próximo conjunto de técnicas de transformações é baseado em alterações geométricas (LECUN et al., 1998; KRIZHEVSKY; SUTSKEVER; HINTON, 2012; HOWARD, 2013). Através do acréscimo de rotações, espelhamento, deslocamento, corte, e deformações das imagens, vieses relacionados à posição no *dataset* de treinamento são reduzidos em relação ao *dataset* de teste ou a novas imagens. Isto implica na ampliação da capacidade dos modelos em reconhecer feições de interesse em uma nova imagem, mesmo que elas ocorram em lugares em que não estavam presentes no *dataset* original. Entretanto, estas transformações podem alterar a categoria das instâncias, dependendo de seus parâmetros de aplicação ou da natureza do *dataset*. Por exemplo, rotacionar uma imagem correspondente ao dígito 6 pode resultar no dígito 9, alterando sua categoria. Este não é um problema para imagens de lâminas petrográficas, considerando que litofácies permanecem as mesmas, independente das rotações de uma imagem. As imagens foram aleatoriamente rotacionadas a cada 36 graus, viabilizando dez possíveis posições. A deformação de imagens já é diferente, pois as rochas podem de fato ter passado por algum processo de deformação ou cisalhamento devido processos diagenéticos, tectônicos ou metamórficos. Por isso, o uso desta técnica foi realizado com cautela,

limitando o parâmetro ângulo em 0,2 radianos. Deslocamentos aleatórios na horizontal e na vertical foram limitados a uma região correspondente a 30% do tamanho total da imagem. Sempre que necessário, o preenchimento de uma região foi realizado com a reflexão da imagem modificada. Este preenchimento é necessário após as operações de deslocamento, corte ou deformação. A Figura 32 mostra um exemplo das transformações geométricas aplicadas em uma das instâncias do *dataset* de treinamento.

Figura 32. Técnicas de aumento geométrico aplicadas em uma instância da classe estromatólito: rotações, espelhamento, deslocamento, corte e deformação. Um círculo com as cores azul, vermelho, amarelo e verde foi adicionado à instância original com o objetivo de destacar o efeito de cada transformação.




Fonte: Elaborada pelo autor.

O último conjunto de técnicas de aumento e ampliação de dados utilizado neste trabalho é a criação e utilização de imagens sintéticas no *dataset* de treinamento. Estas imagens sintéticas foram criadas utilizando redes adversárias geradoras. Especificamente, uma implementação baseada em uma arquitetura de *Deep Convolutional GANs* (RADFORD; METZ; CHINTALA, 2016). A Figura 33 mostra um exemplo de imagens sintéticas geradas para cada classe. O *dataset* original foi criado com imagens quadradas de três canais, com lados de pelo menos 256 *pixels*. Sempre que maiores, elas são reduzidas para este tamanho antes do treinamento dos modelos. Apesar de os modelos apresentarem imagens com 256 x 256 *pixels* de

entrada, imagens sintéticas quadradas com três canais foram criadas apresentando lados de 64 *pixels*, a fim de reduzir o custo computacional de criar imagens maiores. Este é o mesmo tamanho dos mapas de atributos antes da última camada convolucional dos modelos. Elas são, posteriormente, ampliadas para 256 x 256 *pixels* através de interpolação bilinear, viabilizando sua integração ao *dataset* de treinamento. Entre outras técnicas (LEEVY et al., 2018), a ampliação de *datasets* através de imagens sintéticas é uma forma eficiente de reduzir o desbalanceamento.

Figura 33. Exemplo de imagens sintéticas geradas por GANs para cada uma das seis categorias: estromatólito, esferulítico, laminito, grainstone, dolomito e silexito. As imagens foram criadas com resoluções mais baixas para reduzir custos computacionais. Não é possível inserir escalas, pois elas foram geradas a partir de imagens com escalas diferentes.



Fonte: Elaborada pelo autor.

Todas estas transformações no *dataset* original não necessariamente implicam em um aumento no número de instâncias para treinamento dos modelos. A aplicação do filtro NLM não muda o número total de instâncias, uma vez que as imagens originais não são utilizadas para o treinamento. Os aumentos espectrais de fato ampliam o número de instâncias em uma magnitude de dez: para cada imagem original, nove novas imagens são criadas e adicionadas ao *dataset*. Isto significa que, após aplicar os aumentos espectrais, o *dataset* de treinamento apresenta 6420 instâncias. Os aumentos geométricos são implementados de forma que o número de

instâncias utilizados para cada época durante o treinamento permanece o mesmo. Entretanto, as próprias instâncias mudam aleatoriamente durante cada época de acordo com os parâmetros detalhados anteriormente. Até mesmo as instâncias originais não são utilizadas, mas sim variações aleatórias destas instâncias. Eventualmente, algumas destas variações são muito similares às imagens originais. Assim, existe potencialmente o número inicial de instâncias vezes o número de épocas sendo utilizado para o treinamento dos modelos. Isso quer dizer que, nos modelos em que foram realizados *augmentations* espectrais, *augmentations* geométricos criam o potencial de 6420 imagens vezes o número de épocas utilizadas para o treinamento. A palavra “potencial” é empregada devido ao fato de existir uma remota possibilidade estatística dos *augmentations* geométricos aleatoriamente criarem duas ou mais imagens que são exatamente iguais.

Seis modelos diferentes foram treinados utilizando: 1. somente o *dataset* original; 2. imagens do *dataset* original em que o filtro NLM foi aplicado; 3. somente aumentos espectrais nas imagens que foram submetidas ao filtro NLM; 4. somente aumentos geométricos nas imagens que foram submetidas ao filtro NLM; 5. ambos os aumentos espectrais e geométricos nas imagens que foram submetidas ao filtro NLM; 6. filtragem com NLM, aumentos espectrais e geométricos nas imagens do *dataset* original ampliado por imagens sintéticas geradas por redes adversárias geradores. Para avaliar esta abordagem centrada no dado, as arquiteturas de redes neurais convolucionais de todos os modelos foram mantidas inalteradas. Somente parâmetros de treinamento, tais como taxa de aprendizado e épocas, foram modificados de forma que fossem adequados às circunstâncias de cada modelo. Estes parâmetros foram obtidos com base na evolução de acurácia e perdas, verificadas durante o treinamento a partir do *dataset* de validação. Características específicas para cada modelo são destacadas na Tabela 03.

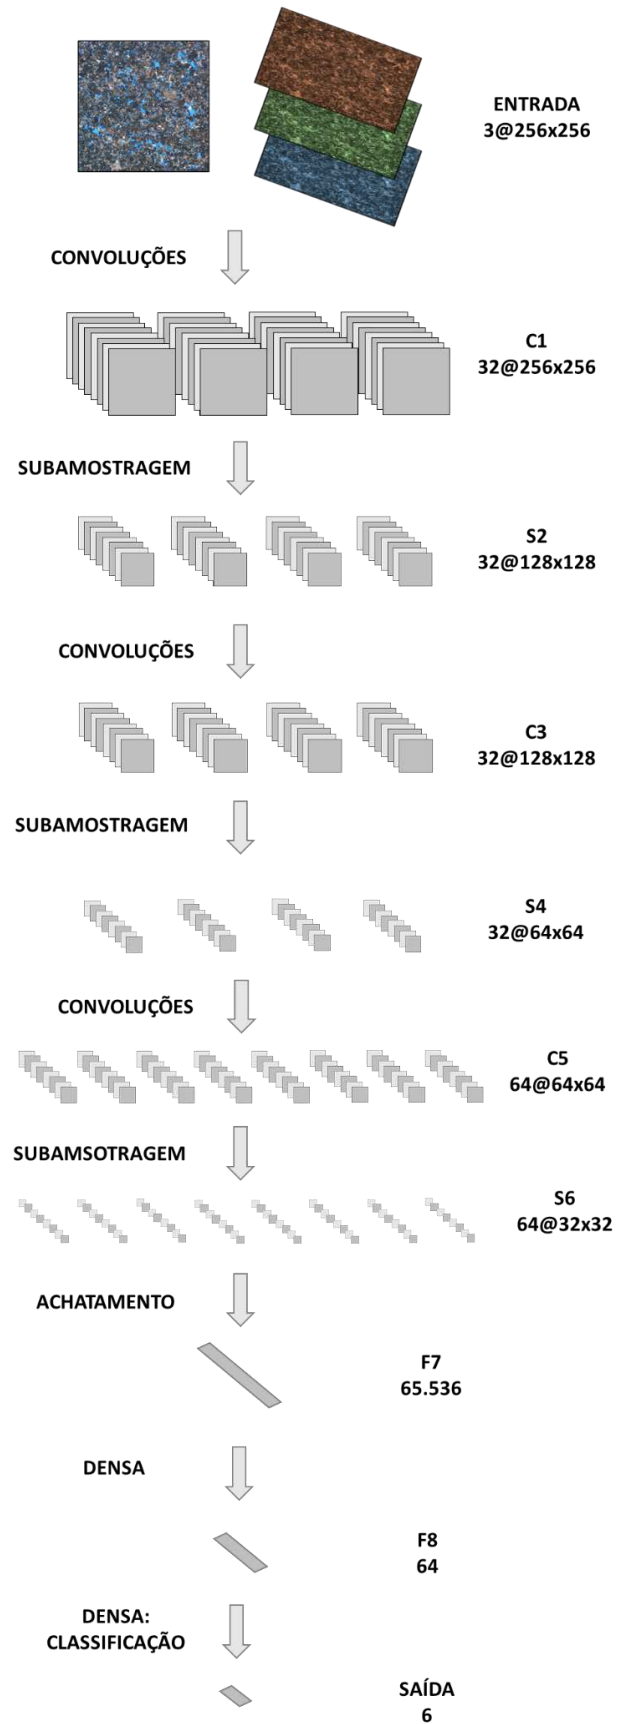
Tabela 03. Parâmetros e características utilizadas para treinamento dos modelos de classificação de litofácies.

Modelos	Épocas	Taxa de aprendizado	Transformações	Instâncias por época	Número de imagens durante o treinamento
1	50	0,0001	None	642	642
2	50	0,0001	NLM	642	642
3	50	0,0001	NLM + spectral augmentations	6.420	6.420
4	250	0,0001	NLM + geometric augmentations	642	160.500
5	250	0,001	NLM + spectral augmentations + geometric augmentations	6.420	1.605.000
6	300	0,001	GAN synthetic images + NLM + spectral augmentations + geometric augmentations	11.060	3.318.000

Fonte: Elaborada pelo autor.

A arquitetura de rede neural convolucional fixa utilizada para todos os modelos é bastante simples de forma que o foco do desenvolvimento da pesquisa não fosse nos modelos em si, mas sim nas técnicas de transformação dos dados. É uma arquitetura projetada com base na LeNet-5, proposta por LeCun et al. (1998). Modificada para receber imagens maiores e maior número de dimensões. Também foram acrescentadas algumas camadas (Figura 34). As imagens de entrada apresentam 256×256 *pixels* e três canais coloridos. Elas passam por uma camada convolucional que gera 32 mapas de atributos do mesmo tamanho. Então, uma camada de subamostragem utilizando *maxpooling* reduz os 32 mapas de atributos para 128×128 *pixels*. Este par de camadas convolucional-subamostragem repete-se mais duas vezes. Na segunda vez, o número de mapas de atributos é mantido, mas seus tamanhos caem para 64×64 *pixels*. Na última vez que este par de camadas é aplicado, ele dobra o número de mapas de atributos para 64 e reduz os tamanhos para 32×32 *pixels*. Após isso, há uma camada de achatamento seguida por duas camadas densas que resultam na classificação em seis categorias. A função de ativação utilizada para todas as camadas é a ReLu, exceto para a última camada de classificação, que utiliza Softmax.

Figura 34. Arquitetura da rede neural convolucional, fixa e utilizada para todos os modelos.



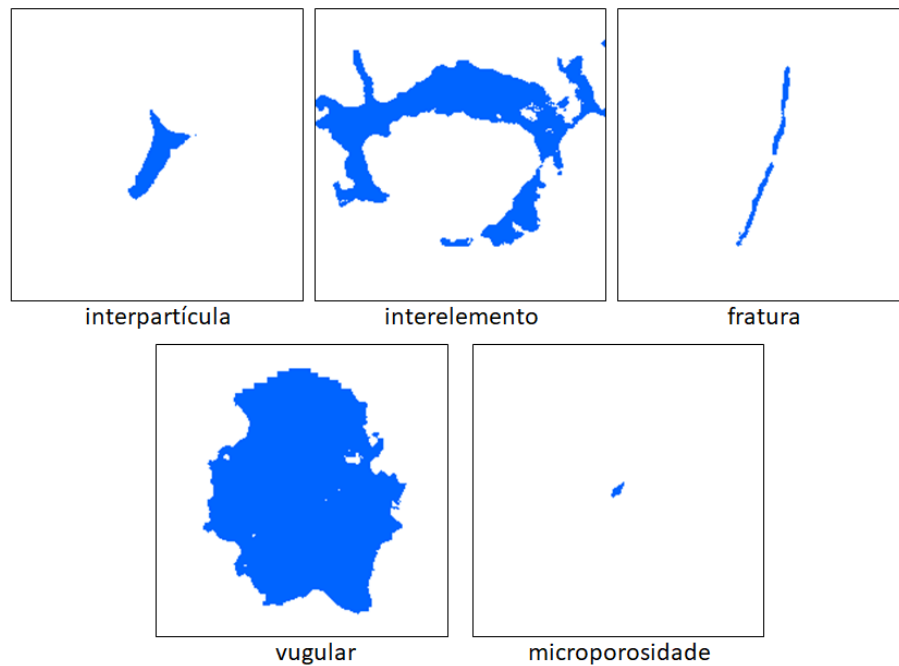
Fonte: Elaborada pelo autor.

Para todos os modelos, o *dataset* de validação foi utilizado para calcular acurácia e perdas durante o treinamento. Desta forma, parâmetros ideais foram escolhidos para respeitar características específicas dos *datasets* de treinamento. Ao final do treinamento, a acurácia é obtida não somente para os dados de validação, mas também para o *dataset* de teste com imagens de amostras de poços diferentes. Acurácias obtidas do *dataset* de teste permitem a avaliação da capacidade de generalização dos modelos. Tanto para os *datasets* de validação quanto para teste, matrizes de confusão normalizadas são calculadas para avaliar os modelos considerando cada uma das categorias de saída.

3.3.2. Classificação do tipo de porosidade

Os modelos de classificação do tipo de porosidade foram treinados a partir de imagens binárias com classes “poro” e “não-poro”, provenientes do modelo de segmentação de porosidade que utiliza *random forest*. Após a obtenção das imagens segmentadas, alguns dos poros podem permanecer conectados por gargantas de poros. Para individualizá-los, as gargantas de poros são eliminadas através do operador morfológico de erosão. As imagens dos poros individualizados apresentam tamanho padrão de 200 x 200 *pixels* e cada *pixel* apresenta um tamanho de lado de 5 μm . Diferentemente dos modelos de classificação de litofácies, a escala é relevante para os modelos de classificação do tipo de porosidade. Estas imagens são rotuladas com base na proposta de Choquette e Pray (1970), com uma modificação. Os modelos classificam poros de reservatórios carbonáticos em cinco categorias: 1. interpartícula, 2. interelemento, 3. fratura, 4. vugular e 5. microporosidade (Figura 35). A classe intitulada “microporosidade” não faz parte da classificação proposta pelos autores, é acrescida devido à ocorrência de feições abaixo da resolução que viabiliza uma classificação coerente.


Figura 35. Exemplos de observações para as cinco categorias do *dataset* de treinamento.



Fonte: Elaborada pelo autor.

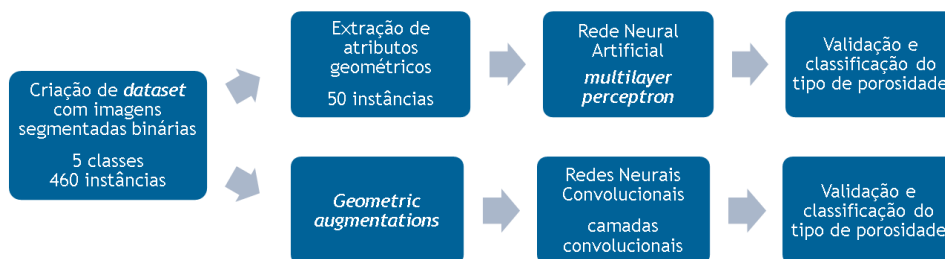
As imagens binárias dos poros individualizados foram aleatoriamente divididas em *datasets* de treinamento, validação e teste, respeitando uma distribuição de aproximadamente 70%, 20% e 10%, respectivamente (Figura 36). Inicialmente, um subconjunto de todas as observações foi criado, com somente 10 observações por categoria, tornando o *dataset* balanceado. Deste subconjunto, atributos geométricos são extraídos e utilizados para classificação. Uma segunda abordagem foi a utilização de todas as observações com peso das instâncias ajustados (WITTEN et al., 1999) para treinamento de uma rede neural convolucional. A Figura 37 apresenta uma síntese das etapas para treinamento e validação dos modelos de classificação do tipo de porosidade.

Figura 36. Distribuição do *dataset* original, destacando os conjuntos de treinamento e validação. O *dataset* só é utilizado integralmente no modelo que utilizou rede neural convolucional. O modelo baseado em atributos geométricos utilizou somente um subconjunto deste *dataset*.



Fonte: Elaborada pelo autor.

Figura 37. Síntese das etapas realizadas para o treinamento e validação dos modelos de classificação do tipo de porosidade.

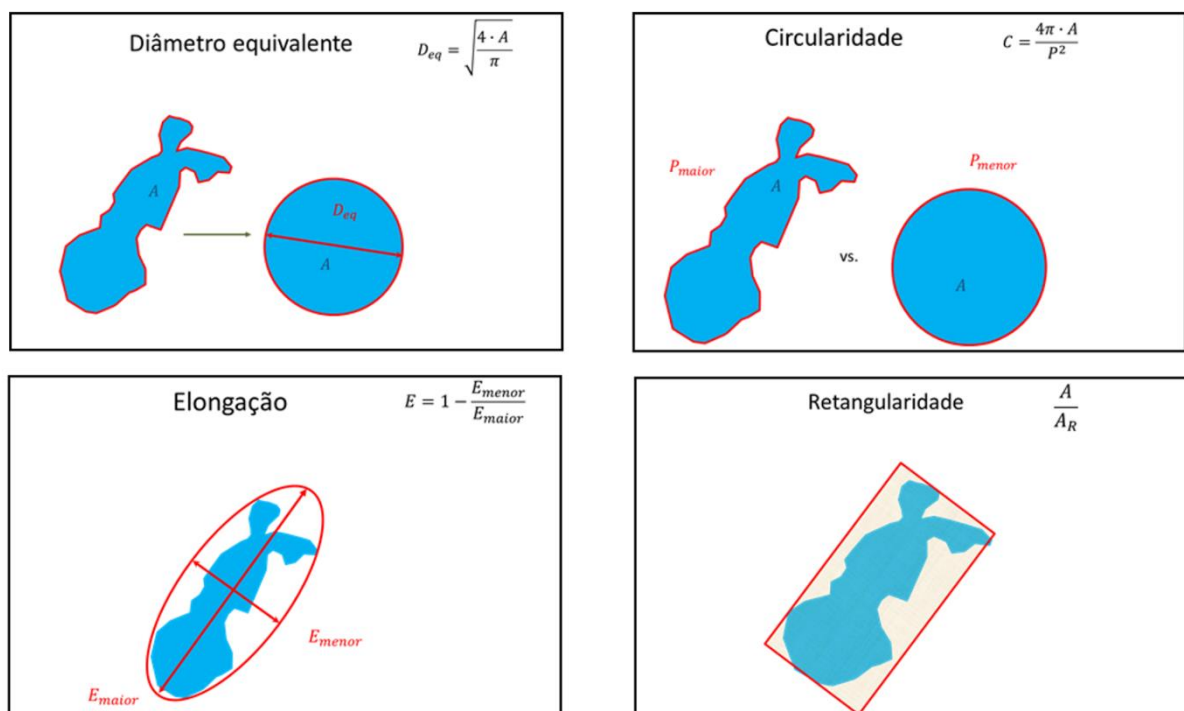


Fonte: Elaborada pelo autor.

O primeiro modelo criado com base no subconjunto do *dataset* original foi baseado em atributos geométricos. Foram extraídos os seguintes atributos: área, perímetro, comprimento e largura do retângulo de seleção, comprimento dos eixos principal e secundário da melhor elipse ajustável, e o ângulo entre este eixo principal

uma linha paralela ao eixo x da imagem. Com estes atributos, são calculados outros quatro atributos adimensionais: diâmetro equivalente, circularidade, alongação e retangularidade. A Figura 38 apresenta uma representação gráfica definindo estes atributos adimensionais, além das expressões utilizadas para o cálculo.

Figura 38. Representação gráfica dos atributos adimensionais e as expressões utilizadas para os cálculos, onde A = área; P = perímetro; E_{maior} = comprimento do eixo principal da melhor elipse ajustável; E_{menor} = comprimento do eixo secundário da melhor elipse ajustável; e A_R = área do menor retângulo ajustável.




Fonte: Elaborada pelo autor.

Os quatro atributos adimensionais são utilizados para treinar um modelo preditivo que utiliza rede neural artificial, especificamente *multilayer perceptron*, para classificar tipos de porosidade. O dado separado para validação permite o acompanhamento da evolução de acurácia e perdas durante o treinamento, o que permitiu definir os seguintes parâmetros para o modelo: 3 camadas escondidas com 100 neurônios cada, 5000 épocas, e taxa de aprendizado igual a 0,001.

Já o modelo baseado em redes neurais convolucionais utiliza todo o *dataset* original e amplia o potencial dos dados de treinamento através da utilização de *data augmentation*, especificamente, as transformações geométricas, detalhadas no

modelo de classificação de litofácies. A arquitetura utilizada também é similar a arquitetura utilizada no modelo de classificação de litofácies, com pequenos ajustes para adequá-la à imagem de entrada binária e menor (Figura 39).

Figura 39. Arquitetura de rede neural convolucional utilizada para o modelo de classificação de tipos de porosidade.



Fonte: Elaborada pelo autor.

A Tabela 04 apresenta uma consolidação das características e parâmetros dos diferentes tipos de modelos treinados. Para os modelos de classificação de litofácies, os códigos utilizados foram disponibilizados e podem ser consultados através da plataforma GitHub: <<https://github.com/rafaelrubo/lithofaciesclassification>>.

Tabela 04. Consolidação das características e parâmetros utilizados para todos os modelos treinados neste trabalho. (*) Foram utilizados 14 fotomosaicos para correlação entre os resultados do modelo e a microanálise química; (**) foram identificados 4 objetos através de análise petrográfica clássica em um fotomosaico que não foi utilizado para treinamento do modelo

Modelo	Algoritmo de aprendizado de máquina utilizado	Convoluções	Augmentations	Arquitetura	Épocas	Taxa de aprendizado	Número de árvores	Tipo de instância	Número de instâncias rotuladas utilizadas por época no treinamento	Número total de instâncias rotuladas utilizadas para treinamento	Avaliação utilizada	Número total de instâncias rotuladas utilizadas para teste
Segmentação mineralógica - dataset 1	Random Forest	Filtros discretos: desfoque gaussiano, sobel, hessiana, diferença de gaussianas, projeções de membrana	-	-	-	-	200	pixels	310.549	310.549	Validação cruzada e out-of-bag error	-
Segmentação mineralógica - dataset 1	Redes Neurais Artificiais	Filtros discretos: desfoque gaussiano, sobel, hessiana, diferença de gaussianas, projeções de membrana	-	Multilayer perceptron : 3 camadas escondidas com 45 neurônios cada, função de ativação logística, algoritmo de aprendizado gradiente descendente backpropagation	500	0,3	-	pixels	310.549	310.549	Validação cruzada	-
Segmentação porosidade - dataset 2	Random Forest	Filtros discretos: desfoque gaussiano, sobel, hessiana, diferença de gaussianas, projeções de membrana	-	-	-	-	200	pixels	640.965	640.965	Validação cruzada e out-of-bag error	-
Segmentação porosidade - dataset 2	Redes Neurais Artificiais	Filtros discretos: desfoque gaussiano, sobel, hessiana, diferença de gaussianas, projeções de membrana	-	Multilayer perceptron : 3 camadas escondidas com 45 neurônios cada, função de ativação logística, algoritmo de aprendizado gradiente descendente backpropagation	500	0,3	-	pixels	640.965	640.965	Validação cruzada	-
Segmentação mineralógica - dataset 3	Random Forest	Filtros discretos: desfoque gaussiano, sobel, hessiana, diferença de gaussianas, projeções de membrana	-	-	-	-	200	pixels	479.380	479.380	Validação cruzada, out-of-bag error e correlação com outros métodos analíticos	14*
Deteção de fragmentos fosfáticos	Random Forest	Filtros discretos: desfoque gaussiano, sobel, hessiana, diferença de gaussianas, projeções de membrana	-	-	-	-	200	pixels, selecionados em grupos	675.798	675.798	Validação cruzada, out-of-bag error e correlação com outros métodos analíticos	4**

Fonte: Elaborada pelo autor. Continua na próxima página.

Tabela 04. Continuação.

Modelo	Algoritmo de aprendizado de máquina utilizado	Convoluções	Augmentations	Arquitetura	Épocas	Taxa de aprendizado	Número de árvores	Tipo de instância	Número de instâncias rotuladas utilizadas por época no treinamento	Número total de instâncias rotuladas utilizadas para treinamento	Avaliação utilizada	Número total de instâncias rotuladas utilizadas para teste
Classificação de litofácies - Modelo 1	Redes Neurais Convolucionais	3 camadas convolucionais	-	Camadas: convolucional-subamostragem, convolucional-subamostragem, convolucional-subamostragem, achatamento, densa, densa, classificação. Função de ativação: ReLu, última camada: <i>softmax</i> .	50	0,0001	-	imagens de 256 x 256 pixels	642	642	Dados de teste	161
Classificação de litofácies - Modelo 2	Redes Neurais Convolucionais	3 camadas convolucionais	Non-local means	Camadas: convolucional-subamostragem, convolucional-subamostragem, convolucional-subamostragem, achatamento, densa, densa, classificação. Função de ativação: ReLu, última camada: <i>softmax</i> .	50	0,0001	-	imagens de 256 x 256 pixels	642	642	Dados de teste	161
Classificação de litofácies - Modelo 3	Redes Neurais Convolucionais	3 camadas convolucionais	Non-local means, transformações espectrais	Camadas: convolucional-subamostragem, convolucional-subamostragem, convolucional-subamostragem, achatamento, densa, densa, classificação. Função de ativação: ReLu, última camada: <i>softmax</i> .	50	0,0001	-	imagens de 256 x 256 pixels	6.420	6.420	Dados de teste	161
Classificação de litofácies - Modelo 4	Redes Neurais Convolucionais	3 camadas convolucionais	Non-local means, transformações geométricas	Camadas: convolucional-subamostragem, convolucional-subamostragem, convolucional-subamostragem, achatamento, densa, densa, classificação. Função de ativação: ReLu, última camada: <i>softmax</i> .	250	0,0001	-	imagens de 256 x 256 pixels	642	160.500	Dados de teste	161
Classificação de litofácies - Modelo 5	Redes Neurais Convolucionais	3 camadas convolucionais	Non-local means, transformações espectrais, transformações geométricas	Camadas: convolucional-subamostragem, convolucional-subamostragem, convolucional-subamostragem, achatamento, densa, densa, classificação. Função de ativação: ReLu, última camada: <i>softmax</i> .	250	0,001	-	imagens de 256 x 256 pixels	6.420	1.605.000	Dados de teste	161
Classificação de litofácies - Modelo 6	Redes Neurais Convolucionais	3 camadas convolucionais	Non-local means, transformações espectrais, transformações geométricas, imagens sintéticas	Camadas: convolucional-subamostragem, convolucional-subamostragem, convolucional-subamostragem, achatamento, densa, densa, classificação. Função de ativação: ReLu, última camada: <i>softmax</i> .	300	0,001	-	imagens de 256 x 256 pixels	11.060	3.318.000	Dados de teste	161
Classificação do tipo de porosidade baseado em atributos geométricos	Redes Neurais Artificiais	-	-	<i>Multilayer perceptron</i> : 3 camadas escondidas com 100 neurônios cada, função de ativação logística, algoritmo de aprendizado gradiente descendente <i>backpropagation</i>	5.000	0,001	-	conjunto de 4 atributos geométricos adimensionais extraídos de poros segmentados	45	45	Dados de teste	5
Classificação do tipo de porosidade baseado em Redes Neurais Convolucionais	Redes Neurais Convolucionais	3 camadas convolucionais	Transformações geométricas	Camadas: convolucional-subamostragem, convolucional-subamostragem, convolucional-subamostragem, achatamento, densa, densa, classificação. Função de ativação: ReLu, última camada: <i>softmax</i> .	600	0,001	-	imagens binárias de 200 x 200 pixels	414	248.400	Dados de teste	46

Fonte: Elaborada pelo autor.

3.4. Subjetividade interpretativa relacionada aos Petrógrafos

Na hipótese desta Tese, há a previsão de que os modelos de aprendizado de máquina geram resultados quantitativos mais confiáveis, padronizados e rápidos do que a descrição tradicional. Para comparar os resultados dos modelos com a interpretação dos petrógrafos, foram realizadas 20 entrevistas com petrógrafos que trabalham com rochas de contextos similares aos utilizados neste trabalho, todos com mais de 10 anos de experiência. Estas entrevistas foram padronizadas, compostas sempre por 12 perguntas que foram respondidas de forma síncrona através de um formulário online (Anexo C). Todas as questões envolvem uma estimativa ou interpretação de uma imagem de lâmina petrográfica delgada, com nicóis descruzados. Elas podem ser divididas da seguinte forma:

Questão 01: estimativa da porosidade de uma rocha a partir de um fotomosaico de uma lâmina e de uma segmentação binária entre poro e não-poro.

Questões de 02 a 05: classificação de imagens em uma das seis litofácies de saída dos modelos de classificação treinados com *data augmentation*. Uma imagem por questão. As quatro imagens correspondentes a estas questões fazem parte do conjunto de testes do modelo de classificação de litofácies e foram classificadas pelo melhor modelo de forma diferente de seu rótulo original.

Questão 06: A partir do fotomosaico de uma lâmina e considerando que uma microanálise química (obtida por QEMSCAN) identificou 4 classes predominantes, é solicitada uma estimativa do percentual de ocorrência para cada uma das classes com base exclusivamente na imagem de microscopia óptica com nicóis descruzados.

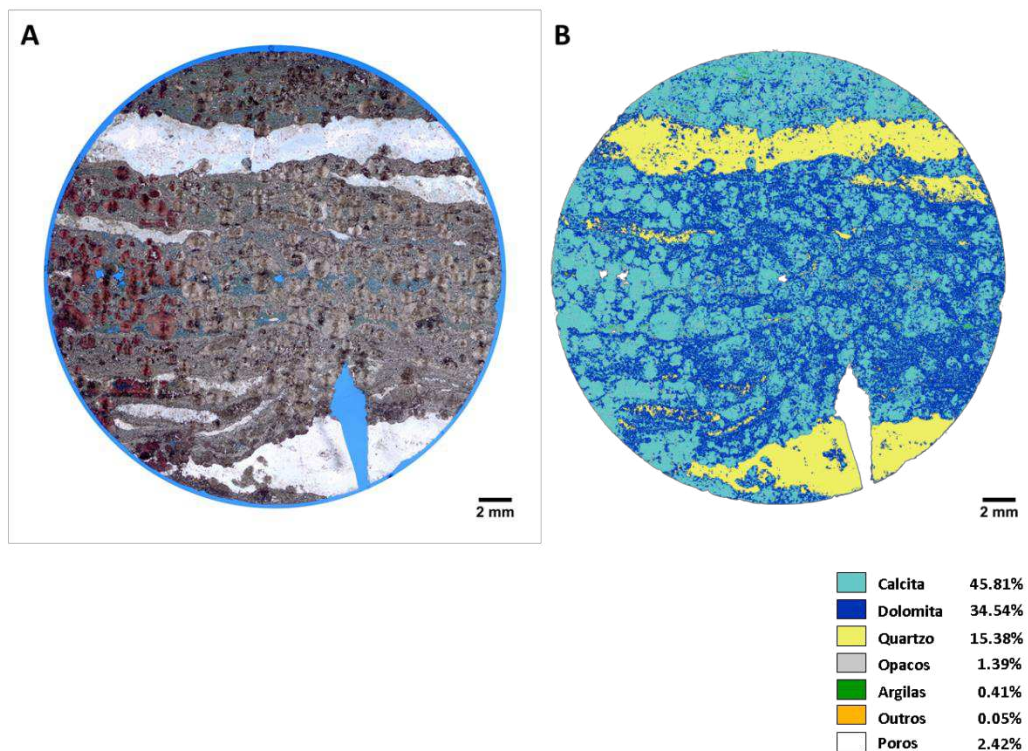
Questão 07 a 12: Dadas 5 imagens representativas de uma litofácies (uma para cada questão), solicita-se ao entrevistado que identifique qual das imagens é sintética. As imagens reais tiveram suas resoluções reduzidas para a mesma resolução da imagem sintética. A escala das imagens reais também foi omitida, uma vez que as imagens sintéticas são geradas sem uma escala definida.

4. RESULTADOS

4.1. Modelos de Segmentação


Todos os resultados relacionados aos modelos de segmentação foram publicados em um artigo no periódico *Journal of Petroleum Science and Engineering* (Anexo A; RUBO et al., 2019). Os *datasets* de treinamento criados a partir dos fotomosaicos obtidos do primeiro conjunto de lâminas petrográficas originaram quatro modelos de segmentação de imagens: dois modelos mineralógicos e dois modelos de porosidade. Os dois modelos mineralógicos foram treinados com o *dataset 1*, enquanto que os dois modelos de porosidade utilizaram o *dataset 2*. O que muda é o algoritmo de aprendizado de máquina utilizado para classificar os *pixels*. A Figura 40 mostra o resultado da aplicação do modelo mineralógico baseado em *random forest* em um dos fotomosaicos de lâminas petrográficas. A Figura 41 destaca o resultado do modelo de porosidade baseado em redes neurais artificiais aplicado ao fotomosaico de uma lâmina petrográfica diferente.

Figura 40. A) Fotomosaico de uma lâmina petrográfica, parcialmente tingida por um composto de alizarina; B) Sua imagem segmentada obtida a partir do modelo mineralógico. A segmentação permite a extração da ocorrência de cada fase mineral na lâmina petrográfica.



Fonte: Elaborada pelo autor.

Figura 41. A) Fotomosaico de uma lâmina petrográfica, parcialmente tingida por um composto de alizarina; B) Sua imagem segmentada obtida a partir do modelo de porosidade. Os poros segmentados estão sobrepondo a imagem original, que está em escala de cinze e clareada.



Fonte: Elaborada pelo autor.


O modelo mineralógico que utiliza redes neurais artificiais apresentou 97,46% de instâncias classificadas corretamente o teste de validação cruzada *10-fold*. Considerando que o *dataset* de treinamento é quase duas vezes maior para os modelos de porosidade em relação aos modelos mineralógicos, e que apresentam somente duas classes de saída, o modelo de porosidade baseado em redes neurais apresentou resultados ainda melhores, conforme esperado: 99,97% de instâncias corretamente classificadas.

Os resultados dos modelos que utilizam classificadores *random forest* apresentaram acurácias igual ou maior do que os modelos que utilizam redes neurais artificiais. O modelo mineralógico que utiliza *random forest* apresentou 98,78% de instâncias classificadas corretamente, com um erro *out-of-bag* de 1,17%. O modelo de porosidade utilizando *random forest* apresentou 99,97% de instâncias classificadas corretamente, igual ao modelo que utiliza redes neurais artificiais. O erro *out-of-bag* para o modelo de porosidade é 0,03%.

Uma análise de sensibilidade foi conduzida utilizando o *dataset* 1 para determinar o número de árvores a serem utilizadas nos modelos que utilizam *random*

forest. Um total de 17 modelos testes, com o número de árvores variando de 1 a 300, mostrou que acurácias e erros estabilizam próximos a 140 árvores (Figura 42). Considerando a natureza investigativa destes modelos, a acurácia foi calculada com base em uma separação simples 80% treino / 20% teste, ao invés de utilizar validação cruzada *10-fold*. Esta análise está em concordância com uma realizada por Hastie Tibshirani; Friedman et al. (2009), que utiliza um *dataset* com características similares. Os modelos finais que utilizam *random forest* foram ajustados para 200 árvores.

Figura 42. Acurácias e erros *out-of-bag* calculados para modelos treinados com diferentes números de árvores, criados com o *dataset* 1 (mineralogia sem validação química).



Fonte: Elaborada pelo autor.

O segundo conjunto de lâminas petrográficas também apresenta medidas de microanálise química, obtidas pelo equipamento QEMSCAN. Fotomosaicos provenientes deste conjunto de lâminas foram utilizados para criar um novo *dataset* (*dataset* 3): dados de treino foram selecionados somente de regiões onde poderiam ser validados por medidas químicas. Um modelo mineralógico foi treinado utilizando este *dataset*. Ele utilizou os mesmos parâmetros do melhor modelo obtido a partir do *dataset* criado com o primeiro conjunto de lâminas petrográficas: algoritmo *random forest* com 200 árvores. O modelo apresentou 90,13% de instâncias classificadas corretamente durante o teste de validação cruzada *10-fold*. O erro *out-of-bag* para este modelo foi 9,71%. A Tabela 05 sumariza os resultados dos cinco modelos criados.

Tabela 05. Resultados dos testes de validação cruzada *10-fold* e erros *out-of-bag* (quando aplicável) para todos os modelos de segmentação criados.

Modelos	Algoritmos	Instâncias corretamente classificadas (teste de validação cruzada <i>10-fold</i>)	Erro <i>out-of-bag</i>
1 Modelo mineralógico (dataset 1)	Redes Neurais Artificiais	97,46%	-
2 Modelo mineralógico (dataset 1)	Random Forest	98,78%	1,17%
3 Modelo porosidade (dataset 2)	Redes Neurais Artificiais	99,97%	-
4 Modelo porosidade (dataset 2)	Random Forest	99,97%	0,03%
5 Modelo mineralógico (dataset 3)	Random Forest	90,13%	9,71%

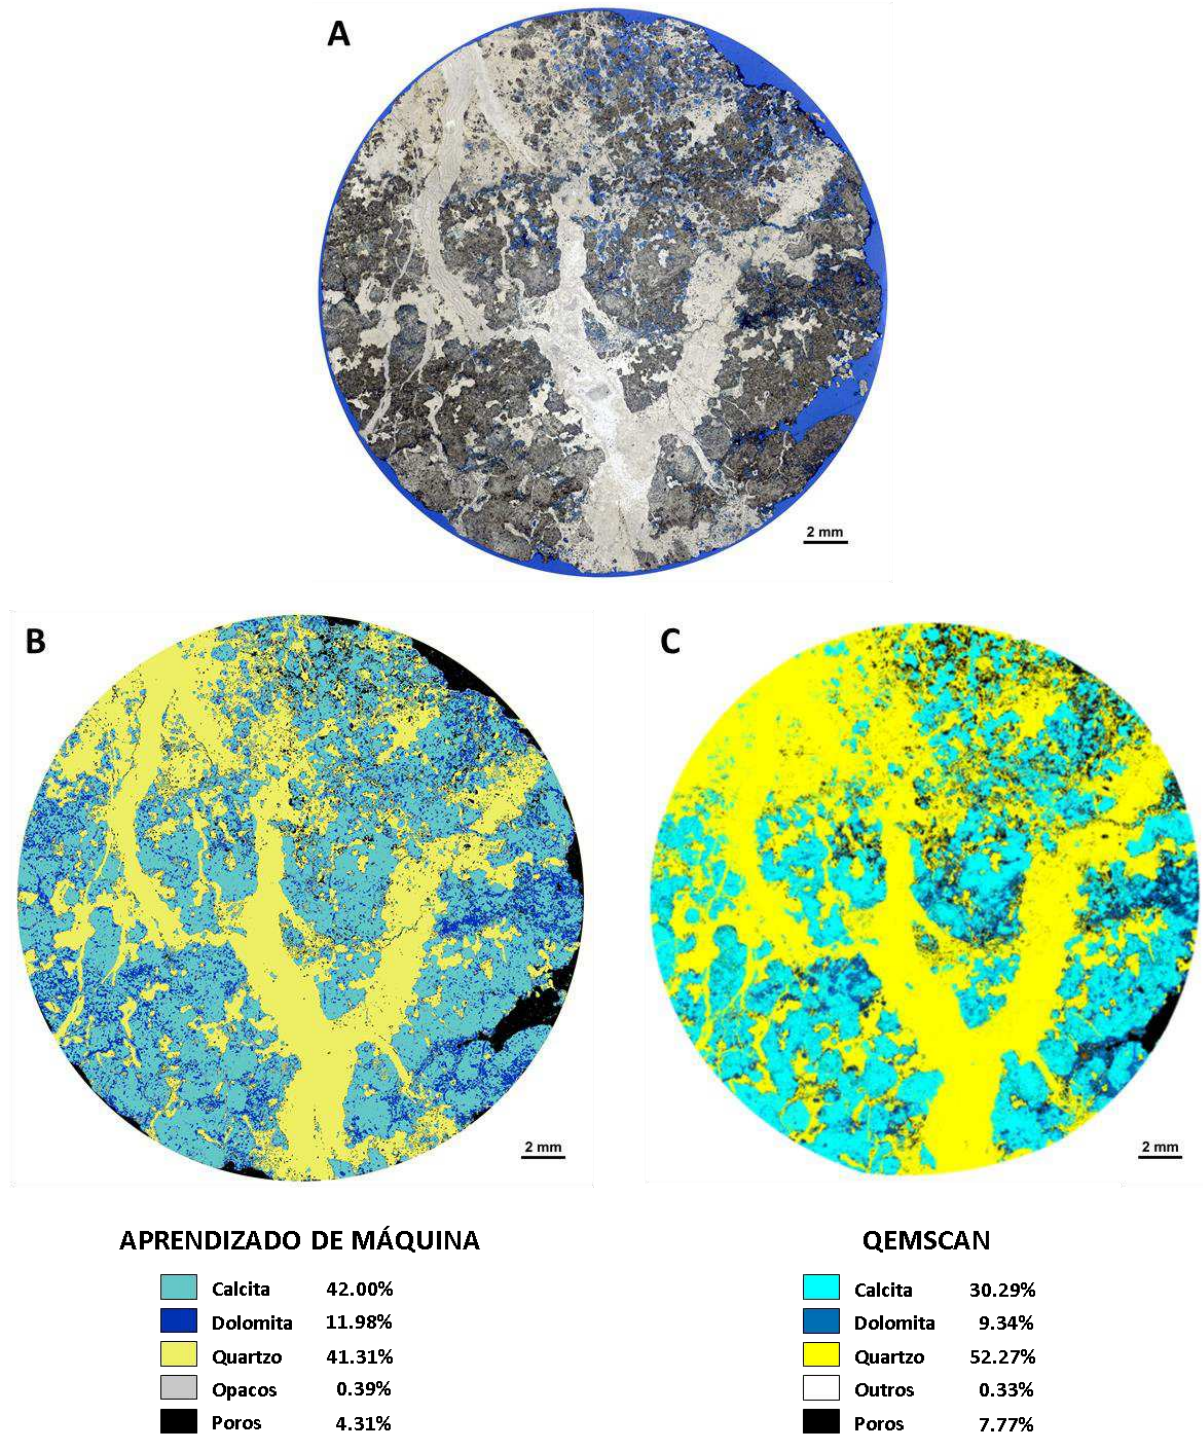
Fonte: Elaborada pelo autor.

A Figura 43 mostra o fotomosaico de uma lâmina petrográfica do segundo conjunto, sua imagem segmentada obtida a partir do modelo mineralógico criado com o *dataset 3*, e sua composição mineralógica interpretada a partir de medidas do QEMSCAN. Embora as imagens dos dois métodos sejam visualmente similares, há diferenças significativas entre os resultados de ocorrências relativas dos minerais.

As matrizes de confusão para os dados de validação dos modelos mineralógicos criados a partir dos *datasets 1* e *3* (Figuras 44 e 45), ambas utilizando *random forest*, mostram que a maioria dos dados classificados incorretamente são originalmente rotulados na classe outros, que agrupa minerais incomuns para as rochas estudadas, tais como ocorrências de dawsonita e apatita. Esta dificuldade é esperada, considerando o aspecto incomum destas fases minerais no arcabouço da rocha. Eles geralmente ocorrem com características petrográficas similares a de minerais mais comuns.

Embora os testes de validação cruzada indiquem de forma acurada quão bem os modelos generalizam, testar os modelos criados utilizando dados novos é essencial para a garantia de sua utilidade. Ao invés de simplesmente selecionar novas instâncias para criar um conjunto de teste, os modelos mineralógicos que utilizam *random forest* treinados com os *datasets 1* e *3* foram aplicados, respectivamente, em 7 e 9 fotomosaicos de lâminas petrográficas. Para as amostras laterais utilizadas na confecção destas lâminas, foram medidas as densidades de sólidos em laboratório.


Figura 43. A) Fotomosaico de uma lâmina petrográfica; B) Sua imagem segmentada obtida do modelo mineralógico validado por microanálises químicas do equipamento QEMSCAN – o modelo não detectou ocorrências da classe argilas ou outros para este fotomosaico; C) Composição mineralógica da lâmina petrográfica criada pela interpretação de medidas do QEMSCAN. Ocorrências relativas para as fases minerais são apresentadas para cada método.



Fonte: Elaborada pelo autor.

Figura 44. Matriz de confusão do modelo mineralógico treinado com o primeiro conjunto de lâminas, utilizando *random forest*.

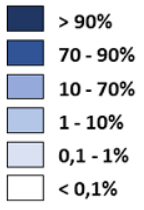
preditos como-->	Poros	Calcita	Dolomita	Quartzo	Argilas	Opacos	Outros	Acurácia
Poros	38.537	5	15	9	1	0	0	99,92%
Calcita	0	133.142	336	19	0	2	0	99,73%
Dolomita	0	1.850	63.514	344	1	0	9	96,65%
Quartzo	4	5	676	62.609	0	0	0	98,92%
Argilas	0	8	6	0	3.610	0	0	99,61%
Opacos	0	1	0	0	1	2.407	0	99,92%
Outros	0	18	286	81	0	1	3.052	88,77%



Fonte: Elaborada pelo autor.

Figura 45. Matriz de confusão do modelo mineralógico treinado com o segundo conjunto de lâminas, utilizando *random forest*.

preditos como-->	Poros	Calcita	Dolomita	Quartzo	Argilas	Opacos	Outros	Acurácia
Poros	57.479	64	121	170	1	0	2	99,38%
Calcita	56	113.564	6.654	2.141	19	13	19	92,73%
Dolomita	46	9.161	54.558	10.279	134	83	63	73,41%
Quartzo	31	2.472	2.134	181.746	1	0	30	97,50%
Argilas	0	470	246	1	9.435	60	0	92,39%
Opacos	8	57	31	0	12	11.064	0	99,03%
Outros	58	3.801	2.784	6.054	6	0	4.235	25,00%




Fonte: Elaborada pelo autor.

Com as ocorrências relativas de cada fase mineral obtidas das imagens segmentadas, foi possível estimar um valor de densidade de sólidos correspondente para cada lâmina petrográfica. A comparação dos dados provenientes destas duas técnicas diferentes permite avaliar a capacidade dos modelos em generalizar, conforme mostrado na Figura 46. O coeficiente de determinação (R^2) para esta correlação é baixo, somente 0,14. Isso pode ser explicado pela baixa variabilidade das densidades medidas em laboratório. Os dados parecem espalhados, pois não há amostras com medidas de densidade abaixo de $2,68 \text{ g/cm}^3$ ou acima de $2,8 \text{ g/cm}^3$, um intervalo de variabilidade bastante restrito. Ainda assim, o RMSE é $0,031 \text{ g/cm}^3$, que é muito baixo. Considerando estes valores, os modelos parecem ser capazes de prever densidades de sólidos muito bem, um atributo obtido a partir das ocorrências relativas. Entretanto, não existe dado suficiente para garantir que os modelos iriam realizar boas previsões para amostras com valores de densidade de sólidos muito mais baixos ou muito mais altos do que os das 16 amostras avaliadas. Também devem ser consideradas as heterogeneidades que as amostras de rocha podem apresentar quando comparadas com lâminas petrográficas, especialmente para rochas carbonáticas. Enquanto as amostras laterais permitem medidas laboratoriais de uma

rocha em três dimensões, os resultados dos modelos fornecem estimativas com base no fotomosaico de lâminas petrográficas de 35 µm de espessura.

Figura 46. Correlação entre valores de densidade dos sólidos obtidas a partir das imagens segmentadas pelos modelos mineralógicos e a partir das amostras de rocha originais. A linha preta representa uma correlação 1:1.




Fonte: Elaborada pelo autor.

O modelo mineralógico baseado no *dataset 3* permite uma avaliação mais detalhada, considerando que as lâminas petrográficas tiveram suas composições químicas medidas pelo equipamento QEMSCAN. A microanálise química é realizada diretamente sobre a lâmina petrográfica delgada, a cada 10 µm, cobrindo a mesma área que o modelo está avaliando. A correlação entre as ocorrências relativas de cada fase mineral obtidas através das duas técnicas mostra o quão bem o modelo está predizendo cada classe (Figura 47). Considerando todas as ocorrências como uma série única, o R^2 total é 0,82 e o RMSE é 8,99%. Baixos valores de RMSE são mantidos quando cada classe é avaliada de forma independente. Entretanto, os valores de R^2 são baixos, com exceção da classe quartzo (Tabela 06). Isso ocorre pela mesma razão que o R^2 da correlação entre valores de densidade de sólidos é baixo: a variabilidade das ocorrências relativas para cada classe é baixa, considerando as lâminas petrográficas avaliadas. Considerando que a silicificação é

bastante heterogênea através da amostra, ocorrências relativas de quartzo variam de 3,63% e 58,86%, um intervalo amplo, o que viabiliza a obtenção de um R^2 elevado. O modelo faz boas previsões de ocorrências relativas, apresentando baixos valores de RMSE. Não há dados suficientes para garantir que ele iria prever bem as ocorrências de todas as classes se fosse aplicado em fotomosaicos de lâminas petrográficas com variabilidades muito diferentes das observadas nas lâminas avaliadas. Embora, o alto valor de R^2 para quartzo indica que o modelo provavelmente iria prever bem considerando valores de ocorrências diferentes para as demais classes.

Figura 47. Correlação entre ocorrências relativas de fases minerais obtidas por microanálise química e pelo modelo mineralógico treinado com o *dataset 3*, para os 14 fotomosaicos de lâminas petrográficas do segundo conjunto. Valores de R^2 e RMSE foram calculados considerando todos os dados como uma classe única.



Fonte: Elaborada pelo autor.

Tabela 06. Valores de RMSE e R^2 para cada classe e seus valores totais, considerando todos os dados como uma série única.

	Calcita	Dolomita	Quartzo	Outros	Poros	TOTAL
RMSE (%)	12,30	11,57	9,37	2,14	5,14	8,99
R^2	0,325	0,296	0,903	0,006	0,159	0,820

Fonte: Elaborada pelo autor.

4.2. Modelos de Detecção de Objetos

Apesar dos resultados validados provenientes dos modelos de segmentação mineralógica e de porosidade, algumas estruturas apresentaram classificação complicada, pois suas propriedades ópticas são mais diversificadas, o que pode ocasionar em confusão com outras classes. Além disso, busca-se identificar e destacar um objeto que é composto de vários *pixels*. Cada *pixel* poderia ser classificado em uma classe diferente em um modelo de segmentação. Neste caso, o interesse é em um elemento que pode ser formado por mais de uma classe proposta por um modelo de segmentação. O interesse passa a ser a textura observada no interior das fronteiras deste elemento. Isto ocorre, por exemplo, com fragmentos fosfáticos. Nos modelos de segmentação mineralógicos, eles foram treinados para serem classificados como “outros”, entretanto, por vezes foram classificados como “calcita” e “dolomita”. Nos modelos de porosidade, podem ser erroneamente classificados como “poro” quando ocorrem com coloração mais azul-esverdeada.

Em casos como este, a classificação *pixel a pixel* não é suficiente para identificar a feição de interesse. Apesar da utilização dos filtros convolucionais, uma etapa de aplicação do filtro de ruídos NLM precede a obtenção dos atributos adicionais. Esta etapa é utilizada em segmentações orientadas a objeto e busca remover texturas de menor relevância para identificar área homogêneas no contexto dos elementos de interesse.


Para complementar os modelos de segmentação, foi criado um modelo em que a feição de interesse deixa de ser o *pixel* e passa a ser um objeto, o fragmento fosfático. A etapa em que é realizada uma segmentação binária da imagem apresentou 97,16% de instâncias corretamente classificadas em um teste de validação cruzada *10-fold*. Entretanto, este valor é representativo somente da etapa de segmentação, e não do modelo final, que apresenta uma etapa subsequente envolvendo uma sequência de operadores morfológicos.

Para avaliar o modelo final, foi necessário a realização de um teste em imagem que não foi utilizada para o treinamento. Foi realizada a análise de uma lâmina petrográfica em microscópio óptico cujo fotomosaico correspondente não foi utilizado para o treinamento. Durante o período de uma hora, foram identificados quatro fragmentos fosfáticos – elementos 1, 2, 3 e 4 da Figura 48. Ao aplicar o modelo de detecção de fragmentos fosfáticos treinado, os mesmos quatro elementos foram

identificados e dois novos fragmentos fosfáticos menores que não haviam sido observados foram destacados – elementos 5 e 6 da Figura 48. A ocorrência destes novos elementos identificados pelo modelo foi confirmada em análise petrográfica posterior à sua aplicação.

O tempo de processamento para aplicação do modelo na imagem de fotomosaico foi de aproximadamente 10 minutos. Entretanto, este custo computacional pode apresentar uma redução significativa associada ao tempo de processamento com a utilização de processamento em paralelo assistido por GPU. De qualquer forma, mesmo nos casos em que esta alternativa não possa ser explorada, o tempo de processamento é baixo quando comparado ao tempo requerido para análise petrográfica convencional. Além de permitir a utilização da mão de obra especializada em outra atividade.

Figura 48. Modelo aplicado à imagem de fotomosaico não utilizada no treinamento. Fragmentos fosfáticos não identificados originalmente pela análise petrográfica convencional foram detectados e confirmados – elementos 5 e 6. As setas amarelas na imagem de fotomosaico foram adicionadas posteriormente, para destacar a posição espacial dos objetos detectados. A saída do modelo é composta pela imagem original sobreposta por caixas de seleção criadas com base no perímetro de cada elemento.



Fonte: Elaborada pelo autor.


4.3. Modelos de Classificação

4.3.1. Classificação de litofácies

Todos os resultados relacionados aos modelos de classificação de litofácies foram submetidos em formato de manuscrito para o periódico *Earth Science Informatics* e encontra-se em processo de revisão (Anexo B). Seis modelos de classificação de litofácies foram treinados, após diferentes estágios de técnicas de *augmentation* de dados aplicadas ao *dataset* de treinamento. Eles foram treinados e numerados de acordo com as seguintes características do *dataset*: Modelo 1 – *dataset* original; Modelo 2 – filtragem NLM; Modelo 3 – filtragem NLM seguida somente por *augmentation* espectral; Modelo 4 – filtragem NLM seguida somente por *augmentation* geométrico; Modelo 5 – filtragem NLM seguida por *augmentation* espectral e geométrico; Modelo 6 – filtragem NLM aplicada no *dataset* original de treinamento ampliado com imagens sintéticas seguido de *augmentation* espectral e geométrica. Todos utilizam a mesma arquitetura de rede neural convolucional.


Acurácia de todos os modelos baseadas em dados de validação (Figura 49) e teste (Figura 50) foram plotados de tal forma que a evolução após a aplicação das diferentes técnicas de transformações fosse destacada. Com exceção do modelo treinado com imagens que foram filtradas com NLM e que passaram somente por *augmentation* espectrais, há uma tendência de aumento geral na acurácia conforme os diferentes conjuntos de transformações são aplicadas e acrescentadas ao *dataset* de treinamento. Ao utilizar somente o *dataset* original para treinar o modelo, o resultado de acurácia para o dado de teste é muito baixo: 42,24%. Quando todas as transformações são implementadas, os dados de teste mostram um resultado de 86,34% de acurácia. Estes valores estão avaliando a capacidade de generalização dos modelos, considerando que as imagens do *dataset* de teste foram obtidas de poços adjacentes e nunca integralizaram o treinamento dos modelos.

Figura 49. Evolução da acurácia para dados de validação, conforme as transformações são aplicadas no *dataset* de treinamento.



Fonte: Elaborada pelo autor.

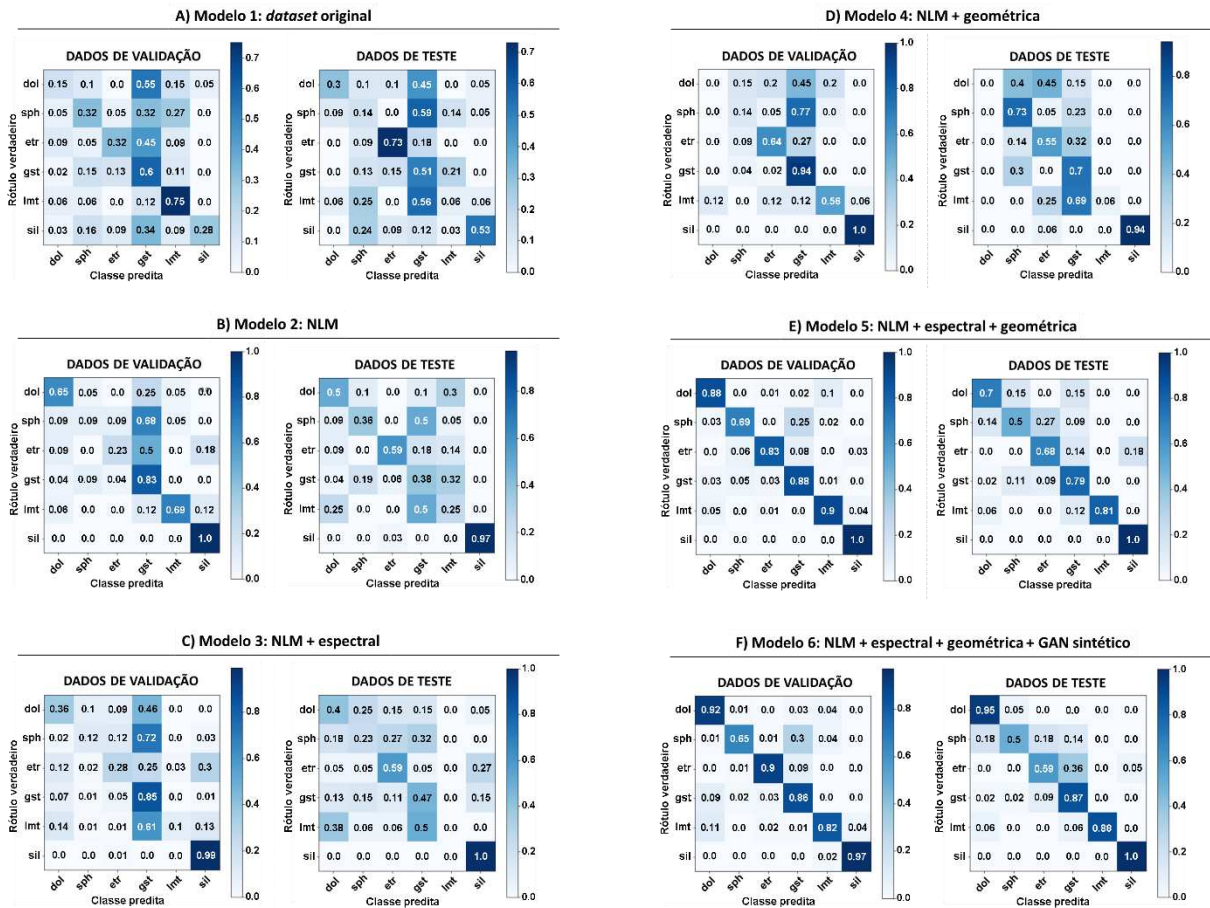
Figura 50. Evolução da acurácia para dados de teste, conforme as transformações são aplicadas no *dataset* de treinamento.



Fonte: Elaborada pelo autor.

As acurácias dos modelos permitem compará-los. Mas, apesar de se tratar de uma métrica importante, um único valor de acurácia para cada modelo não é suficiente para caracterizá-los de uma forma mais detalhada. Para avaliar quais classes estão de fato sendo classificadas de forma mais eficiente, matrizes de confusão normalizadas foram plotadas para os dados de validação e teste de todos os modelos treinados. Conforme as transformações são aplicadas, é possível observar as predições tendendo para a diagonal principal. Os modelos começam classificando mal todas as classes (Figura 51A). Mesmo para os dados de validação, as predições estão longe de convergirem para o rótulo verdadeiro. Após aplicar NLM (Figura 51B) e NLM seguido por *augmentation* espectrais (Figura 51C), a classe silexito torna-se resolvida, as acurácias chegam a atingir 97% para esta classe. A aplicação de NLM seguido somente por *augmentation* geométricos não melhora muito em relação aos modelos anteriores: apesar das previsões dos dados de validação se aproximarem da diagonal principal, predições no dado de teste ainda são espalhadas, exceto para silexito (Figura 51D). A acurácia total do modelo onde NLM, *augmentation* espectrais e geométricos são aplicados sobem para 87,55% para o dado de validação e 73,29% para o dado de teste. Estas acurácias mais elevadas são refletidas nas matrizes de confusão (Figura 51E). O modelo treinado com todas as técnicas de *augmentation* e imagens sintéticas apresenta predições convergindo para a diagonal principal, tanto para os dados de validação quanto de teste. As classes que apresentam maior dificuldade em serem corretamente classificadas são esferulitos e estromatólitos (Figura 51F).


Figura 51. Matrizes de confusão normalizadas para dados de validação e teste, todas obtidas a partir do: A) *dataset* original – Modelo 1; B) modelo treinado com base na filtragem por NLM – Modelo 2; C) modelo treinado com base em filtragem por NLM e técnicas de *augmentation* espectrais. D) modelo treinado com base em filtragem por NLM e técnicas de *augmentation* geométricas – Modelo 4; E) modelo treinado com base em filtragem por NLM, técnicas de *augmentation* espectrais e geométricas – Modelo 5; F) modelo treinado com base em *dataset* expandido por imagens sintéticas, seguido por filtragem por NLM, técnicas de *augmentation* espectrais e geométricas – Modelo 6. As categorias são abreviadas nesta figura conforme a seguir: dol – dolomito; sph – esferulítico; etr – estromatólito; gst – grainstone; lmt – laminito; sil – silexito.



Fonte: Elaborada pelo autor.


Uma forma diferente de avaliar como as classes estão tendo suas classificações melhoradas é desdobrando a evolução da acurácia para cada categoria conforme as transformações são acrescentadas aos diferentes modelos. Ao fazer isso para os dados de validação (Figura 52) e teste (Figura 53), são destacadas as classes com contribuições mais altas e mais baixas à acurácia geral dos modelos. Os dados de teste indicam que o melhor modelo faz previsões melhores para as classes silexito e dolomito, enquanto as classes laminito e grainstone apresentam acurácias próximas à acurácia geral do modelo, e classes estromatólitos e esferulítico puxam a acurácia geral para baixo, devido à baixa performance. Ressalta-se que a forma como as categorias contribuem para a acurácia total dos modelos varia de acordo com as transformações utilizadas.

Figura 52. Evolução da acurácia no dado de validação para cada categoria em relação à acurácia total.



Fonte: Elaborada pelo autor.

Figura 53. Evolução da acurácia no dado de teste para cada categoria em relação à acurácia total.

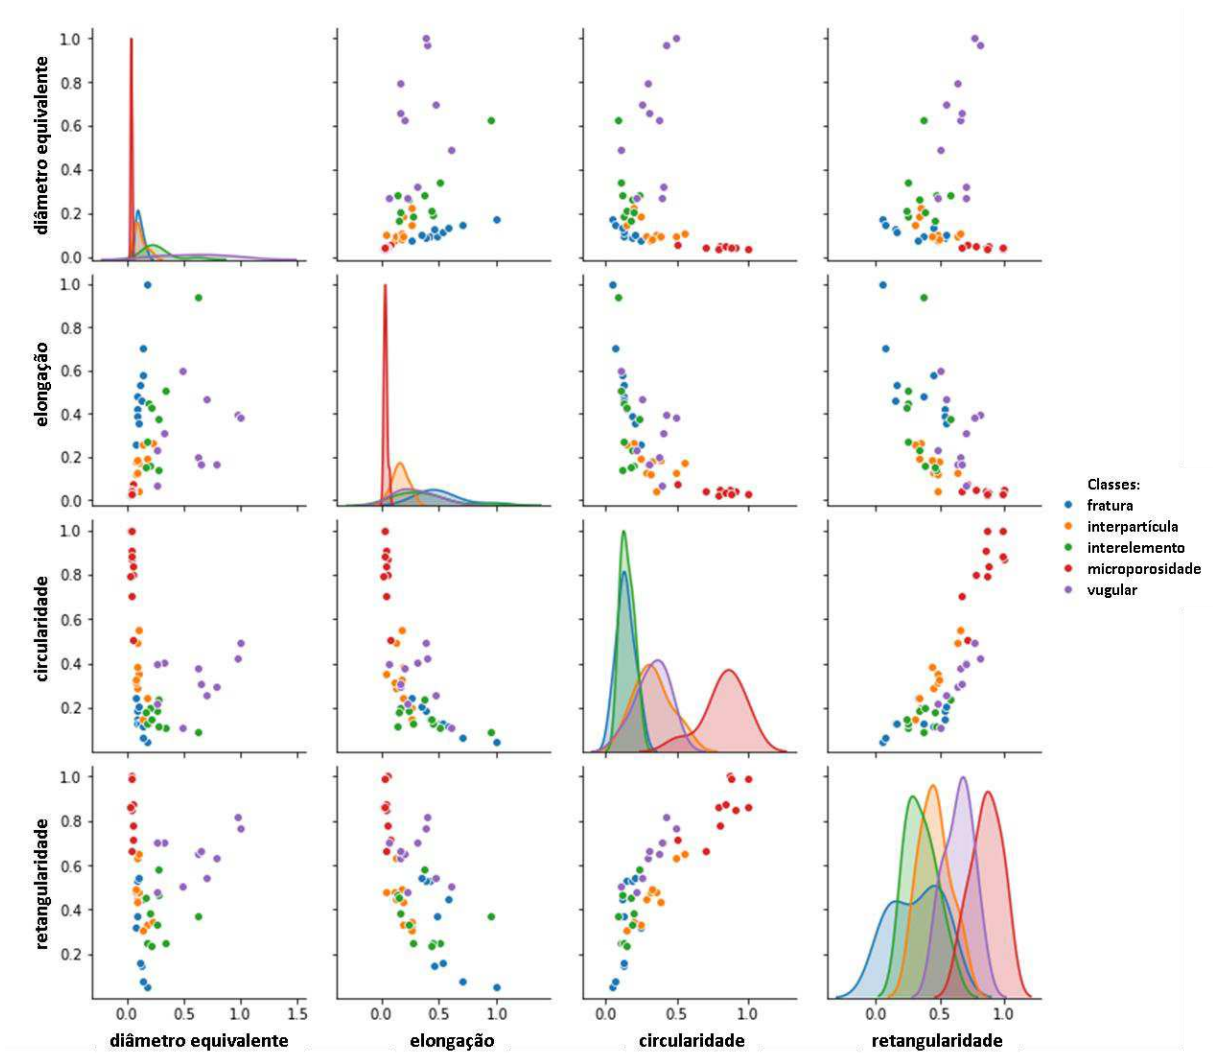


Fonte: Elaborada pelo autor.

4.3.2. Classificação do tipo de porosidade

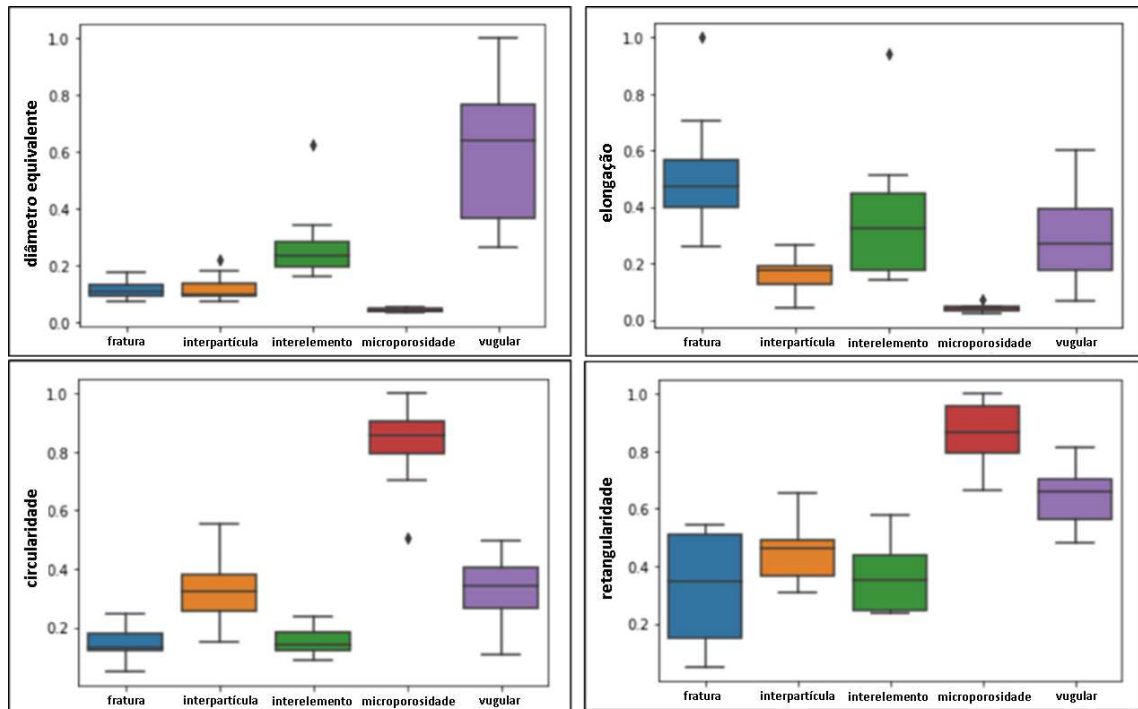
O primeiro resultado obtido a partir do *dataset* criado precede as etapas de treinamento de modelos preditivos. Utilizando os atributos geométricos adimensionais extraídos das 50 instâncias selecionadas do *dataset* original, foi realizada uma análise exploratória dos dados com o objetivo de caracterizar a porosidade. Através da matriz de *crossplots*, histogramas de distribuição (ambos apresentados na Figura 54) e *box plots* (Figura 55), é possível identificar espaços característicos para cada categoria de tipo de porosidade, ainda que ocorram muitas regiões de sobreposição.

Figura 54. Matriz de *crossplots* e histogramas de distribuição dos atributos geométricos.



Fonte: Elaborada pelo autor.

Figura 55. *Box plots* para os quatro atributos geométricos adimensionais extraídos das imagens binárias de poros individualizados




Fonte: Elaborada pelo autor.

Notadamente, a classe microporosidade apresenta características mais exclusivas, o que faz com que seja a mais simples de identificar. Para as demais classes, ainda que os atributos apresentem sobreposições relevantes quando analisados individualmente, têm seus espaços mais bem definidos quando analisados dois a dois, o que indica um bom potencial para determinação de espaços em um contexto de quatro dimensões.

Um modelo de classificação com base nestes quatro atributos geométricos foi treinado utilizando rede neural artificial. A validação cruzada *10-fold* indicou acurácia de 82%. Entretanto, quando aplicado aos dados de teste, a acurácia cai para 73,3%. Este conjunto de teste foi obtido a partir da seleção aleatória de 30% das observações totais e não foram utilizados em momento algum para treinamento do modelo. Ao avaliar a matriz de confusão normalizada para os dados de teste do modelo (Figura 56), identifica-se que a maior parte das classificações incorretas foram em imagens originalmente rotuladas como poro interelemento. Além das classificações corretas, as errôneas foram classificadas como poro vugular ou interpartícula. Também houve algumas observações rotuladas como interpartícula que foram classificadas como interelemento.


Figura 56. Matriz de confusão normalizada para os dados de teste do modelo de classificação de tipos de porosidade baseado em atributos geométricos e redes neurais artificiais.



Fonte: Elaborada pelo autor.

Já o modelo que utiliza rede neural convolucional tem como entrada a própria imagem do poro individualizado. Tem como principal característica a aplicação da técnica de *data augmentation* que envolve transformações geométricas. A validação cruzada *10-fold* indicou acurácia de 92,22%. A aplicação do modelo no dado de teste foi ainda melhor, apresentando 93,5% de acurácia. A matriz de confusão normalizada para os dados de teste do modelo (Figura 57) reflete este valor de acurácia mais elevado e tem sua diagonal principal bem marcada. Ainda assim, houve alguma dificuldade para as classes fratura, interelemento e interpartícula. As classes interelemento e interpartícula deixam de estar vinculadas e o erro da classe originalmente rotulada como interelemento permanece somente com a predição da classe vugular.

Figura 57. Matriz de confusão normalizada para os dados de teste do modelo de classificação de tipos de porosidade baseado em *data augmentation* e redes neurais convolucionais.




Fonte: Elaborada pelo autor.

4.4. Subjetividade interpretativa relacionada aos Petrógrafos

As respostas obtidas durante as entrevistas indicam que: 1. há grande incerteza nas estimativas de ocorrência total realizadas pelos petrógrafos, tanto para porosidade quanto para mineralogia; 2. existem muitas divergências na interpretação das imagens e, conseqüentemente, na classificação de litofácies; e 3. As imagens sintéticas geradas para auxiliar o treinamento dos modelos de classificação de litofácies não são diferenciadas de forma significativa das demais imagens reais obtidas por microscopia ótica, o que confirma a viabilidade e utilidade de sua confecção e utilização.

As estimativas de porosidade total realizadas a partir da Figura 39, excluindo o valor de porosidade obtido pelo modelo de segmentação, no contexto da questão 1, apresentaram duas modas, uma de maior relevância entre 9 e 12%, e outra secundária entre 18 e 21% (Figura 58). Considerando o baixo número de entrevistados, não é possível garantir que estas modas seriam consolidadas ao ampliar o número de petrógrafos participantes, principalmente a moda secundária. Ainda assim, consideramos estas observações para a análise.

Figura 58. Estimativas de porosidade com base na imagem de fotomosaico original de uma lâmina petrográfica e de sua imagem correspondente segmentada pelo modelo de porosidade. Há duas modas, uma principal e uma secundária, marcadas pelos quadrados verdes.




Fonte: Elaborada pelo autor.

A imagem da Figura 59 representa um esferulítico, intensamente dolomitizado, utilizado na questão 2. O rótulo esferulítico foi utilizado como referência no *dataset* de teste. Entretanto, o melhor modelo a classificou como sendo um dolomito. O espaço interelemento está totalmente preenchido por cristais de dolomita e até mesmo os elementos foram recristalizados, o que ocasiona nesta classificação indevida. Esta é a imagem que apresentou maior consenso entre os entrevistados. Com somente uma exceção, todos consideraram que esta seria uma litofácies esferulítico (Figura 60), pois entenderam ser possível a identificação do protólito da rocha, apesar do intenso processo de dolomitização.


A Figura 61 apresenta a imagem referente à questão 3. Ela foi rotulada como esferulítico, pois apresenta partículas de esferulitos aparentemente *in situ*. Entretanto, o melhor modelo a classificou como sendo um estromatólito. A maioria dos entrevistados concordam com o modelo preditivo e também visualizam feições estromatolíticas na imagem (Figura 62). Um número significativo de entrevistados (4) interpretou que a rocha pode estar retrabalhada e a classificaram como grainstone.

Figura 59. Imagem originalmente rotulada como esferulítico e erroneamente predita como dolomito pelo melhor modelo de classificação de litofácies. De fato, a rocha passou por intenso processo de dolomitização. O espaço interelemento é totalmente preenchido por cristais de dolomita e partículas que foram parcialmente recristalizadas. Entretanto, ainda é possível a identificação do protólito da rocha.




Fonte: Adquirida pelo autor.

Figura 60. Interpretação de classificação da imagem da Figura 57 pelos petrógrafos entrevistados. O quadrado verde representa a litofácies originalmente utilizada como rótulo. O quadrado vermelho representa a litofácies erroneamente predita pelo melhor modelo de classificação de litofácies.




Fonte: Elaborada pelo autor.

Figura 61. Imagem originalmente rotulada como esferulitito e erroneamente predita como estromatólito. Para os petrógrafos que entendem realmente se tratar de um esferulitito, esferulitos coalescidos podem apresentar geometrias similares a agregados fasciculares estromatolíticos. A rocha pode representar uma forma transicional entre as duas categorias.



Fonte: Adquirida pelo autor.

Figura 62. Interpretação de classificação da imagem da Figura 59 pelos petrógrafos entrevistados. O quadrado verde representa a litofácies originalmente utilizada como rótulo. O quadrado vermelho representa a litofácies erroneamente predita pelo melhor modelo de classificação de litofácies.




Fonte: Elaborada pelo autor.

Uma das imagens mais controversas é apresentada na Figura 63, referente à questão 4. Ela havia sido originalmente rotulada como um estromatólito, mas foi classificada pelo melhor modelo como sendo pertencente a classe grainstone. Entre os entrevistados, um a atribui à classe dolomito e outro à esferulitito. Mas a grande maioria fica dividido entre as classes grainstone, interpretada por dez petrógrafos, e estromatólito, interpretada por oito petrógrafos (Figura 64).

A Figura 65, referente à questão 5, havia sido originalmente rotulada como um laminito, considerando a forte laminação marcada por material mais escuro. De fato, esta é a interpretação da maioria dos entrevistados (Figura 66). Entretanto, o melhor modelo classifica esta imagem como sendo pertencente à classe grainstone.


Se uma estimativa acurada de porosidade já havia sido problemática na questão 1, a estimativa de classes minerais sem o auxílio de um modelo de segmentação ou de uma microanálise química apresenta-se ainda mais desafiadora na questão 6. Alguns dos entrevistados preferiram não estimar para algumas das classes, considerando que não tinham acesso à imagem com nicóis cruzados ou à realização de um tingimento por composto de alizarina (comumente utilizado na diferenciação entre calcita e dolomita). Por esse motivo, alguns dos histogramas utilizados para apresentar os resultados não apresentam a soma das alternativas igual ao número total de entrevistados. A partir da Figura 43A, foram realizadas estimativas para as classes: calcita, dolomita, quartzo e poros. O nome “quartzo” é utilizado de forma genérica para representar qualquer polimorfo de sílica. Esta terminologia foi utilizada para manter o padrão apresentado nos resultados da microanálise química. Esta foi justamente a classe que apresentou a pior estimativa. Nenhum dos entrevistados escolheu um valor correspondente ao intervalo de classe que de fato corresponde ao observado na microanálise química (Figura 67A). Seu valor é sempre subestimado. Calcita foi o mineral que foi melhor estimado (Figura 67B), mas, ainda assim, houve uma grande variabilidade nas respostas. Tanto a categoria dolomita (Figura 67C) quanto poros (Figura 67D) tiveram um número de estimativas semelhante para três intervalos de classe, indicando que não há um consenso em relação ao percentual de ocorrência total destas classes com base somente na imagem com nicóis descruzados.

Figura 63. Imagem originalmente rotulada como estromatólito e erroneamente predita como grainstone. Para os petrógrafos que entendem se tratar de um grainstone, é possível definir os contornos de partículas retrabalhadas. Já os que a classificam como estromatólito, observam alterações nas texturas de elementos estromatolíticos devido a processos diagenéticos e pedogenéticos, deixando-os “grainificados”.




Fonte: Adquirida pelo autor.

Figura 64. Interpretação de classificação da imagem da Figura 61 pelos petrógrafos entrevistados. O quadrado verde representa a litofácies originalmente utilizada como rótulo. O quadrado vermelho representa a litofácies erroneamente predita pelo melhor modelo de classificação de litofácies.




Fonte: Elaborada pelo autor.

Figura 65. Imagem originalmente rotulada como laminito e erroneamente predita como grainstone. A maioria dos entrevistados concorda com o rótulo original da amostra. Entretanto, há grande variedade de atribuições para esta imagem. Todas as classes foram, eventualmente, selecionadas para nomeá-la, com exceção da classe silexito.




Fonte: Adquirida pelo autor.

Figura 66. Interpretação de classificação da imagem da Figura 63 pelos petrógrafos entrevistados. O quadrado verde representa a litofácies originalmente utilizada como rótulo. O quadrado vermelho representa a litofácies erroneamente predita pelo melhor modelo de classificação de litofácies.



Fonte: Elaborada pelo autor.


Figura 67. Histogramas das estimativas por intervalo de ocorrência de: A) quartzo; B) calcita; C) dolomita; e D) porosidade. A linha pontilhada indica a média móvel utilizando um período igual a 2.



Fonte: Elaborada pelo autor.

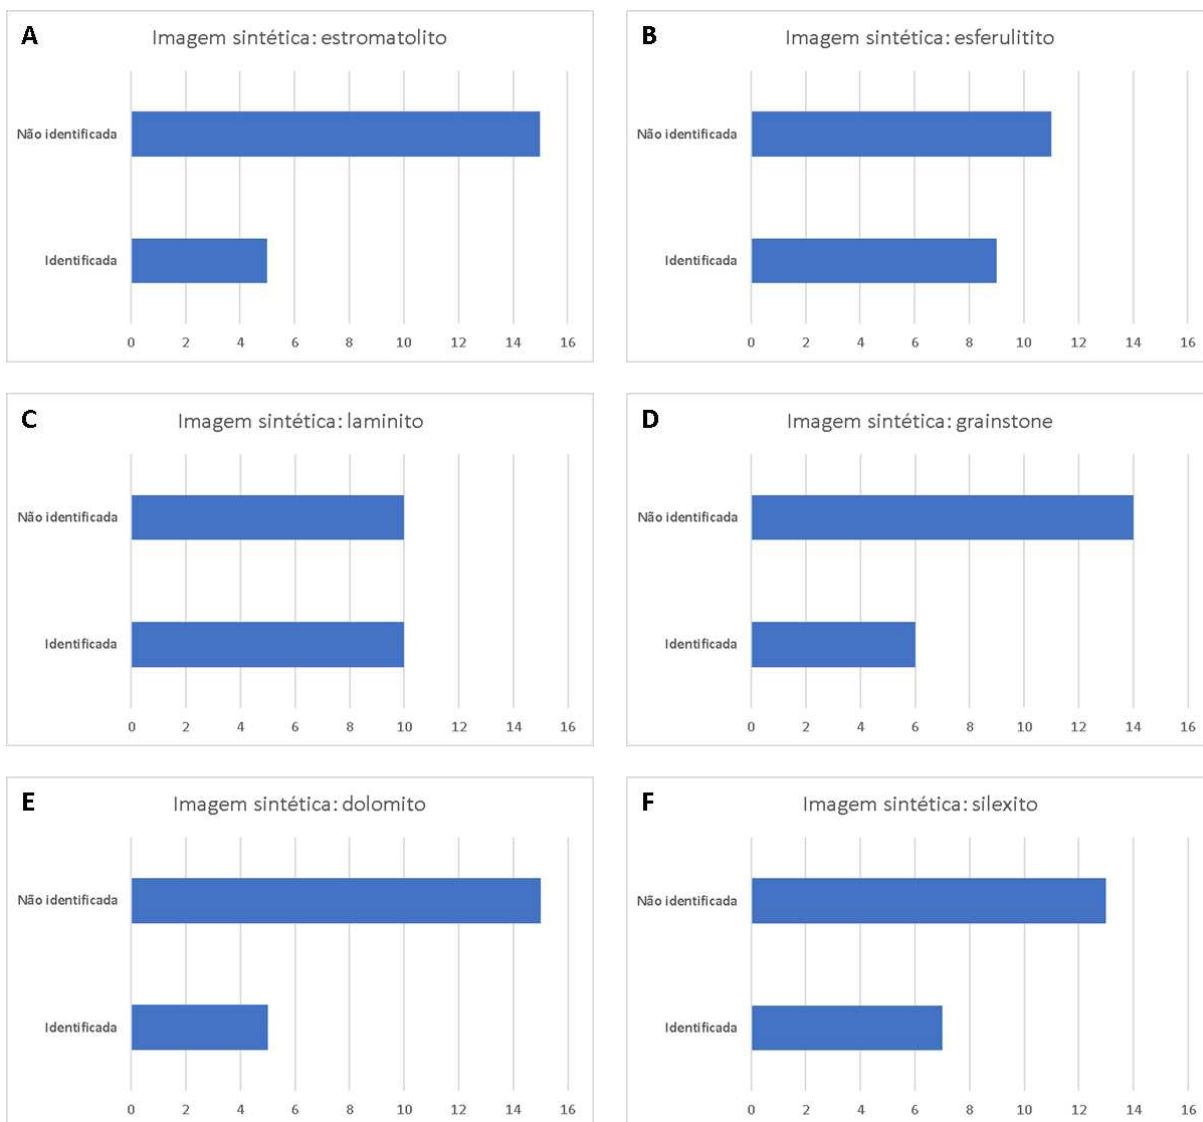
As questões de 7 a 12 apresentam imagens correspondentes a uma mesma litofácies, sendo que uma das imagens apresentadas por questão é sintética (Figura 68). Para todas as litofácies, a maioria dos entrevistados não identificou a imagem sintética entre as imagens apresentadas, com exceção da classe laminito, em que metade dos entrevistados identificou e metade não identificou a imagem sintética (Figura 69). Isso indica que as imagens sintéticas apresentam boa qualidade, uma vez que sua identificação entre um conjunto de imagens do mesmo contexto não é trivial. Ainda assim, considerando o percentual de entrevistados que identificaram as imagens sintéticas, é possível concluir que as imagens criadas para as litofácies laminito e esferulítico não são tão realistas quanto as imagens criadas para as litofácies estromatólito e dolomito. Alguns entrevistados destacaram que a imagem sintética apresentada para a classe laminito apresenta alguns artefatos – linhas verticais – que estariam indicando sua origem artificial. Ainda assim, destaca-se que o número de entrevistados que não identificaram as imagens sintéticas foi maior do que o número de entrevistados que as identificaram, considerando as seis litofácies avaliadas.

Figura 68. Imagens correspondentes às litofácies utilizadas nas entrevistas, na ordem em que foram apresentadas. As imagens sintéticas são destacadas por um quadrado vermelho e foram geradas com resolução inferior, devido ao custo computacional. As demais imagens tiveram suas resoluções reduzidas e escalas removidas para não influenciar a seleção.



Fonte: Elaborada pelo autor.

Figura 69. Identificação das imagens sintéticas pelos entrevistados por litofácies: A) estromatólito; B) esferulitito; C) laminito; D) grinstone; E) dolomito; F) silexito.



Fonte: Elaborada pelo autor.

5. DISCUSSÕES

5.1. Modelos de Segmentação


Embora os resultados tanto dos modelos de segmentação que utilizam redes neurais artificiais quanto dos que utilizam *random forest* para os dois conjuntos de lâminas mostrem alta acurácia e baixos erros, os dois podem ser aplicados de forma restrita, em imagens de lâminas que apresentam o mesmo contexto das imagens utilizadas durante o treinamento. Isto significa que os modelos mineralógicos serão mais acurados quando aplicados em imagens de lâminas petrográficas que são originadas na seção Pré-Sal da Bacia de Santos, preferencialmente do mesmo campo de petróleo das amostras utilizadas para treinamento. O modelo de porosidade pode ser aplicado a qualquer lâmina petrográfica que utilize corante azul para preencher os poros na etapa de sua confecção (embora possam ocorrer algumas variações a depender do fabricante dos produtos para confeccionar as lâminas).

Existem outras limitações importantes que devem ser observadas ao aplicar os modelos à novos dados. Lâminas petrográficas delgadas apresentam uma espessura que varia entre 30 e 35 μm , o que limita a resolução vertical. Este fator geralmente faz com que as ocorrências de poros sejam subestimadas devido à efeitos de borda e à presença de microporosidade. Se as lâminas não estão na espessura padrão, as propriedades ópticas dos minerais podem ser diferentes. Isso iria causar erros nos modelos mineralógicos. Além disso, durante a fase de desbaste da confecção das lâminas, alguns minerais podem ser removidos se a lâmina se tornar muito fina. Isso iria causar uma superestimativa de porosidade. Uma das premissas para que todos os modelos funcionem é que a aquisição seja realizada com potência de luz adequada. O ajuste de exposição e balanço de branco são fundamentais. A aplicação dos modelos em imagens muito escuras ou muito claras pode resultar em classificações erradas.

Alguns minerais podem apresentar uma ampla variedade de propriedades ópticas, resultando em muitas respostas de transmissibilidade possíveis. Fragmentos fosfáticos, por exemplo, são treinados para serem classificados na categoria outros. Entretanto, em uma das lâminas em que o modelo foi aplicado, eles apareceram muito mais claros do que durante o treinamento (Figura 70). Isso induziu o modelo a classificar este elemento como calcita, dolomita e minerais opacos, ao invés de outros.


Outros artefatos relacionados à confecção da lâmina podem resultar em erros de classificação. A Figura 71 mostra uma bolha presa em um poro, erroneamente classificada como não-poro.

Figura 70. A) Fragmento fosfático mais claro do que os utilizados para treinamento. B) Imagem segmentada pelo modelo treinado com o *dataset 1*, utilizando *random forest*. O modelo somente classifica localmente a ocorrência do fragmento como outros (em laranja).



Fonte: Elaborada pelo autor.

Figura 71. A) Poro com uma bolha presa: artefato da confecção da lâmina petrográfica. B) Imagem segmentada a partir da aplicação do modelo de porosidade treinado com o *dataset 2*, utilizando *random forest*, com transparência, sobreposta a imagem original. A bolha representa um espaço poroso, entretanto é classificada como não-poro pelo modelo.



Fonte: Elaborada pelo autor.

Características do tipo de porosidade também apresentam um efeito na acurácia da segmentação. Poros preenchidos por muitos argilominerais são mais difíceis de serem segmentados, considerando que a fronteira entre argila e poro é mais difusa. De forma oposta, poros provenientes de rochas cristalinas são mais facilmente segmentados.

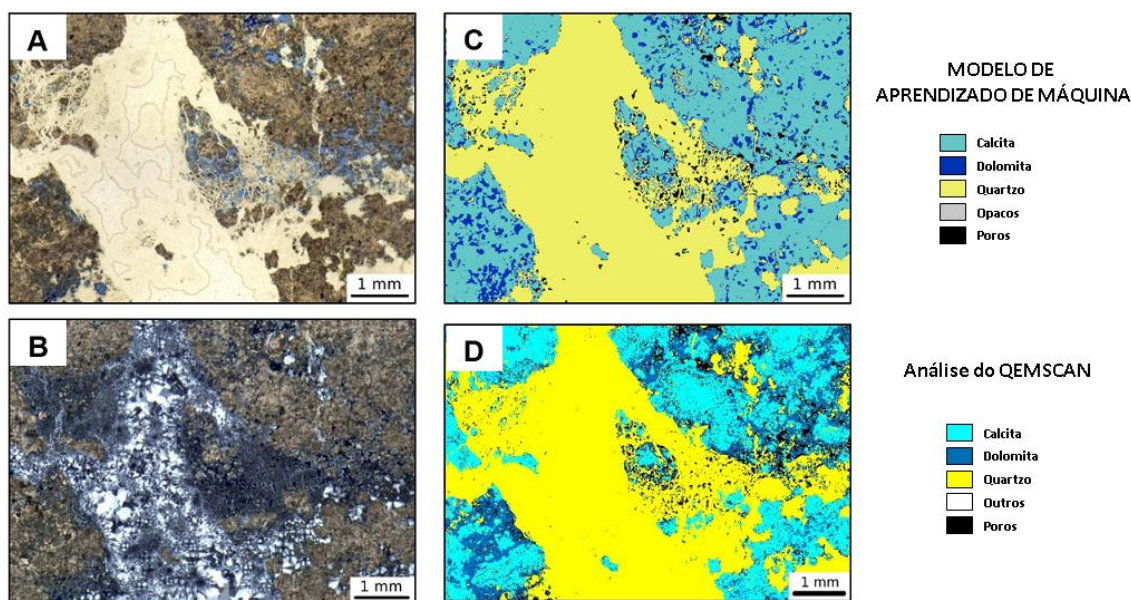
Quando avaliadas as matrizes de confusão dos dois modelos mineralógicos baseados em *random forest*, um treinado com o *dataset 1* e outro com o *dataset 3*, é observado um padrão semelhante aos dois modelos, porém mais evidentes no modelo criado a partir do *dataset 3*. Considerando que o dado de treinamento do *dataset 1* foi

selecionado sem a validação por dados químicos, os *pixels* correspondentes aos minerais que foram utilizados para treinar a classe outros foram claramente identificados por análise petrográfica, embora carreguem similaridades aos minerais mais comuns. *Pixels* selecionados para treinamento da classe outros no *dataset 3* foram inicialmente identificados por microanálise química e poderiam ter sido ignorados em uma análise petrográfica comum.

A matriz de confusão do modelo mineralógico treinado com o *dataset 3* e *random forest* permite verificar a dificuldade em classificar dolomita. Este também é um problema para a análise petrográfica tradicional. Geralmente é utilizado um composto baseado em alizarina que tingem minerais calcínicos, mas não dolomita. Fotomosaicos do primeiro conjunto de lâminas petrográficas – utilizado para seleção do *dataset 1* – foram adquiridos de lâminas petrográficas parcialmente tingidas. O mesmo não ocorreu para os fotomosaicos adquiridos a partir das lâminas do segundo conjunto – utilizadas para seleção do *dataset 3*.


A correlação de ocorrências relativas de fases minerais entre o modelo mineralógico e a análise QEMSCAN mostra tendências que levemente superestimam dolomita, em oposição a uma suave subestimação de quartzo. Isto é consistente com a correlação entre valores de densidades de sólidos, no qual as densidades calculadas médias obtidas dos modelos é levemente superior às medidas em laboratório – dolomita apresenta densidade superior ao quartzo. Considerando as distorções em imagens de lâminas petrográficas delgadas devido às curvaturas das lentes e as diferenças de resolução em termos de tamanho do lado do *pixel*, as imagens segmentadas pelos modelos de porosidade e os resultados da microanálise química não foram registrados. Embora não seja possível obter uma análise *pixel a pixel* do resultado, é possível visualizar tendências e obter conclusões baseado em suas similaridades (Figuras 72 a 74). As fronteiras entre diferentes fases minerais podem ser erroneamente classificadas devido a efeitos de bordas, juntamente com limitações relacionadas à resolução das imagens. Especificamente, na fronteira entre quartzo e calcita, pode ser identificada uma inexistente franja de dolomita.

Figura 72. Imagens representando a mesma região de uma lâmina petrográfica. Quartzo microcristalino é erroneamente classificado como dolomita ou calcita. A) Imagem petrográfica adquirida com polarizadores descruzados. B) Imagem petrográfica adquiridas utilizando os polarizadores cruzados. C) Imagem segmentada obtida a partir do modelo mineralógico baseado no *dataset 3*; D) Composição de QEMSCAN interpretada para microanálise química.




Fonte: Elaborada pelo autor.

Figura 73. Imagens representando a mesma região de uma lâmina petrográfica. A fronteira entre quartzo e calcita pode ser classificada erroneamente como dolomita, criando uma franja inexistente. A) Imagem petrográfica adquirida com polarizadores descruzados. B) Imagem petrográfica adquiridas utilizando os polarizadores cruzados. C) Imagem segmentada obtida a partir do modelo mineralógico baseado no *dataset 3*; D) Composição de QEMSCAN interpretada para microanálise química.



Fonte: Elaborada pelo autor.

Figura 74. Imagens representando a mesma região de uma lâmina petrográfica. A ocorrência relativa de dolomita mostra uma tendência a superestimação. Entretanto, espera-se que sua classificação seja difícil considerando que as lâminas do segundo conjunto de lâminas petrográficas não está tingido por um composto baseado em alizarina. A) Imagem petrográfica adquirida com polarizadores descruzados. B) Imagem petrográfica adquiridas utilizando os polarizadores cruzados. C) Imagem segmentada obtida a partir do modelo mineralógico baseado no *dataset 3*; D) Composição de QEMSCAN interpretada para microanálise química.



Fonte: Elaborada pelo autor.

Modelos que utilizam *random forest* permitem uma análise da importância dos atributos baseada no índice de impureza médio e no número de nós utilizando cada atributo. Para todos os modelos, os atributos gerados pela aplicação de variações do filtro convolucional hessiana são os mais importantes para a classificação, seguidos pelos atributos não-convolucionais. Interessante destacar que os atributos menos importantes também são gerados por variações de hessiana. De qualquer forma, a combinação de diferentes filtros convolucionais discretos permite a criação de modelos mais robustos.

5.2. Modelos de Detecção de Objetos

O modelo de detecção de fragmentos fosfáticos envolve a utilização de um conceito intermediário entre a segmentação *pixel a pixel* e a classificação de uma imagem inteira em uma categoria. Para este tipo de modelo intermediário, o interesse está em um grupo de *pixels* que forma um objeto. Para obter um modelo com essas características foi necessário utilizar conceitos dos dois extremos. De um lado, é aplicado o filtro NLM – como os modelos de classificação – de forma a remover feições que possam ser consideradas ruídos, além de homogeneizar *pixels* com características semelhantes, simplificando a delimitação de um objeto. Do outro, é realizada uma segmentação binária – como proposto pelos melhores modelos de segmentação – que precisa ser sucedida por uma sequência de operadores de erosão e dilatação para eliminar falsos positivos.

Existem algumas fragilidades na tentativa de generalizar este método para outros objetos que precisam ser consideradas. Parte-se do princípio que objetos são relativamente uniformes em seu interior quando comparados ao ambiente em que estão inseridos. Entretanto, esta não é uma realidade em geologia e, do ponto de vista da petrografia, é comum a análise de partículas ou elementos que apresentem texturas internas que poderiam complicar a etapa de aplicação do NLM. Eventualmente, a presença de texturas laminadas pode dificultar a delimitação das fronteiras de um objeto. Texturas mais complexas, como a textura fibro-radial em esferulitos, texturas de crescimento ou fibrosas em estromatólitos, podem complicar ainda mais esta delimitação. Os fragmentos fosfáticos são uma alternativa relativamente simples para esta tarefa, pois não apresentam texturas internas complexas (apesar de suas geometrias diversas). É interessante explorar a aplicação em outros tipos de objetos de interesse na atividade de análise petrográfica.

O segundo ponto de atenção está relacionado à frequência de ocorrência do objeto de interesse. A sequência de operadores morfológicos criada para o modelo de detecção de fragmentos fosfáticos pode não ser adequada para identificação de objetos com frequências de ocorrência muito diferentes das observadas para este modelo. A terceira questão a ser considerada é a forma de validação deste tipo de modelo. Devido à complexidade das imagens, não há como garantir que as todas as ocorrências do objeto de interesse foram identificadas. Apesar da criação de um conjunto de teste a partir de uma imagem que não foi utilizada para treinamento do

modelo, foi identificado um número maior de ocorrências de fragmentos fosfáticos do que o observado originalmente pela análise petrográfica. Este já é um resultado excelente do ponto de vista de melhoria do processo de análise petrográfica, mas não garante que todas as ocorrências tenham sido identificadas pelo modelo (da mesma forma que foram negligenciadas pelo petrógrafo). Uma alternativa seria a utilização de imagens menores, ou de amostras controladas, como a utilização de plugues sintéticos para confecção da lâmina delgada.

5.3. Modelos de Classificação


5.3.1. Classificação de litofácies

O melhor modelo de classificação de litofácies apresentou as classes diagenéticas como sendo as de maiores acurácias nos dados de teste: 95% para dolomito e 100% para silexito. Este é um resultado esperado considerando que alterações associadas à processos de dolomitização e silicificação tendem a criar rochas mais homogêneas, que irão apresentar características similares. Outras instâncias que foram classificadas corretamente para outras categorias são muito representativas de suas litofácies correspondentes, como demonstrado nas Figuras 75 a 80. Alguns exemplos de instâncias classificadas incorretamente são discutidos considerando a interpretação dos petrógrafos obtidas em entrevistas, que será detalhada em seção subsequente.

Interessante notar como a performance das classes muda de acordo com as transformações aplicadas. Por exemplo, o modelo 4, baseado somente em NLM e augmentations espectrais, classificou erroneamente todas as instâncias da categoria dolomito. Isto é atribuído à presença de cristais de dolomita recristalizados, o que indica a menor relevância de feições geométricas para a classificação. O oposto ocorre para a classe esferulítico, que apresenta sua melhor acurácia para este modelo. Considerando a importância de feições arredondadas para a classificação desta categoria, a geometria tem maior relevância e a acurácia aumenta.

Figura 75. Exemplos de instâncias corretamente classificadas para a categoria estromatólito.


A) Shrubs fasciculares não são tão evidentes como em B e o espaço interelemento é parcialmente cimentado por dolomita. B) Porosidade é preservada no espaço interelemento e estruturas estromatolíticas são destacadas. Os modelos deveriam reconhecer estas estruturas em diferentes escalas, mas a imagem precisa ter um contexto mínimo para ser corretamente classificado: se estruturas não puderem ser reconhecidas considerando a escala na qual as imagens são adquiridas.



Fonte: Adquiridas pelo autor.


Figura 76. Exemplos de instâncias corretamente classificadas para a categoria esferulítico.

Existem partículas de esferulitos arredondadas tanto em A quanto em B. Cimentação por dolomita é mais comum em B, o que poderia causar alguma confusão na classificação. Em B, texturas radiais são mais evidentes do que em A. Para estas duas imagens, não há muita diferença no tamanho das partículas, mas os modelos são capazes de generalizar para diferentes escalas.




Fonte: Adquiridas pelo autor.

Figura 77. Exemplos de instâncias corretamente classificadas para a categoria laminito. As laminações observadas em A são mais crenuladas do que as observadas em B. Embora as condições de iluminação sejam bastante diferentes para as duas instâncias, o melhor modelo é capaz de predizê-las corretamente.




Fonte: Adquiridas pelo autor.

Figura 78. Exemplos de instâncias corretamente classificadas para a categoria grainstone. Enquanto as partículas retrabalhadas são mais compactadas em A, são de natureza e composição mais heterogênea em B, onde o espaço interpartícula encontra-se mais preservado. Ainda assim, a porosidade é parcialmente reduzida por cimentação de dolomita e sílica.




Fonte: Adquiridas pelo autor.

Figura 79. Exemplos de instâncias corretamente classificadas para a categoria dolomito. Cristais de dolomita estão representados maiores em A do que em B. Isto não significa necessariamente que eles sejam maiores, a imagem pode estar em uma escala diferente (neste caso, são maiores de fato). Os modelos foram treinados em informação de escala de forma que eles possam ser usados para imagens adquiridas por diferentes lentes objetivas dos microscópios. Apesar de terem sido adquiridas sob condições de iluminação distintas, ambas foram corretamente classificadas.



Fonte: Adquiridas pelo autor.

Figura 80. Exemplos de instâncias corretamente classificadas para a categoria silexito. O ajuste da intensidade da fonte de luz foi maior do que deveria durante a aquisição da imagem A, provavelmente devido a regiões mais escuras da lâmina petrográfica enquanto adquirindo o fotomosaico. Em B, condições de iluminação estão melhor ajustadas. A lâmina que deu origem a esta instância é mais homogênea. Porosidade ocorre diferentemente para as instâncias: enquanto B apresenta somente microporosidade, é possível verificar poros vulgares em A.



Fonte: Adquiridas pelo autor.

Simplesmente aplicar todas as *augmentations* espectrais nas instâncias de treinamento pode sugerir aos modelos que os canais de cor não são relevantes para a classificação. Por exemplo, acrescentar instâncias com priorização do canal azul criadas para todas as instâncias originais implica que a informação relacionada ao canal azul não é tão relevante para o problema de classificação. Chatfield et al. (2014) comparou acurácias de classificação de modelos treinados com imagens RGB – três canais de cor – com modelos treinados com as mesmas imagens convertidas para escala de cinza – um canal de cor. Eles obtiveram uma queda aproximada de 3% na acurácia para os *datasets* avaliados. Esta é uma queda consistente com a observada pelo modelo treinado após a filtragem NLM com *augmentations* espectrais – Modelo 3. A acurácia do *dataset* de teste caiu de 53,52% obtida no modelo treinado após a filtragem NLM – Modelo 2 – para 50,93% obtida para modelo treinado com as mesmas imagens acrescidas de *augmentations* espectrais – Modelo 3.

Embora novos dados estejam sendo acrescentados ao *dataset* de treinamento, quando aplicado para todas as imagens e independente de outras técnicas de *augmentation*, *augmentations* espectrais podem ter um efeito similar a converter imagens com três canais de cor em imagens com coloração de cinza. Entretanto, este efeito é observado considerando somente o *dataset* original de tamanho limitado usado para treinamento. Quando aplicado em conjunto com *augmentations* geométricas, que amplifica o número de imagens utilizadas durante o treinamento, são capazes de aumentar a acurácia dos dados de teste para 73,29% – Modelo 5. A aplicação de *augmentations* geométricas isoladamente, somente com a filtragem NLM – Modelo 4 – adicionou um ganho de somente 3% em relação ao modelo treinado com imagens que passaram por filtragem NLM – Modelo 2, atingindo 56,52%. Este resultado mostra a importância de aplicar as duas técnicas e como elas podem ser relevantes para a capacidade de generalização dos modelos.

Estas técnicas de transformação do dado são muito úteis para aumentar a acurácia, mas não são tão efetivas como acrescentar um dado novo real ao *dataset* de treinamento. A alternativa mais próxima a isto seria acrescentar novas imagens sintéticas criadas por GANs ao *dataset* de treinamento antes de aplicar as outras técnicas – Modelo 6. Obviamente, não é o mesmo que acrescentar novas imagens obtidas em microscópio, mas foi responsável por um aumento significativo na acurácia dos dados de teste, que alcançou 86,34%. Este é um valor próximo à acurácia obtida para o dado de validação dos últimos dois modelos – Modelos 5 e 6: 87,55%. A

estabilização da acurácia do dado de validação nos modelos treinados com e sem imagens sintéticas, com todas as outras técnicas de *augmentation* aplicadas, sugere que uma acurácia máxima foi alcançada, considerando limitações do *dataset* de treinamento original, como as sobreposições entre as classes. O valor similar obtido para a acurácia dos dados de teste indica que o modelo final – Modelo 6 –, que usa imagens sintéticas e todas as técnicas de *augmentation*, é capaz de generalizar da melhor forma possível, ou seja, está bem ajustado, considerando o *dataset* de treinamento original.

5.3.2. Classificação do tipo de porosidade

Em relação aos modelos de classificação do tipo de porosidade, um dos erros de classificação observados com o auxílio da matriz de confusão do modelo baseado em atributos geométricos e redes neurais artificiais está relacionado à distinção entre as classes interelemento e interpartícula. Destaca-se que a porosidade interelemento é característica de rochas *in situ*, enquanto que a porosidade interpartícula ocorre em rochas retrabalhadas. Esta confusão entre poros interelemento e interpartícula é compreensível, pois mesmo com todos os elementos da rocha presentes em uma imagem, há divergências entre o que pode ser considerada uma rocha *in situ* e uma rocha retrabalhada (vide o resultado da questão 04 das entrevistas).

Apesar de o modelo baseado em *data augmentation* e rede neural convolucional ter apresentado valor de acurácia superior para o dado de teste em relação ao modelo baseado em atributos geométricos e rede neural artificial, os *datasets* utilizados para treinamento foram diferentes, sendo que este último foi reduzido em relação ao primeiro. Apesar desta ressalva, há um indicativo de que a utilização de redes neurais convolucionais resulta em modelos melhores. Os atributos geométricos podem ser afetados por diversas alterações decorrentes de processos diagenéticos, como cimentação e compactação, o que influenciaria muito no resultado da classificação.

De qualquer forma, a extração dos atributos geométricos a partir das imagens segmentadas binárias dos modelos de porosidade permite ampliar o caráter quantitativo da caracterização da porosidade nas rochas, proporcionando melhor compreensão do arcabouço poroso. Esta caracterização, auxiliada pela análise exploratória dos dados, vai além da atividade de classificação do tipo de porosidade,

viabilizando a integração com dados de diferentes escalas, como perfis e sísmica, através de correlações.

5.4. Subjetividade interpretativa relacionada aos Petrógrafos

Para a imagem da questão 1, o modelo de segmentação indicou 5,96% de porosidade, enquanto que a petrofísica laboratorial realizada na amostra lateral da qual a lâmina é proveniente, apresenta um valor bem mais elevado, de 18,57% de porosidade. Caso a moda principal da estimativa estiver correta em relação à porosidade observada na lâmina, há uma correspondência em relação ao que foi observado nas correlações com o dado de microanálise química das lâminas, pois o modelo estaria subestimando a ocorrência de poros devido a efeitos de bordas e presença de microporosidade. Existe a possibilidade de que parte dos entrevistados tenha estimado um valor de porosidade já levando em consideração a experiência que têm em correlacionar suas estimativas a partir da lâmina com as medidas laboratoriais em um momento posterior. Eles estariam extrapolando uma estimativa da lâmina para a amostra lateral, compensando possíveis heterogeneidades geológicas que já estão acostumados a observar. Esta seria uma explicação para a moda secundária observada. Ainda assim, a incerteza a partir da estimativa dos petrógrafos é alta, considerando que houve ao menos uma resposta para cada intervalo de classe acima de 3%.

A imagem utilizada para a questão 2 apresentou grande consenso entre os entrevistados. A classificação errônea por parte do melhor modelo de classificação de litofácies indica uma possível limitação de sua aplicação em rochas que foram muito alteradas por processos diagenéticos, mas que ainda permitem a identificação do protólito. A imagem da questão 3 é marcada por ter sido predita pelo modelo como estromatólito, enquanto o rótulo original é de esferulitito. A maioria dos entrevistados concordaram com o modelo. Confusão entre estas duas classes é esperada devido ao contexto deposicional: formas transicionais entre esferulitos calcíticos e agregados de calcita fasciculares são frequentes, o que indica precipitação dos mesmos fluidos sob condições levemente diferentes (DE ROS, 2018; LIMA; DE ROS, 2019). Estas formas transicionais são difíceis de serem classificadas em categorias discretas, como esferulitito ou estromatólito. Podem ocorrer, ainda, esferulitos amalgamados apresentando geometrias que se assemelham a estruturas estromatolíticas. Para os

entrevistados que classificaram a imagem como grainstone, a rocha retrabalhada seria composta tanto por esferulitos quanto por fragmentos de estromatólito. A imagem da questão 4 é bastante controversa, pois teve a maioria dos entrevistados divididos entre duas classes: grainstone e estromatólito. Isto indica que há uma dificuldade em definir uma questão fundamental para a interpretação do ambiente deposicional, pois uma das categorias representa uma fácies retrabalhada e outra, uma fácies *in situ*. Para os petrógrafos que interpretaram a imagem como sendo um grainstone, é possível definir os contornos de partículas retrabalhadas. Já os petrógrafos que interpretaram um estromatólito, entendem que a rocha passou por intensos processos diagenéticos e, até mesmo, pedogenéticos, o que ampliou feições de dissolução e alterou as texturas de elementos estromatolíticos, deixando-os “grainificados”. Ainda assim, o protólito seria um estromatólito e, por isso, deveriam ser classificados dessa maneira. Assim como a imagem da questão anterior, podem ser representativos de formas transicionais. A imagem da questão 5 havia sido rotulada como laminito e foi classificada como grainstone. A maioria dos entrevistados concordam com o rótulo original, entretanto, há uma grande quantidade de atribuições divergentes, contemplando um percentual elevado de respostas. Apenas um entrevistado classificou a imagem como sendo grainstone, pois a mesma apresentaria algumas partículas interpretadas como pelóides retrabalhados e micritizados. Também houve um entrevistado que a classificou como dolomito e dois que a classificaram como esferulitito. Uma outra alternativa seria a identificação de um estromatólito, interpretado por quatro entrevistados. Estes argumentaram que a imagem estaria representando um estromatólito de origem biológica, com uma textura grumosa.

A partir de imagens que foram classificadas incorretamente pelo melhor modelo de classificação de litofácies, as questões 2 a 5 evidenciam as diferentes interpretações possíveis a partir de uma mesma imagem de lâmina petrográfica. Trata-se de um viés interpretativo que ocorre no momento em que as imagens são rotuladas. Estas controvérsias irão influenciar tanto o treinamento quanto o teste do modelo, pois o viés ocorre na formação dos dois *datasets*. Foram avaliadas somente quatro imagens que, em teoria, teriam sido avaliadas incorretamente pelo modelo. Questiona-se o quanto essas diferentes interpretações afetam o resultado do teste. Além do efeito que causam durante o treinamento do modelo final. Uma alternativa para gerenciar estes *datasets* compostos por instâncias que podem apresentar alto viés de interpretação seria a utilização de dois ou mais rótulos em uma mesma

imagem.

A dificuldade dos entrevistados em identificar as imagens sintéticas entre um conjunto de imagens do mesmo contexto indica que as mesmas apresentam boa qualidade. Ainda assim, considerando o percentual de entrevistados que identificaram as imagens sintéticas, é possível concluir que as imagens criadas para as litofácies laminito e esferulitito não são tão realistas quanto as imagens criadas para as litofácies estromatólito e dolomito. Alguns entrevistados destacaram que a imagem sintética apresentada para a classe laminito apresenta alguns artefatos – linhas verticais – que estariam indicando sua origem artificial. Ainda assim, destaca-se que o número de entrevistados que não identificaram as imagens sintéticas foi sempre maior ou igual (para uma classe) ao número de entrevistados que as identificaram, considerando as seis litofácies avaliadas.

6. CONSIDERAÇÕES FINAIS

Algoritmos de aprendizado de máquina possibilitam maior caráter quantitativo na análise petrográfica, além de viabilizar a criação de ferramentas que auxiliam a descrição. Em todos os modelos treinados e avaliados neste trabalho, uma abordagem centrada no dado foi priorizada. Foram utilizadas diversas técnicas: conversão de espaço de cor, operadores morfológicos, convoluções, filtragens, transformações espectrais, geométricas e imagens sintéticas geradas por GANs. Ainda assim, diferentes parâmetros e algoritmos foram testados e avaliados: *random forest*, redes neurais artificiais e redes neurais convolucionais. Existem muitas propostas de arquiteturas de modelos. Em geral, a evolução destas arquiteturas envolve o aprofundamento das redes com o aumento do número de camadas, fenômeno popularmente chamado de “*going deeper*” (SZEGEDY et al., 2015), que dá origem aos modelos de aprendizado profundo, ou “*deep learning*”. Entretanto, o foco no tratamento e transformação dos dados viabiliza a utilização de arquiteturas mais simples para obtenção de modelos acurados, o que permite a utilização de bases de dados reduzidas e despadronizadas, além de uma redução de custos computacionais, em termos de tempo de processamento.

A hipótese de que a análise petrográfica pode ser auxiliada por modelos de aprendizado de máquina, gerando resultados quantitativos confiáveis, padronizados e rápidos foi testada e validada através do uso de diversas ferramentas estatísticas que indicam a capacidade de generalização e limitações que os diferentes tipos de modelos apresentam.

Ao aplicar os modelos treinados em novas imagens, a origem dos dados de treinamento utilizados deve ser levada em consideração. Entretanto, os métodos podem ser replicados para diferentes áreas e/ou contextos estratigráficos. As imagens fornecem informação somente da luz transmitida que passa pela seção delgada. Para os modelos de segmentação, a feição de interesse é representada pelo *pixel*, viabilizando a caracterização mineralógica e da porosidade. Feições de interesse maiores são representadas por um conjunto de *pixels* e os modelos treinados são os de detecção de objetos, como o modelo de detecção de fragmentos fosfáticos. Os modelos de classificação rotulam toda uma imagem com base na análise total de seus *pixels*, como os modelos de tipo de porosidade e de litofácies.

Através da avaliação da importância dos atributos obtidos e utilizados para

criação dos modelos de segmentação, foi possível identificar os filtros convolucionais discretos que apresentam maior relevância para extrair as feições de interesse principais: diferentes variações do filtro hessiana. Entretanto, todos os filtros utilizados contribuem para os modelos. Os resultados obtidos para os modelos de segmentação estão consolidados e validados, através do uso de correlações com dados de análises químicas e validação cruzada. Modelos mineralógicos, quando validados por dados de microanálise química, podem ser utilizados de forma controlada para segmentar imagens de lâminas petrográficas que não terão sua composição medida.

Os modelos de segmentação permitem a extração de atributos geométricos e alimentam, ainda, modelos de classificação do tipo de porosidade, bem como fazem parte do modelo de detecção de fragmentos fosfáticos. A segmentação realizada para os fragmentos fosfáticos é precedida pela filtragem pré-convolucional NLM, que elimina ruídos e contribui na definição das fronteiras de um objeto. Foi sucedida por uma sequência de erosão e dilatação que elimina falsos positivos, além da criação e posicionamento de caixas de seleção.

Para os modelos de classificação de litofácies, as transformações e *augmentations* dos dados mais do que dobraram a acurácia das predições do *dataset* de teste, mantendo uma arquitetura de rede neural convolucional fixa. Considerando a natureza das imagens de lâminas petrográficas, uma nova nomenclatura para *augmentations* de cores é proposta: *augmentations* espectrais. Neste trabalho, as *augmentations* espectrais foram apresentadas como variações de uma janela mais restrita do que o campo do visível. Entretanto, o termo permite a expansão do tamanho da janela, bem como de seu posicionamento no espectro eletromagnético para outras regiões. Foi demonstrado o potencial da aplicação conjunta de técnicas de *augmentations* espectrais e geométricas, bem como os benefícios da utilização de imagens sintéticas geradas por redes adversárias geradoras no treinamento do modelo. Considerando a baixa disponibilidade e padronização dos dados provenientes da indústria de Óleo e Gás, estas técnicas são as melhores opções para se treinar modelos preditivos capazes de generalizar adequadamente. Baseado em um *dataset* de treinamento pequeno, obtido a partir de diferentes fontes de dados, o modelo de classificação de litofácies foi treinado com alto valor de acurácia, medido com dados de poços adjacentes, que não foram utilizados para o treinamento.

O melhor algoritmo de classificação a ser utilizado depende do problema em questão. Para os modelos de segmentação, *random forest* apresentou uma leve

vantagem em relação a redes neurais artificiais. Embora a diferença seja muito pequena em termos de acurácia, *random forest* tem um custo computacional menor do que redes neurais. Problemas mais complexos demandam algoritmos mais robustos, como a utilização de redes neurais convolucionais para os modelos de classificação.

Entrevistas realizadas com petrógrafos evidenciaram um elevado viés de interpretação na etapa de criação de rótulos. Estes rótulos, quando submetidos a análises por aprendizado de máquina, irão compor o *dataset* de treinamento. As avaliações dos modelos preditivos, portanto, podem ser afetadas por este viés, dado ao fato da influência no treinamento do modelo final, e de sua presença na criação do *dataset* de teste. Este mesmo viés também ocorre para a própria atividade de análise petrográfica tradicional. Sem uma ferramenta analítica de uso comum, o resultado é uma grande divergência entre as análises registradas em bancos de dados. Os modelos treinados permitem uma padronização do viés interpretativo ao ser aplicado em novas imagens, além de destacarem os pontos de discordância, o que permite direcionar os esforços de uniformização. Uma alternativa para gerenciar estes *datasets* compostos por instâncias que podem apresentar alto viés de interpretação seria o treinamento de modelos com a utilização de dois ou mais rótulos para uma mesma imagem.

REFERÊNCIAS BIBLIOGRÁFICAS

ADOBE DEVELOPERS ASSOCIATION; 1992. TIFF Revision 6.0 Final. *Adobe Systems Incorporated*.

ADOBE DEVELOPERS ASSOCIATION. Adobe PageMaker 6.0 – TIFF Technical Notes. *Adobe Systems Incorporated*, 1995.

ADOBE DEVELOPERS ASSOCIATION. Adobe Photoshop – TIFF Technical Notes. *Adobe Systems Incorporated*, 2002.

ADLER, M.; BOUTELL, T.; BOWLER, J.; BRUNSCHEN, C.; COSTELLO, A.M.; CROCKER, L.D.; DILGER, A.; FROMME, O.; GAILLY, J.; HERBORTH, C.; JAKULIN, A.; KETTLER, N.; LANE, T.; LEHMANN, A.; LILLEY, C.; MARTINDALE, D.; MORTENSEN, O.; PICKENS, K.; POOLE, R.; RANDERS-PEHRSON, G.; ROELOFS, G.; SCHAIK, W.; SCHALNAT, G.; SCHIMIDT, P.; STOKES, M.; WEGNER, T.; WOHL, J. PNG (Portable Network Graphics) Specification, Version 1.2. Editores: Randers-Pehrson, G.; Boutell, T.; Editores contribuidores: Costello, A.M.; Lane, T.; *World Wide Web Consortium*, 1999.

ADLER, M.; BOUTELL, T.; BOWLER, J.; BRUNSCHEN, C.; COSTELLO, A.M.; CROCKER, L.D.; DILGER, A.; FROMME, O.; GAILLY, J.; HERBORTH, C.; JAKULIN, A.; KETTLER, N.; LANE, T.; LEHMANN, A.; LILLEY, C.; MARTINDALE, D.; MORTENSEN, O.; PICKENS, K.; POOLE, R.; RANDERS-PEHRSON, G.; ROELOFS, G.; SCHAIK, W.; SCHALNAT, G.; SCHIMIDT, P.; STOKES, M.; WEGNER, T.; WOHL, J. Portable Network Graphics (PNG) Specification. Information technology — Computer graphics and image processing — Portable Network Graphics (PNG): Functional specification. ISO/IEC 15948:2003 (E). Editor: Duce, D.; *Oxford Brookes University*, 2nd ed., 2003.

AHR, W.M. Geology of Carbonate Reservoirs: the Identification, Description, and Characterization of Hydrocarbon Reservoirs in Carbonate Rocks, 1a ed. John Wiley & Sons, Inc., Hoboken, Nova Jersey, 2008.

Disponível em: <<https://doi.org/10.1002/9780470370650>>.

AL-BULUSHI, N.I., KING, P.R., BLUNT, M.J., KRAAIJVELD, M. Artificial neural networks workflow and its application in the petroleum industry. *Neural Comput. Appl.*, vol. 21, n. 3, 409–421, 2012.

Disponível em: <<https://doi.org/10.1007/s00521-010-0501-6>>.

ANEMANGELY, M., RAMEZANZADEH, A., BEHBOUD, M.M. Geomechanical parameter estimation from mechanical specific energy using artificial intelligence. *J. Pet. Sci. Eng.*, vol. 175, 407–429, 2019.

Disponível em: <<https://doi.org/10.1016/j.petrol.2018.12.054>>.

ANJOS, S.M.C.; SOUZA, R.S.; BLAETH, M.; RODRIGUES, C.R.O.; SOUZA, A.L.S. Análise de imagens no estudo do sistema poroso de rochas-reservatório. *Boletim de Geociências da Petrobras*, vol. 9, n. 2-4, 157-173. Rio de Janeiro, Brasil, 1995.

ANSELMETTI, F.S.; LUTHI, S.; EBERLI, G.P. Quantitative characterization of carbonate pore systems by digital image analysis. *AAPG Bulletin*, vol. 82, 1815-1836, 1998.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. Redes Neurais Artificiais: Teoria e Aplicações. *Livros Técnicos e Científicos Editora S.A.*. Rio de Janeiro, Brasil, 2001.

BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R.; STONE, C. Classification and Regression Trees. *Wadsworth*, Nova Iorque, 1984.

BREIMAN, L. Bagging predictors. *Machine Learning*, vol. 24, 123-140, 1996.

BREIMAN, L. Random forests. *Machine Learning*, vol. 45, 5–32, 2001.

BROWN, M.A.; LOWE, D.G. Automatic panoramic image stitching using invariant features. *Int. J. Comput. Vis.*, vol. 74, n. 1, 59–73, 2007.

Disponível em: <<https://doi.org/10.1007/s11263-006-0002-3>>.

BUADES, B.C.A.; MOREL, J.M. A non-local algorithm for image denoising. *IEEE Computer Vision and Pattern Recognition*, vol 2, 60-65, 2005.

BUDENNYI, S.; PACHEZHERTSEV, A.; BUKHAREV, A.; EROFEEV, A.; MITRUSHKIN, D. Image Processing and Machine Learning Approaches for Petrographic Thin Section Analysis. *SPE Russian Petroleum Technology Conference*, Moscou: Rússia, 2017.

CAO, F., MUSÉ, P., SUR, F. Extracting meaningful curves from images. *J. Math. Imaging Vis.*, vol. 22, n 2–3, 159–181, 2005.

Disponível em: <<https://doi.org/10.1007/s10851-005-4888-0>>.

CCITT. Recommendation T.81. Information Technology – digital compression and coding of continuous-tone still images – requirements and guidelines. *The International Telegraph and Telephone Consultative Committee*, International Telecommunication Union, 1992.

CHAUDHARI, P.; AGRAWAL, H.; KOTECHA, K. Data augmentation using MG-GAN for improved cancer classification on gene expression data. *Soft Computing*, vol. 24, 11381–11391, 2019.

CHATFIELD, K., SIMONYAN, K., VEDALDI, A., ZISSERMAN, A. Return of the devil in the details: delving deep into convolutional nets. *Proceedings of BMVC: British Machine Vision Conference*. arXiv:1405.3531v4, 2014.

CHEN, C., LIAW, A., BREIMAN, L. Using Random Forest to Learn Imbalanced Data. *Tech Reports*, n. 666. University of California, Berkeley, 2004.

CHOQUETTE, P.W.; PRAY, L.C. Geological nomenclature and classification of porosity in sedimentary carbonates. *American Association of Petroleum Geologists Bulletin*, vol. 54, n. 2, 207-250, 1970.

DAVIDSON, M.W.; LOFGREN, G.E. Photomicrography in the Geological Sciences. *Journal of Geological Education*, vol. 39, p. 403, 1991.

DE ROS, L.F. Genesis and Evolution of Aptian Pre salt Carbonate Reservoirs in Southeastern Brazilian Margin. Apresentação em: *Brazilian Petroleum Conference*, 19-21, 42 slides. Rio de Janeiro, Brasil, 2018.

DEUTSCH, L.P. Deflate Compressed Data Format Specification version 1.3. *Request for Comments 1951 at Network Working Group (IETF)*, 1996..

DIAS-BRITO, D., TIBANA, P. Calcários do Cretáceo do Brasil: um atlas, vol. 1. *UNESP - IGCE-UNESPetro*, Obra, Rio Claro, Brasil, 2015.

DUMOULIN, V.; VISIN, F. A guide to convolution arithmetic for deep learning. *ArXiv preprint*: 1603.07285, 2016.

DUNHAM, R.J. Classification of carbonate rocks according to their depositional texture. *Classification of Carbonate Rocks - a symposium* (Ham, W.E. ed.). *The American Association of Petroleum Geologists, AAPG Memoir 1*, 108-121. Tulsa, EUA., 1962.

EMBRY, A.F.; KLOVAN, J.E. A Late Devonian reef tract on northeastern Banks Island. *N.W.T.: Bulletin of Canadian Petroleum Geology*, vol. 19, 730-781, 1971.

EHRlich, R.; DAVIES, D.K. Photographic image analysis, I: analysis of reservoir pore complexes. *Journal of Sedimentary Petrology*, vol. 54, n. 4, 1365-1378. Tulsa, EUA, 1984.

EHRlich, R.; CRABTREE, S.J.; HORKOWITZ, K.O.; HORKOWITZ, J.P. Petrography and reservoir physics, I: Objective classification of reservoir porosity. *American Association of Petroleum Geologists Bulletin*, vol. 75, 1547-1562, 1991.

FLEISCHER, M.; WILCOX, R.E.; MARZKO, J.J. Microscopic determination of the nonopaque minerals. 3rd edition. *US Geological Survey Bulletin*, n. 1627, 1984.

FOLK, R.L. Practical petrographic classification of limestones. *AAPG Bulletin*, vol. 43, 1-38, 1959.

FOLK, R.L. Spectral subdivision of limestone types, *Classification of Carbonate Rocks - a symposium* (Ham, W.E. ed.). *The American Association of Petroleum Geologists, AAPG Memoir 1*, 62-84. Tulsa, EUA, 1962.

FRANK, E., HALL, M.A., WITTEN, I.H. The WEKA Workbench. Online Appendix for *Data Mining: Practical Machine Learning Tools and Techniques*, Morgan Kaufmann, 4 ed, 2016.

GEMAN, D.; GEMAN, S.; GRAFFIGNE, C.; DONG, P. Boundary detection by constrained optimization. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, n. 7, 609-628, 1990.

GOODFELLOW, I.J.; POUGET-ABADIE, J.; MIRZA, M.; XU, B.; WARDE-FARLEY, D.; OZAIR, S.; COURVILLE, A.; BENGIO, Y. Generative Adversarial Nets. *Machine Learning*, arXiv:1406.2661, 2014.

GURGEL, S.T.A. Análise de técnicas de implementação paralela para treinamento de redes neurais em GPU. *Dissertação de Mestrado: Universidade Federal da Paraíba*. João Pessoa, Brasil, 2014.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I.H. The WEKA data mining software: an update. *ACM SIGKDD Explor. Newslett.*, vol. 11, n. 1, 10–18, 2009.

Disponível em: <<https://doi.org/10.1145/1656274.1656278>>.

HAN, S.; MENG, Z.; LI, Z.; O'REILLY, J.; CAI, J.; WANG, X.; TONG, Y., Optimizing filter size in convolutional neural networks for facial action unit recognition. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018.

Disponível em: <<https://doi.org/10.1109/CVPR.2018.00532>>.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The Elements of Statistical Learning. *Springer Series in Statistics*, 2nd ed, 2009.

HERLINGER, R.; ZAMBONATO, E.; DE ROS, L.F. Influence of Diagenesis On the Quality of Lower Cretaceous Pre-salt Lacustrine Carbonate Reservoirs from Northern Campos Basin, Offshore Brazil. *Journal of Sedimentary Research*, n. 87, vol. 12, 1285-1313, 2017.

HOFMANN, T.; PUZICHA, J.; BUHMANN, J. Unsupervised texture segmentation in a deterministic annealing framework. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, n. 8, 803-818, 1998.

HOWARD, A.G. Some improvements on deep convolutional neural network based image classification. CoRR, abs/1312.5402, 2013.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximates. *Neural Netw.*, vol. 2, 359–366, 1989.

HUANG, S.C.; HUANG, Y.F. Bounds on the number of hidden neurons in multilayer perceptrons. *IEEE Trans. Neural Netw.*, vol. 2, n. 1, 47–55, 1991.
Disponível em: <<https://doi.org/10.1109/72.80290>>.

HUSH, D.R.; HORNE, B.G. Progress in supervised neural networks. *IEEE Signal Process. Mag.*, vol. 10, n. 1, 8–39, 1993.
Disponível em: <<https://doi.org/10.1109/79.180705>>.

HUSH, D.R. Classification with neural networks: a performance analysis. *IEEE International Conference of Systems Engineering*, 227–280, 1989.
Disponível em: <<https://doi.org/10.1109/ICSYSE.1989.48672>>.

IBRAHEEM, N.A.; HASAN, M.M.; KHAN, R.Z.; MISHRA, P.K. Understanding color models: a review. *ARNP Journal of Science and Technology*, vol. 2, n. 3, 265-275, 2012.

IRIE, B.; MIYAKE, S. Capabilities of three-layered perceptrons. *IEEE Int. Conf. Neural Netw.* 641–648, 1988.
Disponível em: <<https://doi.org/10.1109/ICNN.1988.23901>>.

IZADI, H.; SADRI, J.; BAYATI, M. An intelligent system for mineral identification in thin sections based on a cascade approach. *Computers & Geosciences*, vol. 99, 37-49, 2017.

JAIN, A.; FARROKHANIA, F. Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, vol. 24, n. 12, 1167-1186, 1991.

JODRY, R.L. Pore geometry of carbonate rocks - basic geologic concepts. *Oil and Gas Production from Carbonate Rocks* (Chilingar, G.V.; Mannon, R.W.; Rieke, H.H.; eds.), Elsevier, 35-82. Nova Iorque, EUA, 1972.

KHAN, S.; RAHMANI, H.; SHAH, S.A.A.; BENNAMOUN, M.; 2018. A Guide to Convolutional Neural Networks for Computer Vision. In: *Synthesis Lectures on Computer Vision #15* (eds. Medioni, G.; Dickinson, S.), Morgan & Claypool Publishers.

KOBAYASHI, T. Analyzing filters toward efficient ConvNet. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, EUA, 2018*. Disponível em: <<https://doi.org/10.1109/CVPR.2018.00589>>.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G.E. Imagenet classification with deep convolutional neural networks. *NIPS Neural Information Processing Systems*, vol. 1, 4, 2012.

ŁADNIAK, M.; MŁYNARCZUK, M. Search of visually similar microscopic rock images. *Computer & Geosciences*, vol. 19, 127-136, 2015.

LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional networks and applications in vision. *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, 2010.

Disponível em: <<https://doi.org/10.1109/ISCAS.2010.5537907>>.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE Computer Society Conference*, vol. 86, n. 11, 2278-2324, 1998.

LECUN, Y.; BENGIO, Y. Convolutional networks for images, speech, and time-series. *The Handbook of Brain Theory and Neural Networks* (Arbib, M.A., ed.), MIT Press. Boston, EUA, 1995.

LECUN, Y.; BOSER, B.; DENKER, J.S.; HENDERSON, D.; HOWARD R.E.; HUBBARD, W.; JACKEL, L.D. Backpropagation applied to handwritten zip code recognition. *Neural Computation*, vol. 1, n. 4, 541-551, 1989.

LEEVY, J.L.; KHOSHGOFTAAR, T.M.; BAUDER, R.A.; SELIYA, N. A survey on addressing high-class imbalance in big data. *Springer Journal of Big Data*, vol. 5, 42, 2018.

LIMA, B.E.M.; DE ROS, L.F. Deposition, diagenetic and hydrothermal processes in the Aptian Pre-Salt lacustrine carbonate reservoirs of the northern Campos Basin, offshore Brazil. *Sedimentary Geology*, vol. 383, 55-81, 2019.

LIMA, B.E.M.; TEDESCHI, L.R.; PESTILHO, A.L.S.; SANTOS, R.V.; VAZQUEZ, J.C.; GUZZO, J.V.P.; DE ROS, L.F. Deep-burial hydrothermal alteration of the Pre-Salt carbonate reservoirs from northern Campos Basin, offshore Brazil: Evidence from petrography, fluid inclusions, Sr, C and O isotopes. *Marine and Petroleum Geology*, vol. 113, 104143, 2020.

LIMA, B.E.M. Impacto da alteração hidrotermal na qualidade dos reservatórios carbonáticos do Pré-Sal no norte da bacia de campos. *Tese de doutorado: Programa de Pós-Graduação em Geociências, Instituto de Geociências da Universidade Federal do Rio Grande do Sul – UFRGS*. Orientador: Prof. Dr. Luiz Fernando De Ros. Porto Alegre/RS, 2020.

LUCIA, F.J. Petrophysical parameters estimated from visual descriptions of carbonate rocks: a field classification of carbonate pore space. *Journal of Petroleum Technology*, vol. 35, 629-637, 1983.

LUCIA, F.J.; Rock-Fabric/Petrophysical Classification of Carbonate Pore Space for Reservoir Characterization. *American Association of Petroleum Geologists Bulletin*, vol. 79, n. 9, 1275-1300, 1995.

MAINWARING, P.R.; PETRUCK, W. Introduction to image analysis in the earth and mineral sciences. *Image Analysis applied to mineral and earth sciences*, 156 p. Mineralogical Association of Canada. Toronto: Canadá, 1989.

MAO, J.; JAIN, A. Texture classification and segmentation using multiresolution simultaneous autoregressive models. *Pattern Recognition*, vol. 25, 173-188, 1992.

MCCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, vol. 5, 115-133, 1943.

MERCIONE, M.A.; TIRON, A.; HOLBAN, S. Dynamic modification of activation function using the backpropagation algorithm in the artificial neural networks. *Int. J. Adv. Comput. Sci. Appl.*, vol. 10, n. 4, 51–56, 2019.

Disponível em: <<https://doi.org/10.14569/IJACSA.2019.0100406>>.

MOREIRA, J.L.P.; MADEIRA, C.V.; GIL, J.A.; MACHADO, M.A.P. Bacia de Santos. *Boletim de Geociências da Petrobras*, vol. 15, n. 2, 531-549, 2007.

MORENO-BAREA, J.; STRAZZERA, F.; JEREZ, J.M. Forward Noise Adjustment Scheme for Data Augmentation. *IEEE Symposium Series on Computational Intelligence*, Bengaluru, India, 2018.

MORENO-BAREA, J.; JEREZ, J.M.; FRANCO, L. Improving classification accuracy using data augmentation on small data sets. *Expert Systems with Applications*, vol. 161, 113696, 2020.

NAIMAN, A. Color spaces and color contrast. *The Visual Computer*, vol. 1, n. 3, 194-201, 1985.

NAIR, V.; HINTON, G.E. Rectified linear units improve restricted Boltzmann machines. *Proceedings of the 27th International Conference on Machine Learning*. Haifa, Israel, 2010.

NESSE, W.D. Introduction to optical mineralogy. 3rd edition. *Oxford University Press*, Nova Iorque, EUA, 348 p, 2004.

NELSON, M. LZW Data Compression. *Dr. Dobb's Journal*, vol. 14, 1989.

NICHOLS, G. Sedimentology and Stratigraphy. *Blackwell Science Ltd*. Oxford, Reino Unido, 355 p, 1999.

ODENA, A.; OLAH, C.; SHLENS, J.; Conditional Image Synthesis with Auxiliary Classifier GANs. *Proceedings of the 34th International Conference on Machine Learning*, Sydney, Austrália, PMLR 70, 2017.

OLIVEIRA, L.A.B.; CARNEIRO, C.C. Synthetic geochemical well logs generation using ensemble machine learning techniques for the Brazilian pre-salt reservoirs. *Journal of Petroleum Science and Engineering*, n. 196, 108080, 2020.

PALEYES, A., URMA, R.G., LAWRENCE, N.D. Challenges in Deploying Machine Learning: a Survey of Case Studies. arXiv:2011.09926, 2020.

PAPATERRA, G.E.Z. Pré-Sal: conceituação geológica sobre uma nova fronteira exploratória no Brasil. *Dissertação de mestrado: Programa de Pós-Graduação em Geologia, Instituto de Geociências da Universidade Federal do Rio de Janeiro – UFRJ*. Área de Concentração: Estratigrafia e Paleontologia. Orientador: Prof. Dr. Leonardo Fonseca Borghi de Almeida. Rio de Janeiro/RJ, 2010.

PEREZ, L.; WANG, J. The Effectiveness of Data Augmentation in Image Classification using Deep Learning. *Computer Vision and Pattern Recognition*, arXiv e-prints: 1712.04621, 2017.

PERKINS, D.; HENKE, K.R. Minerals in thin section. *Pearson Education*. Nova Jersey, EUA. 163 p, 2004.

RADFORD, A.; METZ, L.; CHINTALA, S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *ICLR: The International Conference on Learning Representations*, arXiv:1511.06434v2, 2016.

RICCOMINI, C.; SANT'ANNA, L.G.; TASSINARI, C.C.G. Pré-Sal: Geologia e Exploração. *Revista USP*, n. 95, 33-42, 2012.

ROELOFS, G. PNG: The Definitive Guide. *O'Reilly & Associates*, 1999.

RUBO, R.A.; CARNEIRO, C.C.; MICHELON, M.F.; GIORIA, R.S. Digital petrography: mineralogy and porosity identification using machine learning algorithms in petrographic thin section images. *Journal of Petroleum Science and Engineering*, vol. 183, 106382, 2019.

RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. Prentice-Hall: Pearson, 3ª ed., 2009.

SAGAN, C. The demon-haunted world: science as a candle in the dark. Nova Iorque, EUA. 15ª ed.: *Random House*, 1995.

SAMUEL, A.L.; 1959. Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, vol. 3, n. 3, 210-229.
Disponível em: <<https://doi.org/10.1147/rd.33.0210>>.

SCHOLLE, P.A.; ULMER-SCHOLLE, D.S. A Color Guide to the Petrography of Carbonate Rocks: Grains, textures, porosity, diagenesis. *The American Association of Petroleum Geologists, AAPG Memoir 77*. Tulsa, EUA, 2003.

SCHINDELIN, J.; ARGANDA-CARRERAS, I.; FRISE, E.; KAYNIG, V.; LONGAIR, M.; PIETZSCH, T.; PREIBISCH, S.; RUEDEN, C.; SAALFELD, S.; SCHIMD, B.; TINEVEZ, J.Y.; WHITE, D.J.; HARTENSTEIN, V.; ELICEIRI, K.; TOMANCAK, P.; CARDONA, A. Fiji: an open-source platform for biological-image analysis. *Nature methods*, vol. 9, n. 7, 676-682, 2012.

SILVESTRINI, N.; BAUMANN, U. Colour Ideas – Color Systems in Art and Science. *Editores Baumann & Stromer*. Zurich, Suíça, 1994.

SOARES, A. A Geoestatística para as ciências da terra e do ambiente. *IST Press*, 2ª ed. Lisboa, Portugal, 2006.

SPONTÓN, H., CARDELINO, J. A review of classic edge detectors. *Image Process. Line*, vol. 5, 90–123, 2015.

Disponível em: <<https://doi.org/10.5201/ipol.2015.35>>.

SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCHE, V.; RABINOVICH, A. Going deeper with convolutions. *Computer Vision and Patter Recognition*. CVPR 2015, Proceedings of the IEEE Computer Society Conference, 2015.

SZELISKI, R. Computer Vision: Algorithms and Applications. *Texts in Computer Science*. Springer, 2010.

Disponível em: <<https://doi.org/10.1007/978-1-84882-935-0>>.

TAFNER, M.A.; XEREZ, M.; FILHO, I.W.R. Redes Neurais Artificiais: Introdução e Princípios de Neurocomputação. *EKO: Editora da FURB*. Blumenau, Brasil, 1995.

TERRA, G.J.S.; SPADINI, A.R.; FRANÇA, A.B.; SOMBRA, C.L.; ZAMBONATO, E.E.; JUSCHAKS, L.C.S.; ARIENTI, L.M.; ERTHAL, M.M.; BLAUTH, M.; FRANCO, M.P.; MATSUDA, N.S.; SILVA, N.G.C.; MORETTI JUNIOR, P.A.; D'AVILA, R.S.F.; SOUZA, R.S.; TONIETTO, S.N.; ANJOS, S.M.C.; CAMPINHO, V.S.; WINTER, W.R. Classificação de rochas carbonáticas aplicável às bacias sedimentares brasileiras. *Boletim de Geociências da Petrobras*, vol. 18, n. 1, 9-29. Rio de Janeiro, Brasil, 2010.

THOMAS, A.J.; PETRIDIS, M.; WALTERS, S.D.; GHEYTASSI, S.M.; MORGAN, R.E. Two hidden layers are usually better than one. *Commun. Comput. Inf. Sci.* 279–290, 2017.

Disponível em: <https://doi.org/10.1007/978-3-319-65172-9_24>.

THOMAS, J.E. Fundamentos de Engenharia de Petróleo. *Editores Interciência Ltda.*, 2ª ed. Rio de Janeiro, Brasil, 2004.

TOMUTSA, L.; BRINKMEYER, A.; RAIBLE, C. Determining petrophysical properties of reservoir rocks by image analysis. *National Institute for Petroleum and Energy Research*, 18 p., Bartlesville, EUA, 1990.

TURING, A.M. On Computable Numbers, with an Application to the Entscheidungsproblem. *Proceedings of the London Mathematical Society*, vol s2-42, n. 1, 230–265, 1937.

Disponível em: <<https://doi.org/10.1112/plms/s2-42.1.230>>.

WALLACE, G.K. The JPEG still picture compression standard. *IEEE Trans. Consumer Electronics*, vol. 38, n. 1, 1992.

WELCH, T.A. A Technique for High-Performance Data Compression. *Computer*, vol. 17, n. 6, 1984.

WIATOWSKI, T.; TSCHANNEN, M.; STANIC, A.; GROHS, P.; BÖLCSKEI, H. Discrete deep feature extraction: a theory and new architectures. *Proceedings of the International Conference on Machine Learning*, 2149–2158, 2016.

WITTEN, I.H.; FRANK, E.; TRIGG, L.; HALL, M.; HOLMES, G.; CUNNINGHAM, S.J. Weka: practical machine learning tools and techniques with java implementations. *Proc ICONIP/ANZIIS/ANNES99 Future Directions for Intelligent Systems and Information Sciences*, 1999.

WITTEN, I.H.; FRANK, E. Data Mining: Practical Machine Learning Tools and Techniques. 2ª ed. *Elsevier/Morgan Kaufman*, São Francisco, EUA, p.525, 2005.

WRIGHT, V.P. A revised classification of limestones. *Sedimentary Geology*, vol. 76, 177-185, 1992.

WRIGHT, V.P.; TOSCA, N.J. Geochemical model for the formation of the Pre-Salt reservoirs, Santos Basin, Brazil: implications for understanding reservoir distribution. Search and Discovery Article #51304. Adaptado de *Oral Presentation, AAPG Annual Convention & Exhibition*. Calgary, Alberta, Canadá, 19-22, 2016.

WU, R.; YAN, S.; SHAN, Y.; DANG, Q.; SUN, G. Deep Image: scaling up image recognition. *Computer Vision and Pattern Recognition*, arXiv e-prints: 1501.02876, 2015.

YAMAMOTO, J.K.; LANDIM, P.M.B. Geoestatística: conceitos e aplicações. Oficina de Textos: São Paulo/SP, 2013.

Ziv, J.; Lempel, A.; 1977. A Universal Algorithm for Sequential Data Compression. *IEEE Transactions on Information Theory*, vol. IT-23, n. 3.

Ziv, J.; Lempel, A.; 1978. Compression of Individual Sequences via Variable-Rate Coding. *IEEE Transactions on Information Theory*, vol. IT-24, n. 5.

APÊNDICE A – Compressão de arquivos de imagens de lâminas petrográficas delgadas

A aplicação dos diferentes tipos de filtros no desenvolvimento da pesquisa, associado à utilização de imagens de alta resolução das lâminas petrográficas, ocasionou na necessidade de avaliar as diferentes formas de armazenamento de dados de imagem. São muitos os formatos de arquivos digitais capazes de armazenar dados de imagens. Os mais comuns e conhecidos são arquivos TIFF, JPEG, GIF, PNG, entre outros. Essa diversidade não existe por acaso. Cada formato de arquivo apresenta características que os tornam ideais para diferentes aplicações. Para avaliar qual o formato ideal para armazenar imagens de lâminas petrográficas, é necessário a compreensão destas características.

JPEG – Joint Photographic Experts Group

O formato JPEG apresenta um algoritmo de compressão associado que utiliza a transformada discreta de cosseno (*discrete cosine transform* - DCT) para otimizar o armazenamento através de compressão com perdas (WALLACE, 1992). A busca por redundância espacial (similaridade entre um *pixel* e os *pixels* em sua vizinhança) é o principal fator na elaboração de algoritmos de compressão. A aplicação da transformada discreta de cosseno nos dados de imagem permite o aumento de similaridades entre *pixels* de um mesmo bloco. Trata-se de uma operação de multiplicação por matriz que converte dados de amplitude espacial (valores dos *pixels*) em coeficientes representando frequências espaciais. Normalmente, a operação é realizada em blocos de 8 por 8 *pixels*. Isso quer dizer que a imagem é subdividida em pequenos blocos com 64 *pixels*, contendo 64 valores de luminância (imagens em tons de cinza) ou crominância (64 valores para cada canal de imagens RGB). Após a aplicação da transformada (multiplicação por uma matriz fixa), 64 novos valores, chamados coeficientes da DCT, são obtidos para cada bloco (e para cada canal, no caso de imagens RGB).

Até esta etapa, a aplicação da transformada discreta de cosseno nos dados da imagem não ocasionou perdas. A aplicação da inversa da transformada discreta de cosseno retornaria os valores da matriz original e a imagem poderia ser formada novamente sem perdas. Entretanto, os valores dos coeficientes da DCT obtidos são

muito baixos nos últimos coeficientes (canto inferior direito da matriz), em oposição à valores altos no primeiro coeficiente e seus vizinhos mais próximos (canto superior esquerdo). Os valores muito baixos dos últimos coeficientes (canto inferior direito) podem ser desprezados (substituídos por zero) sem que ocorra grandes deformações na imagem. Isto é obtido por uma operação de quantização por matrizes pré-estabelecidas para luminância e crominância, ocasionando pequenas perdas. Com parte dos coeficientes zerados, as matrizes resultantes são compactadas com o algoritmo de *Huffman* (sem perdas) e são armazenadas no arquivo formato JPEG (CCITT, 1992).

As matrizes pré-estabelecidas para luminância e crominância foram obtidas empiricamente por CCITT (1992), baseado em experimentos de limites psicovisuais, de tal forma a obter resultados que não apresentem perdas significativas. Estes limites estão associados à sensibilidade da visão humana ao contraste. Entretanto, as matrizes não são necessariamente ajustadas para uma aplicação em particular. Por este motivo, muitos dos programas editores de imagem permitem o ajuste de parâmetros no processo de salvar arquivos no formato JPEG. Neste trabalho, os principais parâmetros foram testados em imagens de lâminas petrográficas para obtenção da máxima compressão, mantendo a qualidade da imagem adequada para aplicação dos algoritmos de aprendizado de máquina.

TIFF – Tagged Image File Format

O formato TIFF é um formato *container*, suporta dados com ou sem a aplicação de algoritmos de compressão, utiliza o espaço de cor CMYK e suporta transparências (ADOBE DEVELOPERS ASSOCIATION, 1992 e 1995). Em geral, os programas de edição de imagem salvam arquivos em formato TIFF sem a utilização de algoritmos de compressão. Nestes casos, os arquivos têm seus tamanhos condicionados ao tamanho em *pixels* da imagem, independente do conteúdo. Isso quer dizer que, uma imagem de 500 x 500 *pixels* salva em formato TIFF toda em branco apresentará o mesmo tamanho de arquivo de uma imagem de 500 x 500 *pixels* salva em formato TIFF com diversas informações de cor (exceto quando utilizado transparência ou fusão de camadas).

Alguns editores de imagens permitem a escolha de algoritmos de compressão para salvar arquivos em formato TIFF. Nestes casos, convencionalmente os

algoritmos apresentados não modificam os dados (compressão sem perda). Entretanto, é possível utilizar compressão com perda e, ainda assim, salvar os dados em formato TIFF (ADOBE DEVELOPERS ASSOCIATION, 2002). O programa *GIMP*, por exemplo, permite utilizar o método de compressão com perda JPEG para salvar arquivos no formato TIFF. Entretanto, é utilizada uma configuração padrão dos parâmetros de compressão, não sendo possível ajustá-los. Métodos de compressão sem perda são mais comumente utilizados, tais como *Pack Bits* (algoritmo RLE – *run-length encoding of data* – que armazena valor e contagem do dado repetido, lançado em 1984 no *MacPaint* para *Macintosh*; Apple, 1987), *Lempel-Ziv-Welch* (LZW: algoritmo baseado em dicionário – sequência de dados que se repetem – patenteado em 1984, porém suas patentes expiraram o que viabilizou sua ampla utilização; ZIV; LEMPEL, 1977, 1978; WELCH, 1984; NELSON, 1989), e *Deflate* (algoritmo baseado no antecessor do LZW combinado com o CCITT – algoritmo de *Huffman*, utilizado em transmissões de imagens via fax; DEUTSCH, 1996).

Por não perder informação após sucessivas gravações e por, geralmente, conter dados com compressão sem perdas, o formato TIFF é indicado para situações em que o arquivo será editado diversas vezes, contendo informações vetoriais e textos (que apresentam maior contraste com o fundo). Por utilizar o espaço de cor CMYK, é comum ser utilizado em arquivos que serão impressos, embora isso não seja atualmente um problema, pois as impressoras modernas também suportam formatos que utilizam espaço de cor RGB.

PNG – Portable Network Graphics

O formato PNG foi originalmente criado para substituir o formato GIF (*Graphics Interchange Format*). O formato GIF utiliza o algoritmo de compressão sem perdas *Lempel-Ziv-Welch* que, apesar de ter tido suas patentes expiradas, foi centro de diversas disputas judiciais. A controvérsia sobre seu uso impulsionou a pesquisa do formato PNG, que utiliza o algoritmo de compressão *Deflate*. Como demonstrado no item 3.4.2, este é o mais eficiente dos algoritmos sem perdas (ADLER et al., 1999; ROELOFS, 1999; ADLER et al., 2003).

No formato PNG, a compressão utilizando o algoritmo *Deflate* é precedida por uma etapa de filtragem sem perdas com o objetivo de realizar predição, resultando em um arquivo significativamente menor. Nesta filtragem, os dados são transformados

de tal forma que um único método de predição é aplicado para toda a imagem, mas diferentes tipos de filtros são aplicados para cada linha de forma a aumentar a eficiência da compressão. O tipo de filtro utilizado por cada linha é anexado em seu início para viabilizar a descompressão.

Além disso, o formato PNG pode armazenar opções de transparência, o que pode ser útil para compor imagens a partir de diferentes arquivos. Há, ainda, uma opção para entrelaçamento, uma técnica que permite uma visualização rápida preliminar do arquivo durante uma eventual transferência (utilizado principalmente em imagens para compartilhamento em rede).


Resultados e conclusões quanto à utilização dos diferentes formatos

A aplicação dos diferentes tipos de filtros no desenvolvimento da pesquisa, associado à utilização de imagens de alta resolução das lâminas petrográficas, ocasionou na necessidade de avaliar as diferentes formas de armazenamento de dados de imagem. São muitos os formatos de arquivos digitais capazes de armazenar dados de imagens. Os mais comuns e conhecidos são arquivos TIFF, JPEG, GIF, PNG, entre outros. Essa diversidade não existe por acaso. Cada formato de arquivo apresenta características que os tornam ideais para diferentes aplicações. Para avaliar qual o formato ideal para armazenar imagens de lâminas petrográficas, é necessário a compreensão destas características.

A forma com que os arquivos TIFF, JPEG e PNG gravam os arquivos de imagem é apresentada em detalhes. Conclui-se que o formato para armazenamento de imagens de lâminas petrográficas que maximiza a qualidade da imagem e compressão do arquivo é o JPEG. O formato JPEG apresenta um algoritmo de compressão associado que utiliza a transformada discreta de cosseno (*discrete cosine transform* - DCT) para otimizar o armazenamento através de compressão com perdas. Os parâmetros para aplicação do algoritmo de compressão são definidos por Wallace (1992) e CCITT (1992), porém, muitos programas editores de imagem permitem o ajuste destes parâmetros, viabilizando uma aplicação otimizada para cada usuário. Apesar deste formato apresentar perda de informação, esta perda pode ser desprezível, caso se escolham parâmetros de compressão adequados. Os principais parâmetros são: qualidade, amostragem, método da transformada e suavização. Dentre os quatro, o mais importante é o parâmetro de qualidade. Utilizando um

parâmetro de qualidade entre 75% e 85%, as perdas são imperceptíveis para a maioria das imagens das lâminas analisadas. Caso a imagem apresente fortes contrastes de cor, a qualidade de 85% pode ser adequada. Quando há necessidade de redução de tamanho de arquivos, a qualidade pode ser diminuída a 75% no máximo. A Figura A1 ressalta a diferença entre imagens armazenadas utilizando diferentes parâmetros de qualidade.

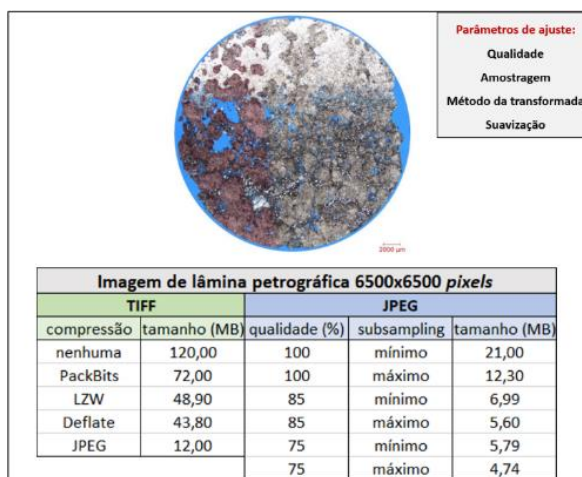
Figura A1. Imagens armazenadas em JPEG utilizando diferentes parâmetros de qualidade.



Fonte: Elaborada pelo autor.

Após testes com os parâmetros de amostragem e método de transformada observou-se que a parametrização que mais reduz o tamanho de arquivo sem prejudicar a qualidade é *máxima subamostragem* e método *Floating DCT*. O parâmetro *suavização* pode ser testado conforme a necessidade, entretanto existe pouco potencial de redução no tamanho de arquivo. A Figura A2 mostra o tamanho de arquivo de uma imagem fotomosaico nos formatos TIFF e JPEG, considerando diferentes parâmetros de compressão. Para a referida imagem, a parametrização que maximizou a qualidade de imagem e compressão de arquivo foi o formato JPEG com qualidade de 75%, *máxima subamostragem* e transformada *Floating DCT*. Para esta parametrização, a compressão foi de 20 vezes quando comparada com o formato TIFF original e de 8 vezes quando comparada com o formato TIFF *Deflate*. Isto evidencia o impacto de uma compressão otimizada no armazenamento das imagens.

Figura A2. Tamanhos de imagem fotomosaico utilizando os formatos TIFF e JPEG com vários parâmetros de compressão.




Fonte: Elaborada pelo autor.

Nas imagens segmentadas, cada segmento representa uma classe, rotulada por um número inteiro. Nestas imagens, é comum que *pixels* adjacentes sejam iguais. Desse modo, algoritmos de compressão sem perdas são os mais adequados, porque a compressão com perdas ocasiona alterações nos valores das cores e, portanto, das classes. Os melhores formatos para salvar este tipo de imagem são TIFF com compressão Deflate e PNG (compressão *Deflate* e filtragem).

A Figura A3 mostra um arquivo TIFF com tamanho original de 137 MB. Foi realizada a gravação no formato TIFF compressão *Deflate* (11,7 MB) e PNG (compressão *Deflate* e filtragem; 3,8 MB). A compressão TIFF *Deflate* reduziu por um fator de 12 vezes e a compressão PNG por um fator de 36 vezes. Logo, o formato PNG resulta na maior compressão sem perdas. Na gravação de imagens segmentadas, se o critério for maior compressão de arquivo, o formato PNG é o mais indicado.

Figura A3. Imagem segmentada de lâmina petrográfica gravada nos formatos TIFF, JPEG e PNG, com seus respectivos parâmetros.



Fonte: Elaborada pelo autor.

ANEXO A – Artigo no *Journal of Petroleum Science and Engineering*

Journal of Petroleum Science and Engineering 183 (2019) 106382



Contents lists available at ScienceDirect

Journal of Petroleum Science and Engineering

journal homepage: www.elsevier.com/locate/petrol

Digital petrography: Mineralogy and porosity identification using machine learning algorithms in petrographic thin section images

Rafael Andreello Rubo^{a,*}, Cleyton de Carvalho Carneiro^b, Mateus Fontana Michelin^a, Rafael dos Santos Gioria^b^a Petrobras – Petróleo Brasileiro S.A., Rua Marques de Herval 90, Valongo, Santos, 11010-310, São Paulo, Brazil^b Universidade de São Paulo, USP, Department of Mining and Petroleum Engineering, Praça Narciso de Andrade, Vila Mathias, Santos, 11013-560, São Paulo, Brazil

ARTICLE INFO

Keywords:

Image segmentation
Artificial neural networks
Random forest
Supervised learning
Optical mineralogy
Carbonate rocks

ABSTRACT

Images represent a large and efficient source of geological information from oil exploration. To better analyze them, well-known machine learning algorithms are used to extract mineralogy and porosity data from petrographic thin section images. Microscopic petrographic analysis allows obtaining images from thin sections in the visible spectrum. They are used to evaluate depositional environments and diagenetic processes during the formation of sedimentary basins. However, that is an activity subjected to the petrographer's experience. Data from other sources, such as chemical microanalysis, provide quantitative information that might assist in petrographic evaluation, but they are expensive and time-consuming. The main objective is to create models that systematically interprets mineralogy and porosity from images acquired of optical microscopic analysis using machine learning algorithms, standardizing descriptions and reducing subjectivity and human errors during thin sections analysis. Image segmentation models are created with representative classes of the rocks' mineralogy and porosity. Datasets were selected from images originated from thin sections of carbonate rocks, which are prepared from sidewall core samples of oil wells, specifically from the pre-salt reservoirs of Santos Basin, on the southeast coast of Brazil. These models use discrete convolutional filters followed by artificial neural networks and random forest classifiers. A number of configurations were tested, using different convolutional filters and classifier's parameters. Five models were created: 1. mineralogical model using artificial neural network; 2. mineralogical model using random forest; 3. mineralogical model using random forest validated by chemical measurements; 4. porosity model using artificial neural networks; and 5. porosity model using random forest. They were evaluated through the use of 10-fold cross-validation tests and by correlation with chemical microanalysis. Correlation between the two technique's relative occurrences for each mineral phase shows a root mean square error of 8.99% and a coefficient of determination of 0.82. That demonstrates how well models can generalize.

1. Introduction

Quantitative and qualitative analysis of petrographic thin sections from sidewall core samples have great relevance for the interpretation and evaluation of oil wells. They allow inferences related to the geological context of the petroleum system, such as interpretations of the depositional environment associated with the sedimentary basin and subsequent diagenetic alterations. However, despite this unquestionable relevance, thin section descriptions have traditionally been carried out from visual evaluations. There are few methods capable of developing automatic quantification, such as quantitative evaluation of minerals by scanning electron microscopy (QEMSCAN). However, these

methods are expensive and traditionally applied to a small number of samples. The increase in computer processing and memory capacity allows the use of robust machine learning algorithms for image analysis. These algorithms make it possible to evaluate automated methods for thin section image interpretation.

Geoscientists study the Earth by creating models that represent its processes. In order to accomplish the best results, all collected data must be thoroughly analyzed and integrated. There are many studies on the application of machine learning algorithms for analyzing data provided from airborne sensors, such as lithological (Cracknell and Reading, 2014), geophysical (Carneiro et al., 2012) and land cover (Waske et al., 2009) attributes. These data are obtained on a regional

* Corresponding author.

E-mail address: rafaelrubo@gmail.com (R.A. Rubo).<https://doi.org/10.1016/j.petrol.2019.106382>

Received 31 March 2019; Received in revised form 30 June 2019; Accepted 12 August 2019

Available online 17 August 2019

0920-4105/ © 2019 Elsevier B.V. All rights reserved.

scale. However, geological data may be derived from a local source of information, such as acoustic and resistivity image logs from wells. Valentín et al. (2018) estimated petrophysical attributes from image logs of oil wells using support vector machine algorithms. Anemangely et al. (2017, 2019a) predicted shear wave velocity using petrophysical logs based on different algorithms. An even more local source is the microscopic analysis from petrographic thin sections.

Preparing thin sections from a rock sample and analyzing them in a petrographic microscope is a relatively simple activity when compared to other analytical methods, such as x-ray diffraction analysis or scanning electron microscopy. Optical mineralogy studies the interaction of minerals with light and their optical properties in thin sections (Kerr, 1977). Each mineral observed in a thin section has its own distinct optical properties, which allow their characterization.

A great number of images is acquired from thin sections while analyzing them. If the images of a thin section cover its whole area, it is possible to create a composition of images, which is called photomosaic of a thin section (Milgram, 1975; Brown and Lowe, 2003). Many applications of quantitative methods on petrographic thin section images have been studied. Most of them are based on spatial analysis using threshold filters and simple classifiers (Ehrlich and Davies, 1984; Tomutsa et al., 1990; Anjos et al., 1995; Anselmetti et al., 1998, among others). More recent ones have been focusing on the input of extracted attributes, such as grain geometric parameters, in conventional multi-layer neural networks and other machine learning algorithms (Ladniak and Młynarczyk, 2015; Budenny et al., 2017; Izadi et al., 2017).

In this study, thin section photomosaic images were used as input data to machine learning algorithms. The objective is to create segmentation models that generate mineralogical maps or that highlight porosity of petrographic thin section images. In order to extract features from the images, computer vision approaches using convolutional kernels have been applied, increasing the number of attributes that each pixel of an image represents (Khan et al., 2018). These attributes serve as input to classifier layers. The outcome falls into one of the classes defined during training, which were either a specific mineral or pore. A new image is generated, with the same size of the original, in which each pixel receives only one attribute, consisting of the class selected by the model. This output image is a segmented version of the original input photomosaic image from the thin section, where pixels represent either a mineral phase or pore.

2. Conceptual background

2.1. Optical mineralogy

The basic principle in optical mineralogy is that most of the minerals transmit light when presented in thin slices, even if they look opaque in a hand sample (Fleischer et al., 1984; Perkins and Henke, 2004). There are a few exceptions, such as minerals with a metallic luster, that do not transmit light even when cut in thin slices. Those are called opaque minerals.

Geoscientists analyze thin sections with petrographic microscopes. The light sources from the microscopes are used for studying transmitted light from translucent minerals. They may also be equipped with a different light source for studying reflection, which is useful for the characterization of opaque minerals. The optical properties of the minerals will vary according to their composition and crystalline structure (Nesse, 2004).

2.2. Convolutions

The objective of applying convolutions in an image is to extract features through mathematical operations between functions represented by Equation (1).

$$g(x) = f(x) * h(x) = \int_{-\infty}^{\infty} f(s)h(x-s)ds \quad (1)$$

A convolutional operation may also be represented through matrices. The resulted convolved matrix is the sum of the multiplication of a larger matrix to a smaller one, also called filter. An RGB image may be decomposed into three channels. This way, an image can be represented by three matrices, one for each channel. These matrices would be equivalent to the larger matrix of a convolution operation. There is a great number of discrete convolutional filters –corresponding to the smaller matrix – that might be applied to the image, highlighting different characteristics, such as the borders of features (Khan et al., 2018).

That is the main process of interpreting images applied in the field of computer vision. Once convolutional filters have been applied to an image, each pixel contains much more information than the regular three channels. They also contain data that express the relations with their neighboring pixels.

2.3. Machine learning algorithms

There are many machine learning algorithms, each designed for analyzing data with different characteristics (Witten and Frank, 2005; Hastie et al., 2009). They may be simpler, demanding lower computational costs, or more complex, demanding high-performance computing. Usually, the more complex the algorithm, more able to analyze non-linearities it is.

2.3.1. Artificial neural networks

Artificial neural networks are mathematical models based on the neural structure of intelligent organisms, specifically the human brain (Hastie et al., 2009; Rojas, 1996). Their main characteristics are learning, generalization and abstraction capacities, which they obtain through the search of relationships, automatic construction of models and corrections based on experience, in order to reduce their own errors.

The artificial neuron has been first proposed by McCulloch and Pitts (1943). When arranged together with other artificial neurons, they work in parallel. Multilayer perceptron is the most commonly used neural network (Al-Bulushi et al., 2012) and it is structured in a way that the number of input features is the same as the number of neurons in the input layer (first layer). The output layer (last layer) has the same number of neurons as the classes of interest. Hidden layers in between and the neurons in each one of these layers may vary according to the problem characteristics (Ramchoun et al., 2016). Eq. (2) represents how neurons act on the data they receive. Neurons from the input layer receive input data (x_i) – features – through entrance terminals, which are equivalent to dendrites in a biological neuron. Distinct and variable weights (w_i) are applied to the information received by each neuron, simulating synapses. The weighted data received by each neuron are then summed with a value called bias (b). The neuron body is represented by the activation function (f_a), that will result in the output to the next layer (g). The activation function may vary, assuming the form of an identity function, binary step function, binary sigmoid, bipolar sigmoid, gaussian or linear function (Fausett, 1994; Ashrafi et al., 2019).

$$g = f_a \left(\sum_{i=1}^n (x_i \times w_i) + b \right) \quad (2)$$

The results from the first layer of neurons are the input for the next layer, where data is once again weighted and summed to bias. The activation function results go to the next layer and so on, up to the moment where data reaches the output layer and one of the classes is selected. Depending on the architecture of a neural network, that is, how artificial neurons are arranged, they may solve different sorts of

problems. The architecture establishes parameters such as the number of neuron layers, the number of nodes in a layer, and the type of connection between the nodes and the network topology. These parameters are essential on determining how well the model deals with non-linearities (Braga et al., 2000; Venables and Ripley, 2002). The choice of artificial neural network architecture is directly related to the complexity of the problem. The more layers and neurons, more complex problems – non-linear elements – the network is able to classify.

Once a network architecture has been established, the weights applied to each entry are randomly initialized. They are then, updated according to a learning algorithm. There are many learning algorithms, all of them presenting different ways of updating the weights. An error obtained after each iteration, associated with a learning rate, are the main variables for the different algorithms. The learning rate controls the steps to which the weights should be updated. The requested number of iterations during the learning process is called epochs (Russel and Norvig, 2009).

2.3.2. Random forests

These algorithms are an ensemble of a much simpler classifier: decision trees. Decision trees are a set of premises that are structured in an organized manner (Breiman et al., 1984). If the input data agrees with the first premise – root node, it goes to the next one – internal node, up to the moment that it is classified – leaves. If the data does not agree with one of the premises along the way, it follows a different path in the tree, reaching a position where it is labeled as a different class from the alternative path. The decision of following one path or the other is implemented by a binary splitting process in which a premise is progressively divided into two (Maucec et al., 2015; Singh, 2017). Eventually, a premise cannot be further divided, achieving classification (Sabah et al., 2019). The structure with which decision trees are organized depends on the impurity of the nodes (Breiman et al., 1984). These impurity factors are specific to each premise and they are called Gini Impurity, given by Eq. (3). They measure how decisive is a node to the classification of input data.

$$\text{Gini Impurity} = 1 - (\text{probability of "yes"})^2 - (\text{probability of "no"})^2 \quad (3)$$

In order to analyze input data, random forest algorithms create a diverse number of decision trees with random structures. Instead of a single restricted decision tree, random forest creates several unpruned decision trees with sequential growth. They also randomly select part of the data to serve as input to each generated tree, in a process called bootstrap aggregation, or bagging (Breiman, 1996). The class that receives more votes from the trees is the class selected by the random forest algorithm (Breiman, 2001). During bootstrap aggregation, a fixed number of features is randomly selected for all unpruned trees. The features themselves, however, may vary. This resampling process is with replacement and ensures diversification between the generated trees (Sabah et al., 2019), causing more accurate estimates considering a large number of trees.

3. Materials and methods

In order to create the image segmentation models, thin sections were prepared from sidewall core samples of three oil wells. Part of the thin sections was chemically analyzed. Images from all the thin sections were acquired on petrographic microscope and served as source for selecting and creating training data. Convolutional filters added features from neighboring pixels to the training data. Machine learning algorithms were used to create supervised models. The models were applied to new data and their ability to generalize was evaluated. The applied methodological sequence is synthesized in Fig. 1.

3.1. Materials

Petrographic thin sections used in this study were obtained from

sidewall core samples of oil wells in the pre-salt reservoirs of Santos Basin, on the southeast coast of Brazil. In order to prepare the thin sections, the samples have been first submitted to an oil cleaning and salt extraction process, assisted by solvents – toluene for oil and methanol for salts. Those processes are necessary to remove remaining fluids from the sample's porous system. That is a standard procedure when studying rocks from sedimentary basins, especially in oil and gas exploration, considering the importance of better understanding the relationship between pores and the rock framework. Then, samples are impregnated by a resin and epoxy catalyst, together with a blue dye that will fill the pores. They are glued to a thin section glass, cut and roughened to a thickness of 30–35 μm . Two sets of thin sections were prepared. The first is from 75 sidewall cores of two oil wells. The second is a smaller set, thin sections from 14 sidewall cores, all from a third well.

3.2. Analytical methods

Although the second set of thin sections is smaller, a more complete analysis of them was obtained: all 14 thin sections of the second set were chemically analyzed using QEMSCAN 650 FEI equipment with two coupled EDS/Bruker detectors. For both sets, all thin sections were analyzed in a petrographic optical microscope, where color RGB images were acquired for each thin section. Images from the first set were acquired with an objective lens of 1.25-time magnification, while the more detailed second set had images acquired with an objective lens of 2.5-times magnification. Images from each individual thin section were used to create photomosaics of them, according to the invariant local feature method proposed by Brown and Lowe (2007), in order to avoid distortions during the composition of the image. Each pixel of the images from the first set of thin sections has a 4.90 μm side. The second set images were acquired with a better resolution, each pixel has a 2.55 μm side.

3.3. Features extraction

Initial stages from the created models are convolutional. Selected pixels from the photomosaics served as input data, extracting features from the images. That is a data augmentation method which, through the use of discrete convolutional filters, aggregates information in a pixel derived from its neighboring pixels. The application of the filters is assisted by Trainable Weka Segmentation plugin from ImageJ Fiji 1.51S (Schindelin et al., 2012).

Originally, each pixel from an RGB image contains only three attributes, all related to color. These original attributes are expressed as hue, saturation and brightness. Before applying the convolutional filters, it is added an extra attribute obtained from the conversion of the RGB image to an 8-bit color image with 256 colors. It is also added an attribute labeling a mineral class or pore for each selected pixel, an essential step considering that the learning algorithm used to create the models is a supervised one. Hence, there are five non-convolutional features in each pixel.

The convolutional filters intend to aggregate spatial information to an image by adding the relationship of a pixel with its neighbors, highlighting specific characteristics such as contrasts and feature borders, depending on the filter. The selection of which convolutional filters to use was based on computer vision literature (Cao et al., 2005; Szeliski, 2010; LeCun et al., 2010; Spontón and Cardelino, 2015; Wiatowski et al., 2016; Han et al., 2018; Kobayashi, 2018). The following discrete filters were chosen: gaussian blur, sobel, hessian, difference of gaussians and membrane projections. For each filter, features are generated considering different settings for standard deviation (σ) and membrane patch size.

Gaussian blur filters are σ dependents. The greater their values, the more blurred images become. Convolutional layers from the models apply gaussian blur filters considering $\sigma_{\min} = 1$ and $\sigma_{\max} = 16$, being




Fig. 1. Synthesis of the applied methodological sequence.

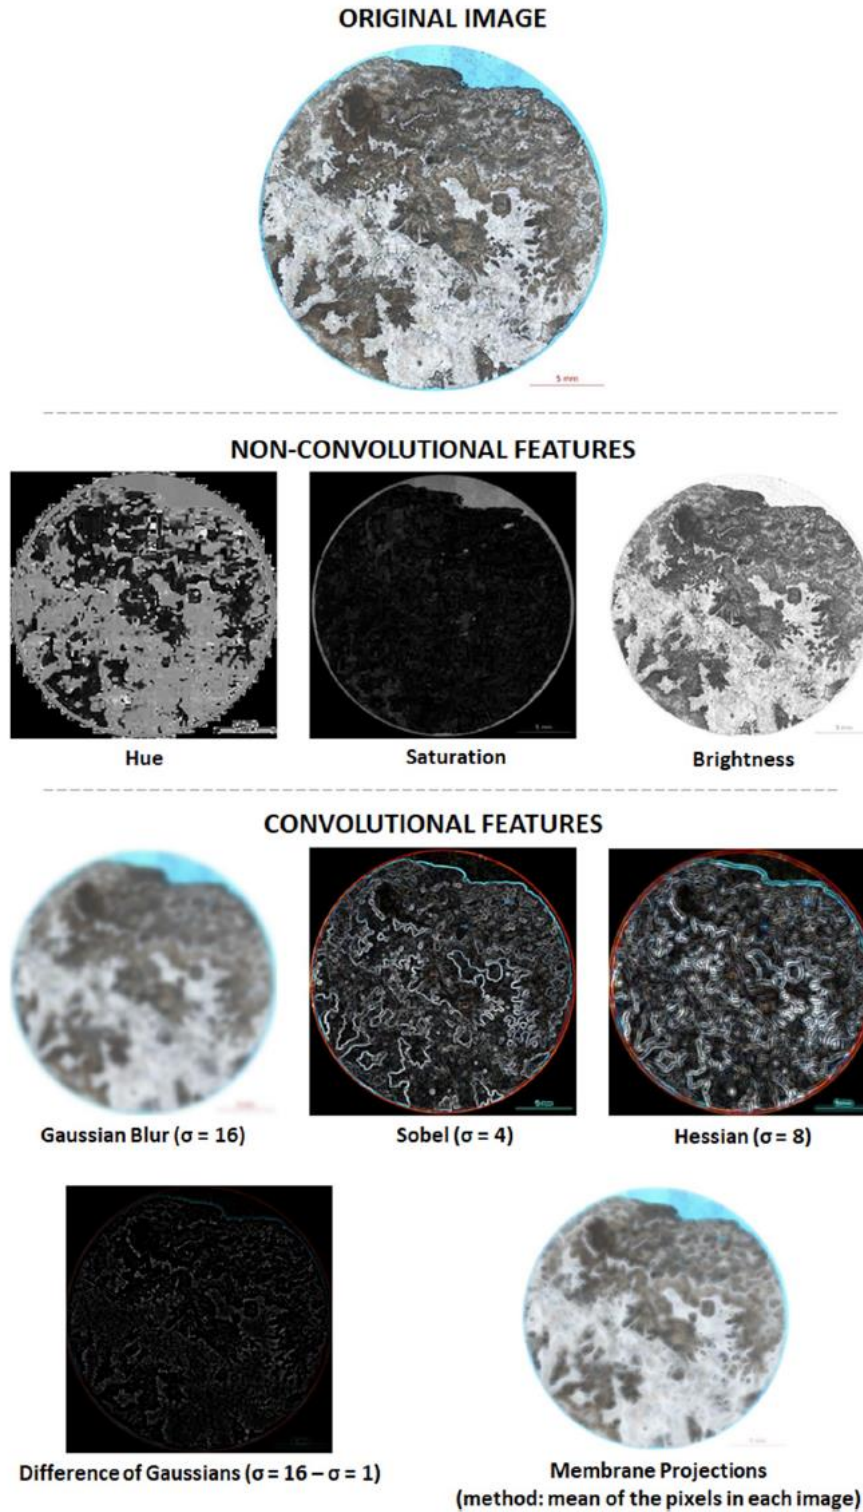


Fig. 2. Examples of features obtained using discrete convolutional filters with different parameters.

generated for σ_{min} , $2\sigma_{min}$, $4\sigma_{min}$, ..., $2^{n-1}\sigma_{min}$, where $2^{n-1}\sigma_{min} \leq \sigma_{max}$ and, therefore, $n = 5$. Sobel and hessian filters are applied from the derived gaussian blur images for each σ . Difference of gaussians filters are applied based on two gaussian blur features obtained by two different σ . Membrane projections filters are set using a 19×19 zero matrix (patch size) with the middle column entries set to 1. Rotations of this pattern totalize 30 different kernels that are convolved with the original image. The results are projected into a single image using six different methods, each one becoming a feature. Some of the features generated by different filters, with different settings, are shown in Fig. 2.

After the convolution operations, 75 convolutional features are added to each pixel. Thus, there are 80 features per pixel used as input for training machine learning models. In order to process all these data and to classify each pixel, different classifier algorithms have been tested.

3.4. Algorithm selection

Nature is filled with non-linear behaviors and responses. Rock properties are no exception. In order to classify the pixels of a thin section image into a mineral class or pore, artificial neural networks and random forest classification algorithms were applied to the convolved augmented data, using supervised learning to train the models.

Specifying correct parameters for both algorithms defines their ability to provide good results to the problem. There are many approaches for sensitivity analysis in order to investigate the best parameters to use (Al-Bulushi et al., 2012), both in neural networks and random forest. Specifically, for neural networks, in order to determine the network architecture, one approach is to start with the smallest possible network and gradually increase its size (Hush, 1989). Similar methods are applied for random forest, however, instead of increasing the size of the network, it is the number of trees that increases (Hastie et al., 2009). Test models using different numbers of trees were created in order to confirm the use of this parameter. All final models created based on random forest have 200 trees.

While random forest demand lower computational costs, neural network sensitivity analysis would be impractical, especially considering the number of variables to test. A different approach was taken: variations on the number of hidden layers and its neurons were tested based on the number of classes and attributes of the training data. Although it is theorized that one hidden layer would be sufficient for modeling continuous functions (Hornik et al., 1989; Irie and Miyake, 1988), it is shown that a large number of neurons might be needed (Huang and Huang, 1991; Hush and Horne, 1993). Adding a second layer would help in problems with greater complexities and in those which the number of neurons in one hidden layer becomes too high (Hush and Horne, 1993; Thomas et al., 2017). Considering the highly complex nature and non-linear behavior of the thin section images, it was chosen to be applied three hidden layers in all created models using neural networks. As to the number of neurons of each layer, an intermediate option proposed by Frank et al. (2016) suggests adding the number of attribute features to the number of classes and divide it by two. After the convolutional layers, all datasets have 80 features. Mineralogical models have seven classes, so they would need 43.5 neurons. Porosity models have two classes, so they would need 41 neurons. Considering these numbers, it was chosen that all created

models using neural networks would have an architecture of three hidden layers, each one with 45 neurons.

One of the most relevant parameters for a neural network is its activation function (Mercione et al., 2019). They work as filters that define how the information passes to the next layer. In all created models based on neural networks, it was used a sigmoid function, one of the most common in multilayer perceptron neural networks. Specifically, it was used a logistic function, given by Eq. (4). The learning algorithm was a gradient descent backpropagation, considering a learning rate of 0.3 and 500 epochs. This algorithm modifies the weights of the neurons in the hidden layers based on the strength of each neuron contribution to the prediction (Witten and Frank, 2005; Anemangely et al., 2019b). An ideal learning rate was obtained based on stabilization with a smaller number of epochs.

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

3.5. Application of the models

Five machine learning models were created: four for the first set of thin sections and one for the second set. They segment the photomosaics in different mineral classes and porosity. For the first set of petrographic thin sections, two of the models intended to segment mineralogical phases and the other two intended to segment specifically porosity. For the second set, one model that segments mineralogical phases was created. The Waikato Environment for Knowledge Analysis (WEKA) is a graphic interface developed by Witten et al. (1999), updated by Hall et al. (2009) and Frank et al. (2016). It was used to run different java implementations of machine learning algorithms, each with different settings. Particularly, artificial neural networks and random forests were compared.

The models classify pixel by pixel of input images creating segmented output images, where each pixel represents a mineral class or pore. Seven classes were defined for the mineralogical models: "calcite", "dolomite", "quartz", "opaque minerals", "clays", "others" and "pores". These classes were chosen based on the mineralogical background and stratigraphic context of the studied reservoirs (Moreira et al., 2007; Ahr, 2008; Terra et al., 2010; Dias-Brito and Tibana, 2015; Wright and Tosca, 2016; Lima and De Ros, 2019). It was also considered chemical microanalysis results from the second set of thin sections and limitations on the optical microscopy analysis, such as opaque minerals. Considering that the algorithms would better classify two classes instead of seven, the choice of creating models specifically for pore analysis is an attempt of obtaining results that are more accurate.

From all 75 photomosaics of the first set, 310,549 pixels (instances) were selected and labeled into one of the seven mineral classes in order to train two mineralogical models – dataset 1. Porosity models were trained with 640,965 pixels, considering only two classes: "pore" and "not-pore" – dataset 2. Two models were created for each dataset: one using neural network and the other, random forest. From the second set of thin sections – 14 photomosaics –, 479,380 pixels were selected – dataset 3. They were used to train one mineralogical model validated by chemical microanalysis, using random forest (Table 1).

Most classifiers, including neural networks and random forest, focus

Table 1
Created models with their respective algorithms, corresponding set of thin sections, and selected training data.

	Models	Algorithms	Thin Sections	Training Data
1	Mineralogical model	Artificial Neural Networks	First set (75 photomosaics)	Dataset 1 (310,549 instances)
2	Mineralogical model	Random Forest	First set (75 photomosaics)	Dataset 1 (310,549 instances)
3	Porosity Model	Artificial Neural Networks	First set (75 photomosaics)	Dataset 2 (640,965 instances)
4	Porosity Model	Random Forest	First set (75 photomosaics)	Dataset 2 (640,965 instances)
5	Mineralogical model	Random Forest	Second set (14 photomosaics)	Dataset 3 (479,380 instances)



Fig. 3. Distribution of the three training datasets according to its classes, evidencing their imbalance.

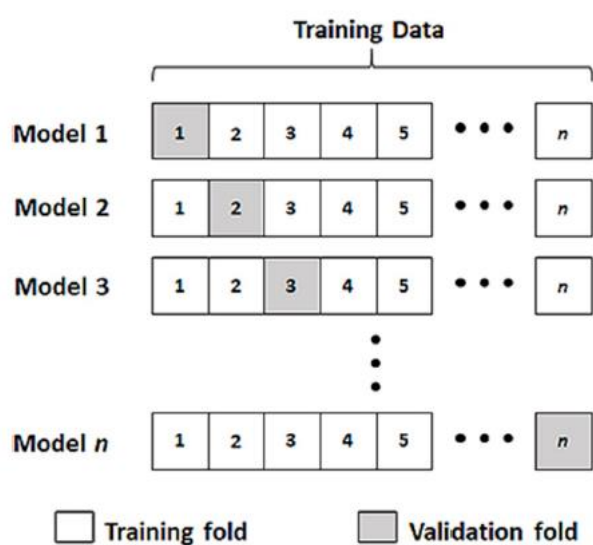


Fig. 4. n -fold cross-validation test representation.

on improving the prediction accuracy of the majority class in a training dataset, minimizing the overall error rate (Chen et al., 2004). Considering the imbalanced nature of mineral and pore occurrences, all three datasets have classes containing a minority of the data (Fig. 3). Although random forest creates trees that force less represented classes to be taken into consideration, training data from both sets of petrographic thin sections have been normalized according to an algorithm that reweights the instances (Witten et al., 1999), preventing classification from being biased by imbalance.

3.6. Evaluation

Classification error of the machine learning algorithms is usually measured by a simple training/test split of the input dataset. However, this method may be of low statistical representation. In order to evaluate if data is not being biased by overfitting and that the measure is accurate, it is used a cross-validation test: n -fold cross-validation. The training dataset is randomly divided into n non-overlapping partitions (usually 10). Repeatedly, models are generated for all n partitions using $n-1$ fold data for training and then validated on the remaining left-out fold (Fig. 4).

After this is done for all n partitions, the mean squared error (MSE) is calculated, according to Equation (5). MSE is the average of the




Fig. 5. A) Photomosaic of a thin section, partially dyed with an alizarin-based compound; B) Its segmented image obtained from the mineralogical model. The segmentation allows obtaining occurrence of each mineral phase on the thin section.




Fig. 6. A) Photomosaic of a thin section, partially dyed with an alizarin-based compound; B) Its segmented image obtained from the porosity model. The segmented pores are overlaying the original image, which is in grayscale and lightened.




Fig. 7. Accuracies and out-of-bag errors calculated for models with different number of trees, created with dataset 1 (310,549 instances).

difference between the expected value (y_i) and the predicted value (\hat{f}_i) obtained by the models, squared, for n partitions (Ashrafi et al., 2019). The squaring has the objective of preventing the negative values from canceling the positive values.

$$MSE = \frac{1}{n} \times \sum_{i=1}^n [y_i - \hat{f}_i]^2 \quad (5)$$

The number of correctly classified instances was obtained for each model using 10-fold cross-validation tests. Based on these tests, it is also obtained confusion matrices for the models. They highlight the classes in which difficulties in predicting correctly are more common. For random forest implementations, it was also possible to obtain the out-of-bag error, which is the error calculated from the data that has not been randomly chosen during the bootstrap aggregation process. These

measures of error are important not only for evaluating predictions, but also to obtain the best parameters for each model.

In order to evaluate how well models generalize to new data, instead of simply creating a test dataset and, once again, check the predictions, relative occurrences of each class and attributes obtained from them are correlated to measured occurrences and other attributes using different techniques. Correlations between these data are evaluated using root mean square error (RMSE), given by Eq. (6), and the coefficient of determination (R^2), given by Eq. (7). RMSE is calculated based on the square root of MSE. This measure of error has the advantage of bringing the values to the same unit as the compared variables. R^2 indicates how much of the variance of a variable can be explained by the other variable. It is determined by squaring the division of the covariance of the variables by the product of the two variables' standard deviation.

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n [y_i - \hat{f}_i]^2} \quad (6)$$

$$R^2 = \left(\frac{\sum (\hat{f}_i - \bar{\hat{f}}) \times (y_i - \bar{y})}{\sqrt{\sum (\hat{f}_i - \bar{\hat{f}})^2 \times \sum (y_i - \bar{y})^2}} \right)^2 \quad (7)$$

Relative occurrences were registered for each mineral phase or pore in a thin section, from the application of the models in all the photomosaics. This was possible using binary images of each class. A fixed selection for each thin section of the area of interest is used for all classes in different images. An algorithm provided by Schindelin et al. (2012) calculates the total amount of pixel of each class divided by the total amount of pixels within the fixed selection.

Based on the minerals' relative occurrence, it is possible to estimate the densities of solids (ρ_s) from the thin sections' segmented images by using an estimate of each mineral class density and applying Equation (8). The sum of the area of each mineral in a thin section (A_i) times the mineral's density (ρ_i), divided by the sum of the minerals' areas (or the

Table 2

Results from 10-fold cross-validation tests and out-of-bag errors (if applicable) for all created models.

Models	Algorithms	Correctly classified instances (10-fold cross validation test)	Out-of-bag error
1 Mineralogical model (dataset 1)	Artificial Neural Networks	97.46%	-
2 Mineralogical model (dataset 1)	Random Forest	98.78%	1.17%
3 Porosity Model (dataset 2)	Artificial Neural Networks	99.97%	-
4 Porosity Model (dataset 2)	Random Forest	99.97%	0.03%
5 Mineralogical model (dataset 3)	Random Forest	90.13%	9.71%

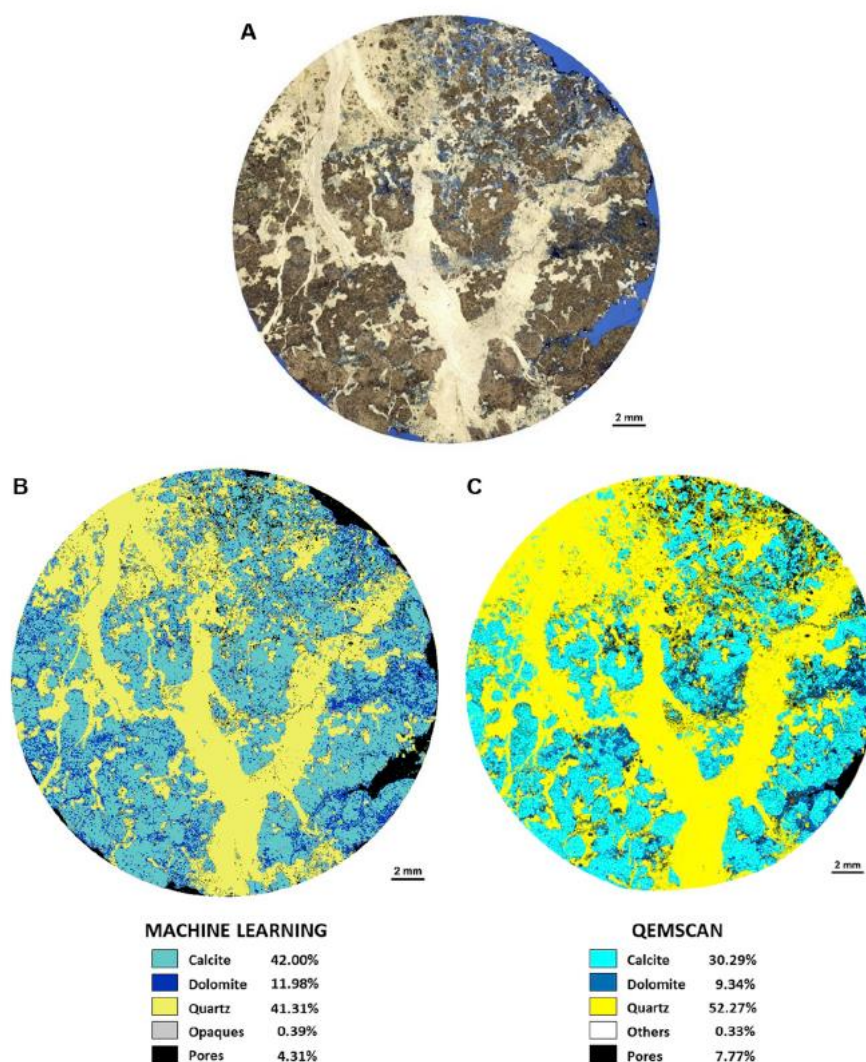


Fig. 8. A) Photomosaic of a thin section; B) Its segmented image obtained from the mineralogical model validated by chemical microanalysis from QEMSCAN equipment – the model did not detect any occurrence of the classes “clays” or “others” for this photomosaic; C) Mineralogical composition of the thin section created by interpreted QEMSCAN measures. Relative occurrences for mineral phases are presented for each method.

total area of the thin section with the exception of porous space), results in density of solids for the thin section. These thin section densities can be correlated to the densities obtained on the laboratory from their correspondent sidewall cores.

$$\rho_s = \sum (A_i \times \rho_i) / \sum A_i \quad (8)$$

For the second set of thin sections, relative occurrences of minerals are compared to the chemical microanalysis results obtained by QEMSCAN. There are significant differences between data from both techniques. While chemical microanalysis gives the exact composition from advanced scanning electron microscopy of the thin section surface, optical petrography measures the amount of transmitted light from an artificial source passing through the thin section, and then mineralogy is classified accordingly.

In order to correlate them, a few adaptations were necessary. The machine learning model class “opaque minerals” does not exist on the chemical data. From the total amount of opaque minerals classified by the model, it was subtracted the number of minerals identified by chemical microanalysis that have an opaque optical property. What was left had to be interpreted into one of the mineral classes. On carbonate rocks, calcite micritization usually gives opacity to the mineral. However, the

mineralogical model created based on the second set of thin sections was able to distinguish this micritized calcite after training. Microcrystalline quartz would eventually occur as an opaque mineral, so it was interpreted by the model as such. Considering that characteristic, what was left of opaque minerals was interpreted as quartz.

Clay minerals are identified by their exact composition on the chemical microanalysis. The machine learning model identified as “clays” whatever minerals with very fine grain characteristics, independently of their composition. From the total amount of clays classified by the model, it was subtracted the actual hydrous aluminum phyllosilicates identified by chemical microanalysis. The rest of the “clays”, just like the “opaque minerals” class, was interpreted into one of the mineral classes. According to the chemical data, these fine-grained minerals have a silicon dioxide composition, so they were also interpreted as quartz.

4. Results and discussions

4.1. Performance of the models

Datasets created based on the first set of petrographic thin sections' photomosaics originated four image segmentation models: two




Fig. 9. Correlation between density of solids obtained from the mineralogical models segmented images and from the original rock samples. The black line is a 1:1 correlation.




Fig. 10. Correlation between relative occurrences of mineral phases obtained by chemical microanalysis and by the mineralogical model created from dataset 3, for the 14 thin section photomosaics of the second set. R^2 and RMSE values were calculated considering all data as a unique class.

Table 3

RMSE and R^2 values for each class independently and the total values, considering all data as a unique series.

	Calcite	Dolomite	Quartz	Others	Pores	TOTAL
RMSE (%)	12.30	11.57	9.37	2.14	5.14	8.99
R^2	0.325	0.296	0.903	0.006	0.159	0.820

mineralogical models and two porosity models. The dataset used for both mineralogical models is the same (dataset 1), as is the dataset used for both porosity models (dataset 2). What changes is the machine learning algorithm used to classify the pixels. Fig. 5 shows the result of the application of the mineralogical model based on random forest in

one of the thin section's photomosaic. Fig. 6 highlights the result of the porosity model based on artificial neural network applied to the photomosaic of a different thin section.

Mineralogical model using neural networks had 97.46% correctly classified instances during the 10-fold cross-validation test. Considering that the training data is more than twice as big for the porosity model than for the mineralogical model, and that there are only two classes to be evaluated, the porosity model based on neural network had even better results, as expected: 99.97% correctly classified instances.

The results from models that used random forest classifiers were as good or better than the neural network models. Mineralogical model using random forest had 98.78% correctly classified instances, with an out-of-bag error of 1.17%. Porosity model using random forest had 99.97% correctly classified instances, just like the neural network model. The out-of-bag error for the porosity model was 0.03%.

A sensitivity analysis was conducted using dataset 1 in order to determine the number of trees to be used in random forest models. A total of 17 test models, with the number of trees varying from 1 to 300, showed that accuracy and errors stabilize around 140 trees (Fig. 7). Considering the investigative nature of these models, accuracy was calculated on a simple 80% train/20% test separation, instead of using 10-fold cross-validation. This analysis is in agreement with the one performed by Hastie et al. (2009), which used a dataset with similar characteristics. Ultimate models using random forest were set to use 200 trees.

The second set of petrographic thin sections also has measured chemical data, obtained from QEMSCAN equipment. Photomosaics from this set of thin sections were used to create a new dataset (dataset 3): training data was selected only where it could be validated by the chemical measurements. A mineralogical model was created based on this dataset. It used the same configuration as the best model obtained from the dataset of the first set of thin sections: random forest algorithm with 200 trees. The model had 90.13% correctly classified instances during the 10-fold cross-validation test. The out-of-bag error for this model was 9.71%. Table 2 summarizes the results for all five created models.

Fig. 8 shows a photomosaic of a thin section from the second set, its segmented image obtained from mineralogical model created from dataset 3, and its mineralogical composition interpreted from QEMSCAN measures. Although images from both methods are visually similar, relative occurrences of the minerals show that there are significant differences between the results.

4.2. Correlation with data from different techniques

Although cross-validation tests indicate accurately how well models generalize, testing the created models in new data is essential for guaranteeing their usefulness. Instead of simply selecting new instances for creating a test set, mineralogical models using random forest based on datasets 1 and 3 were applied, respectively, to 7 and 9 thin section photomosaics. Corresponding sidewall core samples from these thin sections also have a measure of density of solids.

Relative occurrences of each mineral phase from the segmented images allowed the estimation of the corresponding density of solids for each thin section. Comparing these data from two distinct techniques allows the evaluation of the models' ability to generalize, as shown in Fig. 9. The R^2 for this correlation is low, only 0.14. This could be explained by the low variability of the laboratory measured densities. Data looks scattered because there are no samples with measured densities lower than 2.68 g/cm^3 or higher than 2.8 g/cm^3 , a very strict range of variability. Still, RMSE is 0.031 g/cm^3 , which is very low. Considering these values, the models seem to predict densities of solids really well, an attribute obtained through relative occurrences. However, there is not enough data for ensuring that the models would predict well densities of solids for samples with values much lower or much higher than the ones from the 16 evaluated samples. It also




Fig. 11. A) Phosphatic fragment brighter than trained. B) Segmented image from the mineralogical model of dataset 1, using random forest. The model only classifies locally fragment's occurrence as "others" (in orange). (For interpretation of the references to color in this figure legend, the reader is referred to the Web version of this article.)




Fig. 12. A) Pore with a trapped bubble: artifact from the thin section preparation. B) Segmented image from the porosity model of dataset 2, using random forest, with transparency overlaid on the original image. The bubble represents porous space, however it is classified as "not-pore" by the model.

Table 4

Confusion matrix from the mineralogical model for the first set of thin sections, using random forest.

classified as- >	Pore	Calcite	Dolomite	Quartz	Clays	Opaque	Other	Accuracy
Pore	38,537	5	15	9	1	0	0	99.92%
Calcite	0	133,142	336	19	0	2	0	99.73%
Dolomite	0	1850	63,514	344	1	0	9	96.65%
Quartz	4	5	676	62,609	0	0	0	98.92%
Clays	0	8	6	0	3610	0	0	99.61%
Opaque	0	1	0	0	1	2407	0	99.92%
Other	0	18	286	81	0	1	3052	88.77%

Table 5

Confusion matrix from the mineralogical model for the second set of thin sections, using random forest.

classified as- >	Pore	Calcite	Dolomite	Quartz	Clays	Opaque	Other	Accuracy
Pore	57,479	64	121	170	1	0	2	99.38%
Calcite	56	113,564	6654	2141	19	13	19	92.73%
Dolomite	46	9161	54,558	10,279	134	83	63	73.41%
Quartz	31	2472	2134	181,746	1	0	30	97.50%
Clays	0	470	246	1	9435	60	0	92.39%
Opaque	8	57	31	0	12	11,064	0	99.03%
Other	58	3801	2784	6054	6	0	4235	25.00%

should be considered heterogeneities that the rock samples may present compared to the thin sections, especially for carbonate rocks. While sidewall cores allow laboratory measures of a three-dimensional rock, the models' results provide estimates based on photomosaics of 35 μm thick thin sections.

The mineralogical model based on dataset 3 allows a more detailed evaluation considering that thin sections had their chemical composition measured by QEMSCAN equipment. The chemical microanalysis is done directly over the petrographic thin section, every 10 μm , covering the same area that the model is evaluating. Correlation between relative occurrences of each mineral phase from both techniques shows how well the model is predicting each class (Fig. 10). Considering all occurrences as a unique series, the total R^2 is 0.82 and RMSE is 8.99%. While low

values of RMSE are maintained when evaluating each class independently, R^2 values are low, with the exception of "quartz" (Table 3). This occurs for the same reason that the R^2 of the density of solids correlation is low: variability of the relative occurrences for each class is low in the evaluated thin sections. Considering that silicification is quite heterogeneous throughout the samples, relative occurrences of "quartz" vary from 3.63% to 58.86%, a wide range, what causes its R^2 to be high. The model predicts relative occurrences really well, presenting low RMSE values. There is insufficient data to ensure that it would predict occurrences well for all classes if it were to be applied in thin section photomosaics with very different variability from those of the evaluated ones. Although, the high R^2 for "quartz" indicates that the model would predict well considering different occurrences for other classes.

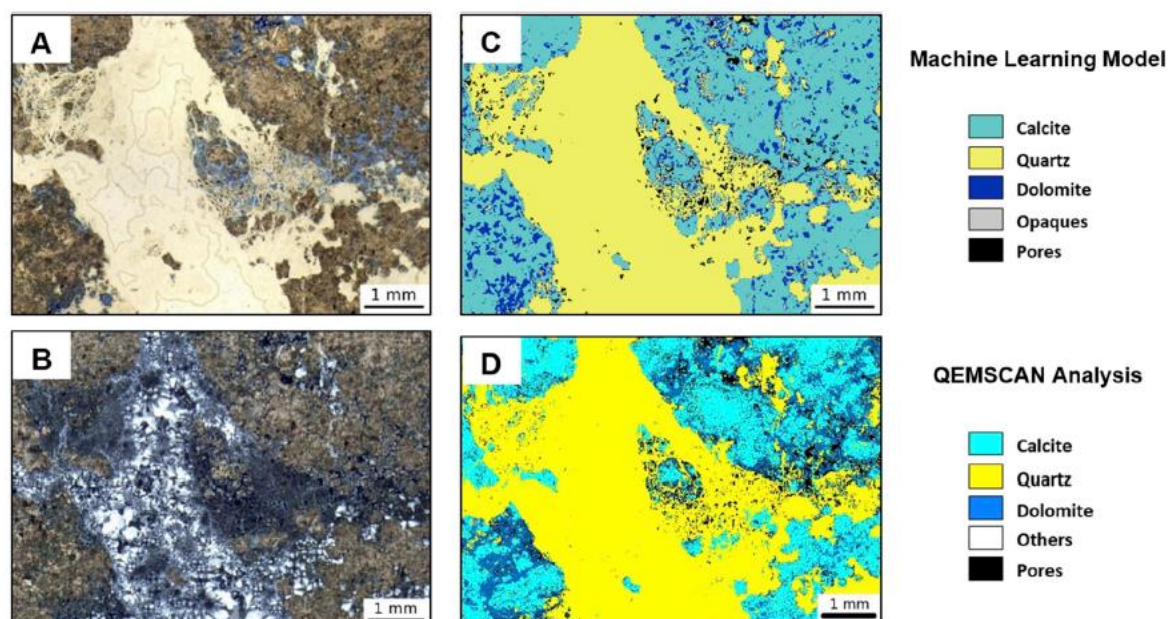


Fig. 13. Images representing the same region of a thin section. Microcrystalline quartz is commonly misclassified as dolomite or calcite. A) Petrographic image acquired using uncrossed polarizers; B) Petrographic image acquired using crossed polarizers; C) Segmented image obtained from the machine learning mineralogical model based on dataset 3; D) QEMSCAN composition interpreted from the chemical microanalysis.

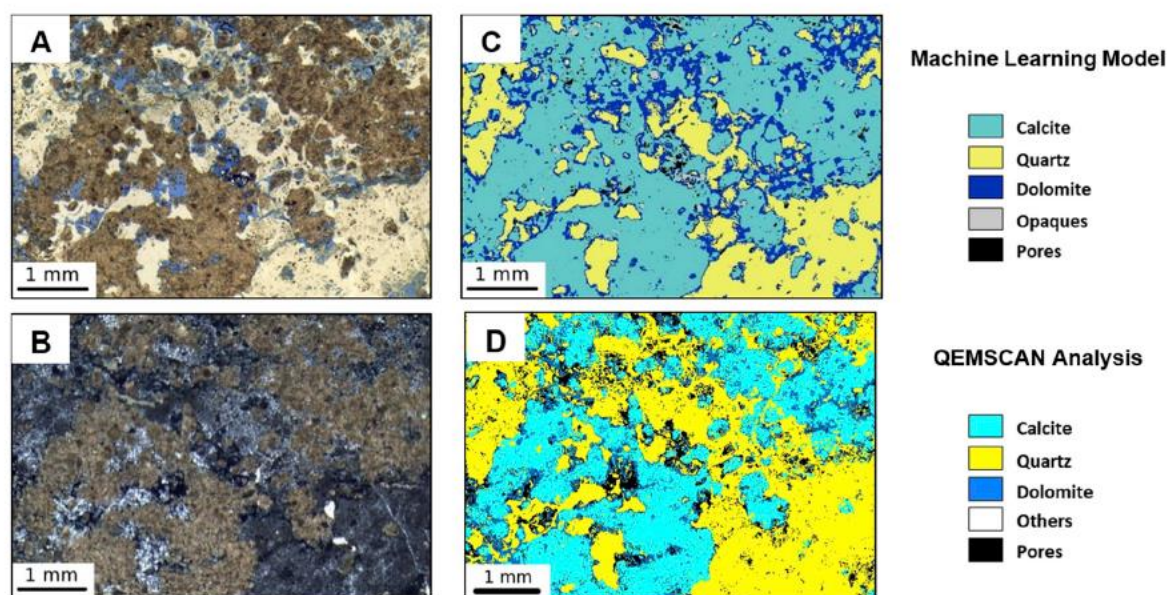


Fig. 14. Images representing the same region of a thin section. The frontier between quartz and calcite may be misclassified as dolomite, creating an inexistent coating. A) Petrographic image acquired using uncrossed polarizers; B) Petrographic image acquired using crossed polarizers; C) Segmented image obtained from the machine learning mineralogical model based on dataset 3; D) QEMSCAN composition interpreted from the chemical microanalysis.

4.3. Discussions

Although the results from artificial neural network and random forest models created for both sets of thin sections show high accuracies and low errors, they are both limited to the dataset used during training. This means that the mineralogical models will be more accurate when used in petrographic thin section images that are originated from the pre-salt section of Santos Basin, preferably from the same oil field of the samples used for training. The porosity model may be applied to whatever thin section that uses a blue dye to fill the pores during its preparation – although some variations may occur depending

on the manufacturer of the products to prepare the thin sections.

There are other important limitations that must be observed when applying the models to new data. Petrographic thin sections have a thickness varying between 30 and 35 μm , which limits the vertical resolution. This usually underestimates the occurrence of pores due to border effects and the presence of microporosity. If the thin sections are not in the standard thickness, optical properties of the minerals may be different. This would cause error on the mineralogical model. Also, during the roughening phase of the preparation, some minerals might be removed if the thin section becomes too thin. This would overestimate porosity. One of the premises for all models to work is that




Fig. 15. Images representing the same region of a thin section. Dolomite relative occurrences show an overestimation trend; however, its classification is expected to be difficult considering that the second set thin section images are not dyed by an alizarin-based compound. A) Petrographic image acquired using uncrossed polarizers; B) Petrographic image acquired using crossed polarizers; C) Segmented image obtained from the machine learning mineralogical model based on dataset 3; D) QEMSCAN composition interpreted from the chemical microanalysis.

there is sufficient light during the acquisition of the images. Exposition and white balance must be adjusted. The application of the models in images too dark or too bright may cause wrong classifications.

Some minerals may present a very broad variety of optical properties. Phosphatic fragments, for example, were trained to be classified as “others” in all mineralogical models. However, in one of the thin sections, they appeared much brighter than during training (Fig. 11). That induced the mineralogical model to classify it as “calcite”, “dolomite” and “opaque minerals”, rather than “others”. Other artifacts from thin section preparation may result in classification errors. Fig. 12 shows a bubble trapped in a pore, which has been erroneously classified as “not-pore”.

Characteristics of the porosity type also have an effect on the segmentation accuracy. Pores filled with too much clay minerals are more difficult to be segmented, considering that the frontier between clay and pore is more diffuse. In the opposite way, pores from more crystalline rocks are more easily segmented.

The confusion matrices for the mineralogical models created from datasets 1 and 3 (Tables 4 and 5), both using random forest, show that the majority of misclassified data is related to the class “others”, which groups uncommon minerals for the studied rocks, such as dawsonite and apatite occurrences. That is to be expected, considering the unusual aspect of these mineral phases in the rock framework. They usually occur with similar petrographic characteristics of more common minerals.

That misclassification is even more clear on the model created from dataset 3. Considering that training data from dataset 1 was selected without chemical data validation, minerals that were used for training the class “others” were clearly identifiable by petrographic analysis, even though they carried similarities to the more common minerals. Pixels selected for training the class “others” on dataset 3 were first identified by chemical microanalysis and might have been ignored in a

regular petrographic analysis.

The confusion matrix for the model based on dataset 3 highlights difficulties in classifying dolomite. That is also an issue for regular petrographic analysis. It is usually used an alizarin-based compound that dyes calcite minerals, but not dolomite. Photomosaics from the first set of thin sections – used for dataset 1 – were obtained from partially dyed thin sections, but none from the second set – used for dataset 3 – were.

Mineral phases relative occurrences correlation between mineralogical model and QEMSCAN analysis shows trends that slightly overestimate “dolomite”, as opposed to a slightly underestimation of “quartz”. That is consistent with the correlation between densities of solids, in which the average calculated densities from the models' images is slightly higher than the laboratory measures – dolomite has a higher density than quartz. Considering distortions on thin section images due to the lenses curvature and the difference in the corresponding size from the images' pixels, segmented images from the machine learning mineralogical model and the results from the chemical microanalysis were not registered. Although it is not possible to obtain a pixel by pixel analysis of the result, it is possible to visualize these trends and draw conclusions based on their similarities (Figs. 13–15). Frontiers between different mineral phases may be misclassified due to border effects, together with limitations on image resolution. Specifically, on the frontier between quartz and calcite, there may be classified an inexistent coating of dolomite.

Random forest models allow an attribute importance analysis based on the average impurity index and on the number of nodes using that attribute. For all models, attributes generated by variations on the hessian convolutional filter are the most important for the classification, followed by the non-convolutional attributes. Interestingly, the least important attributes are also generated by hessian variations. In any case, the combination of different discrete convolutional filters

allows the creation of more robust models.

5. Conclusions

Creating and applying machine learning image segmentation models based on petrographic thin section images is suitable as a tool for quantitative petrographic analysis. The method used in this research may be replicated to different areas and stratigraphic contexts. However, limitations discussed for each model must be taken into consideration when applying them on new images.

Classification of each pixel is restricted to the information on the image obtained from the analytical method. Petrographic images provide information only from the transmitted light that passes through the thin sections. Models will identify features to which they have been exposed during training. Therefore, it is important to consider the origin of the dataset, especially for the mineralogical models. Porosity models are more flexible and may be applied to images of thin section that use a blue dye to fill the pores, although variations on the products used for thin section preparation might cause a more difficult classification. Images from thin sections with too many preparation artifacts will have problems segmenting correctly.

Five models have been created. They standardize descriptions and give measures of relative occurrences for each class. Mineralogical models based on dataset 1 were created using artificial neural network and random forest algorithms. Both models had very good accuracy measures in 10-fold cross-validation test: the first had 97.46% and the second had 98.78% of correctly classified instances. Porosity models based on dataset 2 were created using both algorithms as well. Considering the larger dataset and the existence of only two classes, porosity models had even better accuracies in 10-fold cross-validation test: both models, using artificial neural networks and random forest, had 99.97% of instances correctly classified. Random forest had a slight advantage over artificial neural networks on the mineralogical models.

A different mineralogical model has been created based on dataset 3, validated by chemical microanalysis. Considering the results of the previous models, random forest has been chosen as the classifier algorithm. The 10-fold cross-validation test showed 90.13% of its instances correctly classified. The lower accuracy for this model is expected: while creating dataset 3, selecting was based on the chemical microanalysis identification and some of the data might have been ignored in a regular petrographic analysis due to optical similarities between the classes. In the opposite way, creation of datasets 1 and 2 were based on selecting only data with distinct optical characteristics for each class. The lower value of correctly classified instances for the mineralogical model based on dataset 3 does not mean that the other models will be better in generalizing because 10-fold cross-validation test is based only in data from the created datasets.

Instead of simply creating test sets, that would have the same selection bias as the datasets, correlation with attributes obtained from different techniques are evaluated using RMSE and R^2 . The low RMSE values show how well models are able to predict these attributes. The R^2 values for the total mineralogical data and for the class "quartz" show how promising are the models for predicting a wide range of variability of the classes, however there is insufficient data to ensure that the models would predict well considering a wide range of variability for all classes, due to the nature of the selected samples.

According to the attribute importance analysis based on impurity indexes, variations of hessian are the best discrete convolutional filters to extract the main features of interest. However, all used filters contributed to classification. As to the definition of the better machine learning algorithm to this research purpose, it should be considered both accuracy and processing demand. Both neural networks and random forests had very good accuracy measures. Although this very small difference in terms of accuracy, random forest also has a much lower computational cost.

Acknowledgements

The authors thank three anonymous reviewers for their contributions in improving the description of the work. They are also grateful to Petrobras – Petróleo Brasileiro S.A., specifically the Scanning Electron Microscopy Laboratory, at Petrobras Research Center (CENPES). They thank Yaro Moisés Parizek Silva, for QEMSCAN data interpretation; André Bulcão, for providing the use of a DGX cluster; and André Henrique, for reviewing the manuscript of this paper. They thank the InTRA Research Group, for the discussions and guidance; and Nvidia Corporation, for a GPU Grant that donated a Titan Xp board to Universidade de São Paulo. This research was conducted under the Graduate Program from the Departamento de Engenharia de Minas e de Petróleo of Escola Politécnica, Universidade de São Paulo.

References

- Ahr, W.M., 2008. *Geology of Carbonate Reservoirs: the Identification, Description, and Characterization of Hydrocarbon Reservoirs in Carbonate Rocks*, first ed. John Wiley & Sons, Inc., Hoboken, New Jersey. <https://doi.org/10.1002/9780470370650>.
- Al-Bulushi, N.I., King, P.R., Blunt, M.J., Kraaijeveld, M., 2012. Artificial neural networks workflow and its application in the petroleum industry. *Neural Comput. Appl.* 21 (3), 409–421. <https://doi.org/10.1007/s00521-010-0501-6>.
- Anemangely, M., Ramezanzadeh, A., Tokhmechi, B., 2017. Shear wave travel time estimation from petrophysical logs using ANFIS-PSO algorithm: a case study from Ab-Teymour Oilfield. *J. Nat. Gas Sci. Eng.* 38, 373–387. <https://doi.org/10.1016/j.jngse.2017.01.003>.
- Anemangely, M., Ramezanzadeh, A., Amiri, H., Hoseinpour, S., 2019a. Machine learning technique for prediction of shear wave velocity using petrophysical logs. *J. Pet. Sci. Eng.* 174, 306–327. <https://doi.org/10.1016/j.petrol.2018.11.032>.
- Anemangely, M., Ramezanzadeh, A., Behboud, M.M., 2019b. Geomechanical parameter estimation from mechanical specific energy using artificial intelligence. *J. Pet. Sci. Eng.* 175, 407–429. <https://doi.org/10.1016/j.petrol.2018.12.054>.
- Anjos, S.M.C., Souza, R.S., Blauth, M., Rodrigues, C.R.O., Souza, A.L.S., 1995. Análise de imagens no estudo do sistema poroso de rochas-reservatório. *Bol. Geociencias Petrobras* 9 (2–4), 157–173 (Rio de Janeiro, Brazil).
- Anselmetti, F.S., Luthi, S., Eberli, G.P., 1998. Quantitative characterization of carbonate pore systems by digital image analysis. *AAPG (Am. Assoc. Pet. Geol.) Bull.* 82, 1815–1836.
- Ashrafi, S.B., Anemangely, M., Sabah, M., 2019. Application of hybrid artificial neural networks for predicting rate of penetration (ROP): a case study from Marun oil field. *J. Pet. Sci. Eng.* 175, 604–623. <https://doi.org/10.1016/j.petrol.2018.12.013>.
- Braga, A.P., Carvalho, A.P.L.F., Ludermir, T.B., 2000. *Redes Neurais Artificiais: Teoria e Aplicações. Livros Técnicos e Científicos Editora S.A.* Rio de Janeiro, Brazil, pp. 262.
- Breiman, L., 1996. Bagging predictors. *Mach. Learn.* 24, 123–140. <https://doi.org/10.1007/BF00058655>.
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Breiman, L., Friedman, J., Olshen, R., Stone, C., 1984. *Classification and Regression Trees*. Wadsworth, New York. <https://doi.org/10.1201/9781315139470>.
- Brown, M.A., Lowe, D.G., 2003. Recognising panoramas. *Proc. Ninth IEEE Int. Conf. Comput. Vis.* 2, 1218–1225. <https://doi.org/10.1109/ICCV.2003.1238630>.
- Brown, M.A., Lowe, D.G., 2007. Automatic panoramic image stitching using invariant features. *Int. J. Comput. Vis.* 74 (1), 59–73. <https://doi.org/10.1007/s11263-006-0002-3>.
- Budenny, S., Pachezhertsev, A., Bukharev, A., Erofeev, A., Mitrushkin, D., 2017. Image processing and machine learning approaches for petrographic thin section analysis. In: *SPE Russian Petroleum Technology Conference*, Moscow: Rússia, . <https://doi.org/10.2118/187885-RU>.
- Cao, F., Musé, P., Sur, F., 2005. Extracting meaningful curves from images. *J. Math. Imaging Vis.* 22 (2–3), 159–181. <https://doi.org/10.1007/s10851-005-4888-0>.
- Carneiro, C.C., Fraser, S.J., Crósta, A.P., Silva, A.M., Barros, C.E.M., 2012. Semiautomated geologic mapping using self-organizing maps and airborne geophysics in the Brazilian Amazon. *Geophysics* 77 (4), K17–K24. <https://doi.org/10.1190/geo2011-0302.1>.
- Chen, C., Liaw, A., Breiman, L., 2004. *Using Random Forest to Learn Imbalanced Data*. Tech Reports, n. 666. University of California, Berkeley.
- Cracknell, M.J., Reading, A.M., 2014. Geological mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. *Comput. Geosci.* 63, 22–33. <https://doi.org/10.1016/j.cageo.2013.10.008>.
- Dias-Brito, D., Tibana, P., 2015. *Calcários do Cretáceo do Brasil: um atlas*, vol. 1. UNESP - IGCE-UNESPetro, Obra, Rio Claro, Brazil.
- Ehrlich, R., Davies, D.K., 1984. *Photographic image analysis, I: analysis of reservoir pore complexes*. *J. Sediment. Petrol.* 54 (4), 1365–1378 (Tulsa, USA).
- Fausett, L.V., 1994. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice-Hall Eaglewood Cliffs.
- Fleischer, M., Wilcox, R.E., Marzko, J.J., 1984. *Microscopic Determination of the Nonopaque Minerals*, third ed. US Geological Survey Bulletin, pp. 1627.
- Frank, E., Hall, M.A., Witten, I.H., 2016. *The WEKA Workbench. Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques, Morgan Kaufmann*,

- fourth ed. .
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., Witten, I.H., 2009. The WEKA data mining software: an update. *ACM SIGKDD Explor. Newslett.* 11 (1), 10–18. <https://doi.org/10.1145/1656274.1656278>.
- Han, S., Meng, Z., Li, Z., O'Reilly, J., Cai, J., Wang, X., Tong, Y., 2018. Optimizing filter size in convolutional neural networks for facial action unit recognition. In: *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, . <https://doi.org/10.1109/CVPR.2018.00532>.
- Hastie, T., Tibshirani, R., Friedman, J., 2009. *The Elements of Statistical Learning*, second ed. Springer Series in Statistics. <https://doi.org/10.1007/978-0-387-84858-7>.
- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximates. *Neural Netw.* 2, 359–366.
- Huang, S.C., Huang, Y.F., 1991. Bounds on the number of hidden neurons in multilayer perceptrons. *IEEE Trans. Neural Netw.* 2 (1), 47–55. <https://doi.org/10.1109/72.80290>.
- Hush, D.R., 1989. Classification with neural networks: a performance analysis. In: *IEEE International Conference of Systems Engineering*, pp. 227–280. <https://doi.org/10.1109/ICSE.1989.48672>.
- Hush, D.R., Horne, B.G., 1993. Progress in supervised neural networks. *IEEE Signal Process. Mag.* 10 (1), 8–39. <https://doi.org/10.1109/79.180705>.
- Irie, B., Miyake, S., 1988. Capabilities of three-layered perceptrons. *IEEE Int. Conf. Neural Netw.* 641–648. <https://doi.org/10.1109/ICNN.1988.23901>.
- Izadi, H., Sadri, J., Bayati, M., 2017. An intelligent system for mineral identification in thin sections based on a cascade approach. *Comput. Geosci.* 99, 37–49. <https://doi.org/10.1016/j.cageo.2016.10.010>.
- Kerr, P.F., 1977. *Optical Mineralogy*, first ed. McGraw-Hill, New York, USA, pp. 492.
- Khan, S., Rahmani, H., Shah, S.A.A., Bennamoun, M., 2018. A guide to convolutional neural networks for computer vision. In: Medioni, G., Dickinson, S. (Eds.), *Synthesis Lectures on Computer Vision #15*. Morgan & Claypool Publishers. <https://doi.org/10.2200/S00822ED1V01Y201712COV015>.
- Kobayashi, T., 2018. Analyzing filters toward efficient ConvNet. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, . <https://doi.org/10.1109/CVPR.2018.00589>.
- LeCun, Y., Kavukcuoglu, K., Farabet, C., 2010. Convolutional networks and applications in vision. In: *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, . <https://doi.org/10.1109/ISCAS.2010.5537907>.
- 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. *Sediment. Geol.* 385, 55–81. <https://doi.org/10.1016/j.sedgeo.2019.01.006>.
- Maucec, M., Singh, A.P., Bhattacharya, S., Yarus, J.M., Fulton, D.D., Orth, J.M., 2015. Multivariate analysis and data Mining of Well-Stimulation Data by use of classification-and-regression tree with enhanced interpretation and prediction capabilities. *Soc. Pet. Eng. (SPE) Econ. Manag.* 7 (2), 60–71. <https://doi.org/10.2118/166472-PA>.
- McCulloch, W.S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.* 5, 115–133. <https://doi.org/10.1007/BF02478259>.
- Mercione, M.A., Tiron, A., Holban, S., 2019. Dynamic modification of activation function using the backpropagation algorithm in the artificial neural networks. *Int. J. Adv. Comput. Sci. Appl.* 10 (4), 51–56. <https://doi.org/10.14569/IJACSA.2019.0100406>.
- Milgram, D., 1975. Computer methods for creating photomosaics. *IEEE Trans. Comput.* C-24 (11), 1113–1119. <https://doi.org/10.1109/T-C.1975.224142>.
- Moreira, J.L.P., Madeira, C.V., Gil, J.A., Machado, M.A.P., 2007. Bacia de Santos. *Bol. Geociencias Petrobras* 15 (2), 531–549 (Rio de Janeiro, Brasil).
- Nesse, W.D., 2004. *Introduction to Optical Mineralogy*, third ed. Oxford University Press, New York, USA, pp. 348.
- Perkins, D., Henke, K.R., 2004. *Minerals in Thin Section*. Pearson Education, New Jersey, USA, pp. 163.
- Ramchoun, H., Amine, M., Idrissi, J., Ghanou, Y., Ettaouil, M., 2016. Multilayer perceptron: architecture optimization and training. *Int. J. Interact. Multimed. Artif. Intell.* 60 (1), 26–30. <https://doi.org/10.9781/ijimai.2016.415>.
- Rojas, R., 1996. *Neural Networks: a Systematic Introduction*. Springer-Verlag, Berlin, pp. 502.
- Russel, S., Norvig, P., 2009. *Artificial Intelligence: a Modern Approach*, third ed. Prentice-Hall: Pearson.
- Sabah, M., Talebkeikhah, M., Wood, D.A., Khosravian, R., Anemangely, M., Younesi, A., 2019. A machine learning approach to predict drilling rate using petrophysical and mud logging data. *Earth Sci. Inf.* 1–21. <https://doi.org/10.1007/s12145-019-00381-4>.
- Schindelin, J., Arganda-Carreras, I., Frise, E., Kaynig, V., Longair, M., Pietzsch, T., Preibisch, S., Rueden, C., Saalfeld, S., Schmid, B., Tinevez, J.Y., White, D.J., Hartenstein, V., Eliceiri, K., Tomancak, P., Cardona, A., 2012. Fiji: an open-source platform for biological-image analysis. *Nat. Methods* 9 (7), 676–682. <https://doi.org/10.1038/nmeth.2019>.
- Singh, A., 2017. Application of data mining for quick root-cause identification and automated production diagnostic of gas wells with plunger lift. *SPE Prod. Oper.* 32 (3), 279–293. <https://doi.org/10.2118/175564-PA>.
- Spontón, H., Cardelino, J., 2015. A review of classic edge detectors. *Image Process. Line* 5, 90–123. <https://doi.org/10.5201/ipmap.2015.35>.
- Szeliski, R., 2010. *Computer Vision: Algorithms and Applications*. Texts in Computer Science. Springer. <https://doi.org/10.1007/978-1-84882-935-0>.
- Terra, G.J.S., Spadini, A.R., França, A.B., Sombra, C.L., Zambonato, E.E., Juschaks, L.C.S., Arienti, L.M., Erthal, M.M., Blauth, M., Franco, M.P., Matsuda, N.S., Silva, N.G.C., Moretti Junior, P.A., D'Ávila, R.S.F., Souza, R.S., Tonietto, S.N., Anjos, S.M.C., Campinho, V.S., Winter, W.R., 2010. Classificação de rochas carbonáticas aplicável às bacias sedimentares brasileiras. *Bol. Geociencias Petrobras* 18 (1), 9–29 (Rio de Janeiro, Brasil).
- Thomas, A.J., Petridis, M., Walters, S.D., Gheytaei, S.M., Morgan, R.E., 2017. Two hidden layers are usually better than one. *Commun. Comput. Inf. Sci.* 279–290. https://doi.org/10.1007/978-3-319-65172-9_24.
- Tomutsa, L., Brinkmeyer, A., Raible, C., 1990. Determining Petrophysical Properties of Reservoir Rocks by Image Analysis. National Institute for Petroleum and Energy Research, Bartlesville, USA, pp. 18.
- Valentín, M.B., Bom, C.R., Compañ, A.L.M., Correia, M.D., Jesus, C.M., Souza, A.L., Albuquerque, M.P., Albuquerque, M.P., Faria, E.L., 2018. Estimation of permeability and effective porosity logs using deep autoencoders in borehole image logs from the Brazilian pre-salt carbonate. *J. Pet. Sci. Eng.* 170, 315–330. <https://doi.org/10.1016/j.petrol.2018.06.038>.
- Venables, W.N., Ripley, B.D., 2002. *Modern Applied Statistics with S*, fourth ed. Springer, New York, USA, pp. 495. <https://doi.org/10.1007/978-0-387-21706-2>.
- Waske, B., Benediktsson, J.A., Arnason, K., Sveinsson, J.R., 2009. Mapping of hyper-spectral AVIRIS data using machine-learning algorithms. *Can. J. Remote Sens.* 35 (1), S106–S116. <https://doi.org/10.5589/m09-018>.
- Wiatowski, T., Tschannen, M., Stanic, A., Grohs, P., Böleskei, H., 2016. Discrete deep feature extraction: a theory and new architectures. In: *Proceedings of the International Conference on Machine Learning*, pp. 2149–2158.
- Witten, I.H., Frank, E., 2005. *Data Mining: Practical Machine Learning Tools and Techniques*, second ed. Elsevier/Morgan Kaufman, San Francisco, USA, pp. 525.
- Witten, I.A., Frank, E., Trigg, L., Hall, M., Holmes, G., Cunningham, S.J., 1999. Weka: practical machine learning tools and techniques with java implementations. In: *Proc ICONIP/ANZIIS/ANNES99 Future Directions for Intelligent Systems and Information Sciences*.
- Wright, V.P., Tosca, N.J., 2016. Geochemical model for the formation of the Pre-Salt reservoirs, Santos Basin, Brazil: implications for understanding reservoir distribution. Search and Discovery Article #51304. In: *Adapted from Oral Presentation Given at AAPG Annual Convention & Exhibition*. Calgary, Alberta, Canada, June 19–22, 2016.
- Ładniak, M., Młynarczyk, M., 2015. Search of visually similar microscopic rock images. *Comput. Geosci.* 19, 127–136. <https://doi.org/10.1007/s10596-014-9459-2>.

ANEXO B – Manuscrito submetido ao *Earth Science Informatics*

Cover Letter

Carbonate lithofacies classification in optical microscopy: a data-centric approach using augmentation and GAN synthetic images

Rafael Andrello Rubo, Mateus Fontana Michelin, Cleyton de Carvalho Carneiro

Dear Editors-in-Chief,

please find the enclosed manuscript "Carbonate lithofacies classification in optical microscopy: a data-centric approach using augmentation and GAN synthetic images" which we are submitting for exclusive consideration for publication in *Earth Science Informatics*. We confirm that the submission follows all the requirements and includes all the items of the submission checklist.

The manuscript presents the metrics of models trained specifically for classifying carbonate lithofacies using Convolutional Neural Networks - CNNs. Instead of experimenting with different CNN architectures, a data-centric approach has been chosen, evaluating the effect of augmentations on the model's accuracy and generalization capabilities. These augmentations were created using spectral and geometric transformations on the original images. Synthetic images have also been created using Generative Adversarial Networks - GANs, in order to expand the training dataset and reduce data imbalance. Results showed that, by gradually applying augmentation techniques on the training dataset, models enhance their generalization capabilities evaluated by accuracy on the test dataset.

We provide the source codes in a public repository with details listed in the section "Code availability".

Thanks for your consideration.

Sincerely,

Rafael Andrello Rubo, Petrobras – Petróleo Brasileiro S.A., rafaelrubo@gmail.com, Rio de Janeiro, Brazil.

Mateus Fontana Michelin, Petrobras – Petróleo Brasileiro S.A., fontana.michelon@gmail.com, Rio de Janeiro, Brazil.

Cleyton de Carvalho Carneiro, Universidade de São Paulo – USP, cleytoncarneiro@usp.br, São Paulo, Brazil.

STATEMENTS & DECLARATIONS

Funding

No funding was received for conducting this study.

Competing interests

The authors declare they have no financial interests.

Rafael Andreello Rubo and Mateus Fontana Michelin work for Petrobras – Petróleo Brasileiro S.A., a Brazilian semi-public energy Corporation. Cleyton de Carvalho Carneiro is a Professor at Universidade de São Paulo – USP and he is the advisor of this research, which is intended as Rafael Andreello Rubo’s pursuit of a PhD.

Data availability

The data that support the findings of this study are publicly available from Agência Nacional do Petróleo, Gás Natural e Biocombustível – ANP, which is the Brazilian National Agency that regulates the Oil and Gas sector. However, requests and restrictions are applied according to Brazilian Law – ANP Resolution 757/2018.

Code availability

The codes used in the research are available at: <https://github.com/rafaelrubo/lithofaciesclassification>.

NLM filtering and all the spectral augmentation implementations were made available by Schindelin et al. (2012).

A code written in ImageJ Macro Language has been developed in order to apply all the transformations in one instance. This block of code is available in the “NLM_SpectralAugmentations.ijm” file.

All the geometric augmentations were applied using Tensorflow-Keras Python library. These transformations occur during data loading. They are available in the “GeometricAugmentations.py” file.

Synthetic images were created using a Python implementation of GANs based on Radford et al. (2016). This block of code is available in the “GANSyntheticImages.py” file.

The models were trained using a fixed CNN architecture, also using Tensorflow-Keras Python library. The code for training the models are available in the “TrainingModels.py” file.

Carbonate lithofacies classification in optical microscopy: a data-centric approach using augmentation and GAN synthetic images

Rafael Andrello Rubo^{a*}, Mateus Fontana Michelin^b and Cleyton de Carvalho Carneiro^c

^aPetrobras – Petróleo Brasileiro S.A., ORCID(s): 0000-0003-0186-2297, Rio de Janeiro, Brazil.

*Corresponding author. E-mail address: rafaelrubo@gmail.com

^bPetrobras – Petróleo Brasileiro S.A., ORCID(s): 0000-0002-5135-0583, Rio de Janeiro, Brazil.

^cUSP – Universidade de São Paulo, ORCID(s): 0000-0002-4032-200X, São Paulo, Brazil.

ARTICLE INFO

Keywords:

Digital Petrography

Convolutional Neural Networks

Generative Adversarial Networks

Image augmentation

Author Contributions Statement

Rafael Andrello Rubo: Researcher pursuing his PhD. Acquisition of images. Tagging of images. Development of the codes for generating augmentations, synthetic images and classification.

Mateus Fontana Michelin: Acquisition of images. Advisor for code development. Manuscript review.

Cleyton de Carvalho Carneiro: PhD advisor. Model evaluation. Manuscript review.

ABSTRACT

Carbonate rocks are classified based on many proposals, according to the analysis objective. Pre-Salt carbonate oil reservoirs in the Brazilian marginal basins are being evaluated considering depositional textures characteristics for its lithofacies. Considering the advances in image classification using deep learning algorithms, carbonate lithofacies classification models were trained and evaluated using Convolutional Neural Networks. They classify optical microscopy thin section images obtained from sidewall core samples. A relatively small training dataset composed of 642 instances has been modified and enlarged by a series of augmentation techniques. They include different sorts of spectral and geometric transformations on the original images. Synthetic images have also been created using Generative Adversarial Networks, in order to expand the original training dataset and reduce data imbalance between six classes: stromatolite, spherulite, laminite, grainstone, dolomite and silexite. While training data has been selected from samples of one well in a specific reservoir, test data has been gathered from two other adjacent wells from the same geological context. Results showed that, by gradually applying augmentation techniques on the training dataset, models enhance their generalization capabilities evaluated by accuracy and by test dataset. The model trained based on the original training dataset has an accuracy of only 42.24%. As augmentations are implemented, this accuracy rises, reaching 86.34% on the model trained using all the techniques. It shows that it is possible to obtain useful models based on smaller and imbalanced datasets. These results also validate the data-centric approach that has been chosen for the creation of these models.

1. Introduction

Image classification models have increased their accuracies consistently in the past decade (Deng et al. 2009; Russakovsky et al. 2015). That was accomplished by enhancing neural network's architectures and training models with greater amounts of neuron layers – deep learning. However, the application of these concepts in industrial data is not always possible. Poor quality of data and small datasets are usually observed (Paleyes et al. 2022).

In the oil and gas industry, geological characterization is essential for evaluating reservoir properties and directing exploration. Depositional and diagenetic textures are features that allow understanding the basins. Specifically, classifying lithofacies may assist in that task, simultaneously correlating with petrophysical data and providing the foundation for the basin evolutionary background. Lithofacies can be directly evaluated based on rock sampling during the well drilling. The assessment is more reliable based on how representative are the samples and the more detailed are the analysis, such as optical microscopy.

Thin sections are manufactured from sidewall core samples in order to be studied under transmitted light on optical microscopes. Images from different equipment and light source conditions are acquired by many petrographers in an oil company. These conditions result in an unstandardized dataset. There is also a bias related to the sidewall core sampling: reservoirs with potentially better petrophysical properties are more sampled than other geological formations. That bias may affect class balance during the creation of datasets.

Given this scenario, training image classification models for lithofacies identification represents a challenge not from the model architecture and implementation point of view, but from the data quality and representativeness. A data-centric approach has been chosen in order to deal with those issues. The use of filters, followed by augmentation techniques and synthetic image creation have been gradually applied and models were trained with fixed architecture, in order to evaluate the impact of these measures.

Optical microscopy analysis on carbonate thin sections enable an enhanced characterization of rock features, such as fabric, grain and particle types, pore types, depositional and diagenetic textures. These features allow the classification of these carbonate rocks considering different objectives. Lithofacies categories are proposed by many authors (Folk 1959, 1962; Dunham 1962; Embry and Klovan 1971; among others). Considering the origin of the samples used on this research, a classification proposed by Terra et al. (2010) has been used as the basis for defining the classes of the trained models. It is designed to comply specifically with Brazilian sedimentary basins features, in particular, basins focused on oil and gas exploration and production. They divide carbonate rocks into four groups, based on their

depositional textures: 1. components not bound during formation; 2. original components bound together during formation – in situ; 3. bound or not bound components – laminites; and 4. unrecognizable original texture – obliterated by diagenetic processes.

Samples used in this research are from the Pre-Salt carbonate reservoirs of Santos Basin, a southeastern marginal sedimentary basin on the coast of Brazil. Specifically, they are from the Barra Velha Formation, Guaratiba Group, which is composed of very shallow water and epicontinental sea deposits (Moreira et al. 2007).

The objective of this research is to obtain models of lithofacies predictive classification for the Pre-Salt carbonate reservoirs with high accuracies. They are trained based on a reduced, imbalanced and unstandardized dataset, applying a data-centric approach.

2. Methods

Original Dataset

The original dataset has been built based on the acquisition of 96 photomosaic images corresponding to thin sections manufactured from sidewall core samples. Samples used for training and validation were all obtained from one specific well, drilled based on a structural high identified on seismic data. Squared selections with unfixed sizes were used to create 801 instances from these photomosaic images. Then, they were all downsized to 256 x 256 pixel images. Six lithofacies categories have been defined for training the models: stromatolite, spherulite, laminite, grainstone, dolomite and silexite. The latter is not defined by Terra et al. (2010), it is an adaptation that falls into the group of unrecognizable original texture due to diagenesis. Fig. 01 presents the main characteristics for each class, along with a corresponding observation from the original dataset.

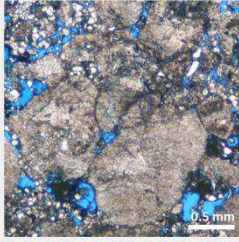
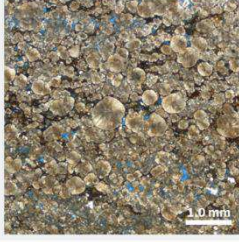
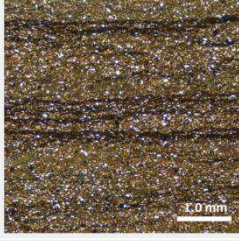
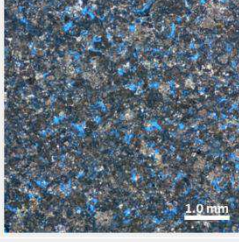
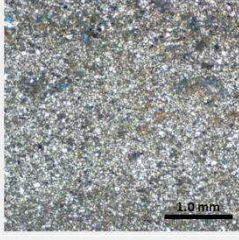
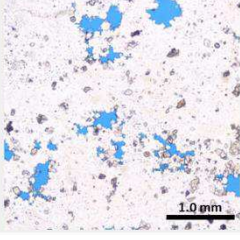
Lithofacies	Descriptions	Example images
Stromatolite	Lithofacies characterized by the presence of in situ calcite growth structures, featuring fibrous to columnar patterns. These structures are interpreted to be of microbial or chemical origin. High porosities are observed in growth framework patterns, but they may also occur in the interelement space. Porosity may be increased by diagenetic processes – such as dissolution – or decreased by them – due to cementation, usually dolomitic.	
Spherulite	These rocks consist of spherical to subspherical calcite aggregates – spherulites – generally smaller than 2 mm in size and which can occur in an amalgamated or isolated form. They may be homogeneous in terms of size or show gradation. Spherulites are the combination of spherulites occurring dispersed in material of syngenetic origin – Mg-clay minerals – or dolomites in the interelement space. Porosity is low, occasionally associated to dissolution films of organic matter.	
Laminite	Fine-grained lithofacies with smooth or crenulated flat-parallel laminated structures. Lamination is highlighted by compositional differences, alternating crystalline calcite, dolomites, Mg-clay minerals and organic matter. Porosity is low, it may occur as micropores or in a fenestral pattern, associated to dissolution processes and degradation of organic matter. Silicified laminae are a common diagenetic outcome.	
Grainstone	Rocks with components not bound during formation – reworked – with very few (lower than 5%) or no matrix. Their fabric is grain supported. These grains are made up of fragments from stromatolites, laminites, spherulites and bioclasts. They feature varied granulometry, with moderate to good selection. They are usually associated to high interparticle porosity, which may be increased by dissolution diagenetic processes.	
Dolomite	Unrecognizable original depositional textures due to dolomitization diagenetic processes. Porosity is usually low, restricted to intercrystalline space and, eventually, enlarged by vugs.	
Silexite	Hydrothermal alteration lithofacies where calcareous beds have been obliterated during diagenesis and replaced by silica. Eventually, it is possible to identify residual textures from the protolith rock, but these are insufficient to characterize a depositional lithofacies. Porosity varies. Micropores are usually present, but vugs and fractures may change most of the pore's framework.	

Fig. 01. Selected lithofacies categories for training the classification models, the description of their main features and an example out of an observation from the original dataset. The scales on the bottom right corner of the images were added later, they are not part of the dataset.

The selection size for creating instances from the photomosaics is defined by the context of the rock, considering minimum features for allowing lithofacies identification. The choice of allowing selections with unfixed sizes is related to the generalization capability of the models: by training the models without a scale parameter, any input image may be evaluated by the best model, allowing greater flexibility on its use. However, the models lose their ability to predict classes that are distinguished only by particle sizes, such as the distinction between the categories grainstone and rudstone. These lithofacies are differentiated by the grains' diameters: both are grain supported carbonate rocks with few or no matrices, however, more than 10% of the grains should have a diameter higher than 2 mm in rudstones. If they were to be included as a category of the trained models, considering the unfixed size of the selections, instances would be no different than the ones from the class grainstone. Because of that, they were not included. Rather, the class grainstone was chosen to represent reworked carbonate rocks. If the models were ever to predict an image corresponding to rudstone, it is expected that they classify it as grainstone.

As shown in Fig. 02, the dataset is highly imbalanced, due to sampling bias. Approximately 20% of the instances from the original dataset were used as a validation set, which corresponds to 159 images. Proportions between classes were respected. That split left the training dataset with only 642 images. The same imbalance proportions were maintained on the test dataset, which was created based on the dimensions of the validation dataset. Like the original dataset, the test dataset was also created using squared selections of unfixed size, and then downsized to 256 x 256 pixels. However, the source of the selections were 19 photomosaic images obtained from thin section of two other adjacent wells, both occurring in the same geological context as the one used for the original dataset. Choosing test data from adjacent wells ensures that models evaluation considers their predictive capability in the context of an oil field. Part of the imbalance from the original dataset is minimized by generating synthetic images that are added for training, also shown in Fig. 02.




Fig. 02. Original dataset distribution, highlighting training and validation sets. Test dataset distribution is also shown. Its size corresponds to approximately 20% of the original dataset and it maintains the same imbalance. Later, the training dataset has been enriched by GAN-generated synthetic images and the imbalance has been reduced.

Experiment design

As detailed in the last section, after acquiring the photomosaic images using optical microscopy for three wells, training and validation datasets were built based on squared selections of images from one of the wells. Photomosaic images from the other two wells were used to create a test dataset using the same unfixed size squared selection, in order to evaluate the model's generalization capabilities. While the test dataset remains preserved, the following transformations are gradually implemented on the training dataset: 1. a pre-convolutional filter is applied so that noise can be reduced; 2. considering the nature of the microscope images, we are proposing the nomenclature of spectral augmentation for transformations based on the displacement of a window through the visible electromagnetic spectrum, usually referred to as color augmentation; 3. geometric augmentations are applied: rotations, flipping, shifting, cropping and straining of images; 4. synthetic images are generated using GANs and enhance the original training dataset. After each transformation step, a CNN model is trained and evaluated based on the untouched test dataset, as detailed in Fig. 03.

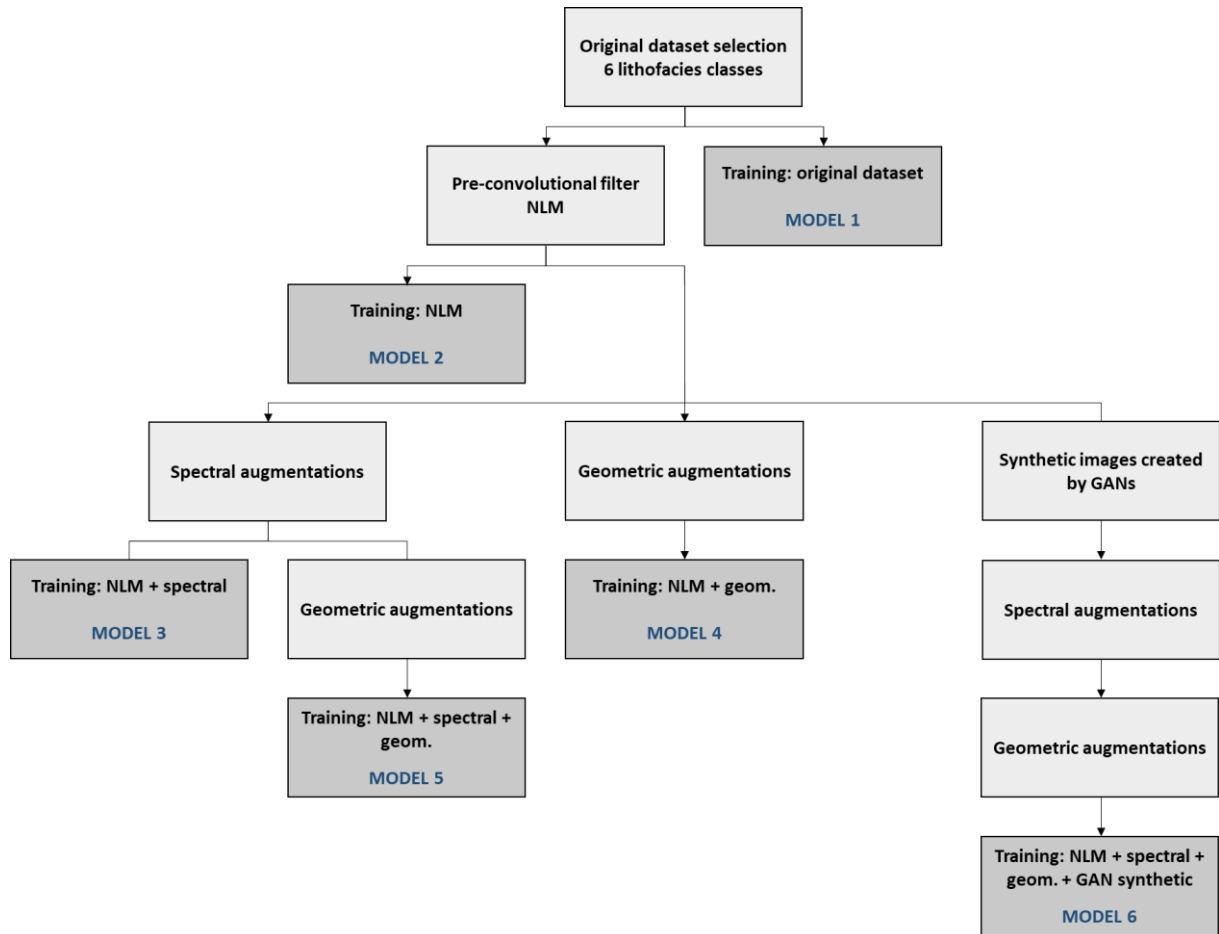


Fig. 03. General workflow for training models after each data transformation step. The following abbreviations were used: Non-Local Means (NLM), spectral augmentation techniques (spectral), geometric augmentation techniques (geom.), and synthetic images generated by Generative Adversarial Networks (GAN synthetic).

Pre-processing: Non-Local Means

The application of a pre-convolutional filter on the original images intends to enhance features of interest and eliminate what would be considered noise for lithofacies recognition. These sorts of filters have been discussed and successfully applied for many years (Geman et al. 1990; Jain and Farrokhnia 1991; Mao and Jain 1992; Hofmann et al. 1998; among others). It was used a filter proposed by Buades and Morel (2005) which is called Non-Local Means – NLM. The application of this filter is done with the use of cost functions for grouping similar pixels into homogeneous segments, minimizing mean heterogeneities.

Fig. 04 highlights the importance of the NLM application. A sobel discrete convolutional filter is applied in an original instance, and then again in the same instance after NLM filtering. Comparison between the results reveals many textural elements that have low relevance for lithofacies classification. After applying NLM to the original dataset, features of interest are highlighted and features that are considered noise for lithofacies classification are eliminated.




Fig. 04. Application of the discrete sobel convolutional filter in one of the instances from the original dataset – class spherulitite –, before and after non-local means filtering. Features highlighted after the pre-convolutional filter application are more relevant for lithofacies classification.

Data-centric approach

As discussed in the Introduction section, there are many problems in the industries' datasets, such as their sizes and quality. CNN architectures have developed considering datasets created in standardized and massive ways, such as the ones obtained by social media, cloud and streaming services. This research's training dataset has only 642 instances for 6 different classes. These instances are comprised of images obtained by different users, from different microscopes, under distinct illumination configurations. A data-centered approach is used, based on data transformations and synthetic image creation.

The first set of transformations is an augmentation technique usually referred to as color augmentation (Wu et al. 2015). Considering that the images obtained from the microscopes are acquired in the visible region of the electromagnetic spectrum, the term spectral augmentation is being proposed to refer to these transformations. It consists in creating new images from the displacement of a narrower window through the visible electromagnetic spectrum. Considering variations on the sensors of different camera manufactures, this technique supports the models to predict images whose origin are from different equipment. Its application also intends to compensate for an eventual lack of parts of the visible spectrum in the light source of the microscopes. The following pre-set configurations, made available by Schindelin et al. (2012), were used to augment the dataset: histogram equalization, contrast stretching, sharpen, RGB stretching, red color casting, green color casting, blue color casting, dichromacy deuteranope, and dichromacy tritanope. Fig. 05 shows an example of each of these configurations applied in one of the training dataset instances. Applying this set of augmentations implies that the original dataset would be instantaneously multiplied by ten.




Fig. 05. An original instance from the grainstone class – top left – followed by the pre-set configurations of spectral augmentations: histogram equalization, contrast stretching, sharpen, RGB stretching, red color casting, green color casting, blue color casting, dichromacy deuteranope, and dichromacy tritanope.

The next set of applied augmentation techniques is based on geometric transformations (LeCun et al. 1998; Krizhevsky et al. 2012; Howard 2013). By adding rotations, flipping, shifting, cropping and straining of images, positional biases in the training dataset are reduced in relation to the test dataset or to new images. That means that models are able to recognize features of interest in a new image even if they occur in places that have not been present in the original dataset. However, these transformations may change the instance category depending on its application parameters or on the nature of the dataset. For example, rotating an image corresponding to the digit 6 may result in digit 9, changing its category. That is not a problem for thin section images, considering that lithofacies remain the same, no matter the image rotations. Images were randomly rotated every 36 degrees, comprising ten possible positions. Straining of images is a different issue for rocks, though. Since rocks may actually be strained or sheared due to diagenesis or metamorphic processes, the use of this technique was made with caution, limiting the parameter angle to 0.2 radians. Width and height random shifting were limited to a region corresponding up to 30% of the total size, restricted to their borders. Whenever necessary, filling of a region used a reflection of the modified image. That filling is necessary after shifting, cropping or straining. Fig. 06 shows an example of the geometric transformations applied in one of the instances.

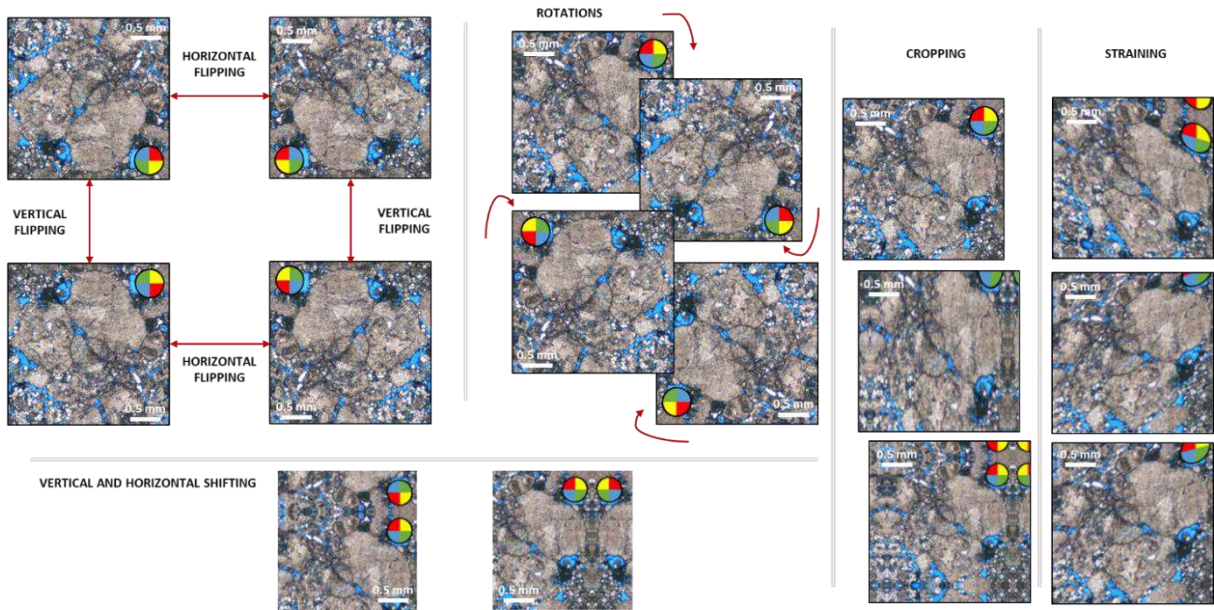


Fig. 06. Geometric augmentation techniques applied in an instance from class stromatolite: rotations, flipping, shifting, cropping and straining. A circle with the colors blue, red, yellow and green has been added to the original instance in order to highlight the effect of each transformation.

The last set of augmentation techniques used in this research was oversampling by creating synthetic images and adding them to the training dataset. These synthetic images were created using GANs. Specifically, an implementation based on an architecture of Deep Convolutional GANs (Radford et al. 2016). Fig. 07 shows an example of synthetic images generated for each class. The original dataset has been created with three channels squared images with sides of at least 256 pixels. Whenever larger, they were reduced to this size before training the models. Even though the models had 256 x 256 pixels images as input, three channels squared synthetic images were created with sides of 64 pixels, to reduce computational cost of creating larger images. That is the size that feature maps get before the model's last convolutional layer – as detailed in the next section. They were later scaled up to 256 x 256 pixels using bilinear interpolation, so they can join the training dataset. Among other techniques (Levy et al. 2018), oversampling using synthetic images is an efficient way of dealing with imbalanced datasets, by creating more synthetic images for the classes with lower amounts of instances.




Fig. 07. Example of synthetic images generated by GANs for each of the six categories: stromatolite, spherulite, laminite, grainstone, dolomite, and silicite. The images were created with lower resolutions in order to reduce computational costs. There can be no scales because they were generated based on multiple-scale images.

All these transformations in the original dataset do not necessarily imply an increase of instances for training the models. Application of NLM filter do not change the total amount of instances, since the original images are not used for training. Spectral augmentations actually increase the number of instances in a magnitude of ten: for each original image, nine new images are created and added to the dataset. This means that, after applying spectral augmentations, the training dataset has 6420 instances. Geometric augmentations are implemented in a way that the number of instances used for each epoch during training remains the same. However, the instances themselves randomly change during each epoch according to the augmentation parameters previously detailed. Even the original instances are not used, but random variations of them. Eventually, some of these variations are very similar to the original images. Thus, there is potentially the initial number of instances times the number of epochs being used for training the models. That means that, in the models that have already gone through spectral augmentation, geometric augmentations create the potential of 6420 images times the number of epochs used for training. The use of the word “potential” is due to the fact that there is always the remote statistical possibility of geometric augmentations randomly generating two or more images that are exactly the same.

CNN architecture and training

Six different models were trained using: 1. only the original dataset; 2. images from the original dataset in which NLM filter has been applied; 3. only spectral augmentation in the images that have been through NLM filtering; 4. only geometric augmentation in the images that have been through NLM filtering; 5. both spectral and geometric augmentations in the images that have been through NLM filtering; and 6. NLM filtering, spectral and geometric augmentations in images from the original dataset enlarged by synthetic images generated by GANs. To evaluate this data-centered approach, CNN architectures of all models were kept unaltered. Only training parameters, such as learning rate and epochs, were modified so that they would be adequate to each model's circumstances. These parameters were obtained based on accuracy and loss evolution evaluated during training with the validation dataset. Specific characteristics for each model are highlighted in Table 01.

Table 01. Parameters and characteristics used for training the models.

Models	Epochs	Learning rate	Transformations	Instances per epoch	Number of images during training
1	50	0.0001	None	642	642
2	50	0.0001	NLM	642	642
3	50	0.0001	NLM + spectral augmentations	6,420	6,420
4	250	0.0001	NLM + geometric augmentations	642	160,500
5	250	0.001	NLM + spectral augmentations + geometric augmentations	6,420	1,605,000
6	300	0.001	GAN synthetic images + NLM + spectral augmentations + geometric augmentations	11,060	3,318,000

The fixed CNN architecture used for all models was very simple so that the focus of this research development would not be on the models themselves, rather on the data transformation techniques. It was designed based on the original LeNet-5, proposed by LeCun et al. (1998). It was modified for receiving larger images, a larger number of dimensions and a few more layers were added (Fig. 08). The input images have 256 x 256 pixels and three-color channels. They go through a convolutional layer that generates 32 feature maps of the same size. Then, a subsampling layer using maxpooling reduces these 32 feature maps to 128 x 128 pixels. This pair convolutional-subsampling of layers is applied twice again. In the second time, the number of feature maps is maintained, but their sizes drop to 64 x 64 pixels. The last time this pair of layers is applied, it doubles the number of feature maps to 64 and reduces size to 32 x 32 pixels. After that, there is a flattening layer followed by two dense layers which will result in classification into six categories. The activation function used for all layers was ReLu, except for the last classification layer, which used Softmax.

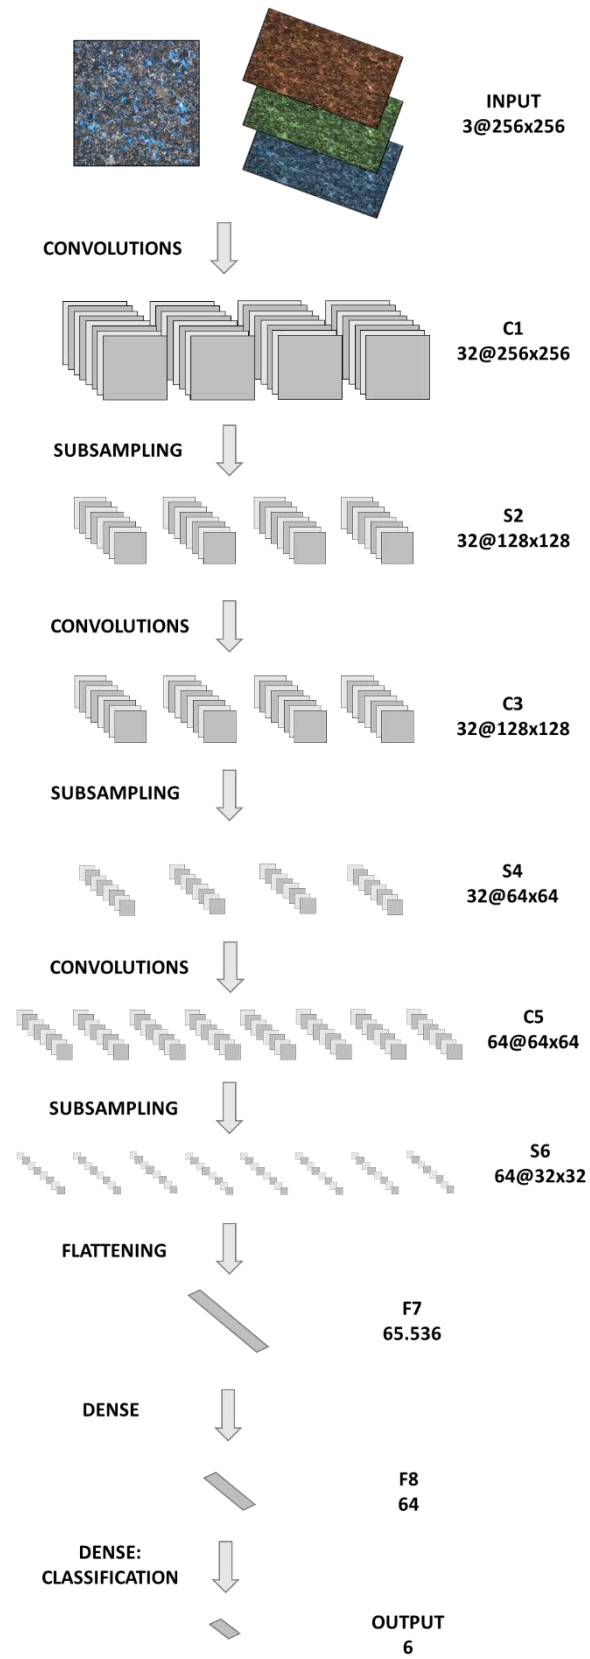


Fig. 08. Fixed CNN architecture used for all the models.

Evaluation metrics

For all models, a validation dataset has been used to calculate accuracy and loss during training. That way, ideal parameters have been chosen to respect each specific dataset's characteristics. By the end of the training, accuracy is obtained not only for validation data, but also for the test dataset with images from samples of different wells. Accuracy from the test dataset allows the evaluation of the generalization capabilities of the models. For both validation and test datasets, normalized confusion matrices are calculated to evaluate the models considering each of their output categories.

3. Results

Six models were trained, after different stages of the data augmentation techniques applied to the training dataset. They were trained and numbered according to the following dataset characteristics: Model 1 – original dataset; Model 2 – NLM filtering; Model 3 – NLM filtering followed only by spectral augmentations; Model 4 – NLM filtering followed only by geometric augmentations; Model 5 – NLM filtering followed by spectral and geometric augmentations; Model 6 – NLM filtering applied on the original training dataset enhanced with synthetic images followed spectral and geometric augmentations. All of them used the same CNN architecture.

Accuracies from all models based on validation (Fig. 09) and test data (Fig. 10) have been plotted, so that the evolution after applying different transformation techniques is highlighted. Except for spectral augmentations applied alone with NLM filtering, there is a general increase in accuracy as different sets of transformations are applied and added as training data. While using only the original dataset for training the model, the accuracy result for test data is very low: 42.24%. When all transformations are implemented, test data shows a result of 86.34% of accuracy. That accuracy is evaluating the generalization capabilities of the models, considering the images for test data have been obtained from adjacent wells and were never part of any model training.




Fig. 09. Accuracy evolution for validation data, calculated as the transformations were applied in the training dataset.




Fig. 10. Accuracy evolution for test data, calculated as the transformations were applied in the training dataset.

Models' accuracies allow comparing them. But even though it is an important metric, a single value of accuracy for each model is not enough for characterizing them in a more detailed manner. To evaluate which classes are actually being more efficiently classified, normalized confusion matrices have been plotted for validation and test data of all trained models. As transformations are applied, it is possible to observe predictions leaning towards the main diagonal. The models start out poorly classifying all classes (Fig. 11A). Even for the validation data, predictions are far from converging to the true label. After applying NLM (Fig. 11B) and NLM followed by spectral augmentations (Fig. 11C),

the class silixite is solved and accuracies reach at least 97% for this class. The application of NLM together only with geometric augmentations does not improve much concerning the previous models: even though validation data predictions get somewhat closer to the main diagonal, test data predictions are still scattered, except for silixite (Fig. 11D). Total accuracy of the model where NLM, spectral and geometric augmentations are applied rises to 87.55% for validation data and 73.29% for test data. These higher accuracies are reflected on the confusion matrices (Fig. 11E). The model trained with all augmentation techniques and synthetic images has predictions converging to the main diagonal for both validation and test data. Classes that have more difficulties in being correctly classified are spherulite and stromatolite (Fig. 11F).

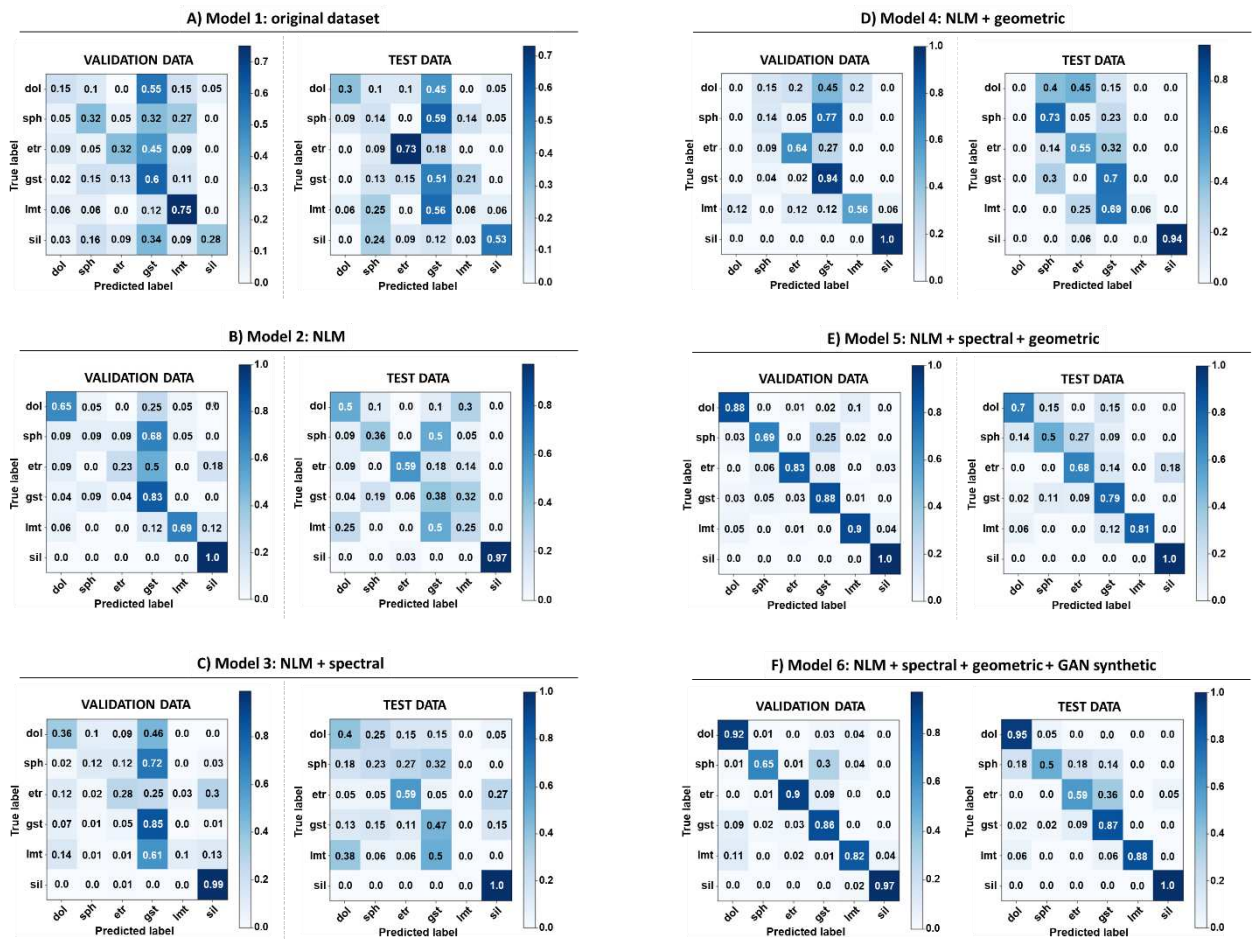


Fig. 11. Normalized confusion matrices for validation and test data, all obtained from: A) the original dataset – Model 1; B) the model trained based on NLM filtering – Model 2; C) the model trained based on NLM filtering and spectral augmentation techniques – Model 3; D) the model trained based on NLM filtering and geometric augmentation

techniques – Model 4; E) the model trained based on NLM filtering, spectral and geometric augmentation techniques – Model 5; F) the model trained based on synthetic images enhancement followed by NLM filtering, spectral and geometric augmentation techniques – Model 6. Categories are abbreviated for this figure on as follows: dol – dolomite; esp – espherulite; etr – stromatolite; gst – grainstone; lmt – laminate; sil – silixite.

A different manner of evaluating how classes are having their classification improved is by plotting each category accuracy evolution as transformations are added to the different models. By doing that for validation (Fig. 12) and test data (Fig. 13), classes with higher and lower contributions to the general model accuracy are highlighted. Test data shows that the best model predicts better the classes silixite and dolomite, while classes laminite and grainstone show accuracies very similar to the model general accuracy, and classes stromatolite and spherulite pull the general accuracy down due to their lower performance. However, the way categories contribute to the model’s total accuracies change according to the transformations that were used.




Fig. 12. Accuracy evolution for each category in relation to the total model accuracy on the validation data, as augmentations are applied for training the six models. The abbreviation “Total val acc” stands for “Total validation accuracy”. Categories are abbreviated as explained in Fig. 11.




Fig. 13. Accuracy evolution for each category in relation to the total model accuracy on the test data, as augmentations are applied for training the six models. The abbreviation “Total test acc” stands for “Total test accuracy”. Categories are abbreviated as explained in Fig. 11.

4. Discussions

Classes that obtained higher accuracies in the best model are diagenetic lithofacies: 95% for dolomite and 100% for silicite. That is an expected result considering that alterations due to dolomitization and silicification tend to create more homogeneous rocks, which will show unique and similar characteristics. Other instances that have been correctly classified for other categories are very representative of their corresponding lithofacies, as shown in Figs. 14 to 19. It is interesting to notice how classes performance change according to the applied transformations. For example, model 4, based only on NLM and geometric augmentations, wrongly classifies all instances from the category dolomite. That is attributed to the presence of recrystallized dolomite crystals, which indicates a lower relevance of geometric features for classification. The opposite happens to the class spherulite, which shows its greatest accuracy in this model. Considering the importance of rounded features for this category classification, geometry has a higher relevance and accuracy rises.




Fig. 14. Examples of correctly classified instances for the category stromatolite. In A, fascicular shrubs are not as evident as in B and interelement space is partially cemented by dolomite. In B, porosity is preserved in the interelement space and stromatolite structures are highlighted. Models should recognize these structures in different scales, but the image must have a minimum context for being correctly classified: if structures cannot be recognized considering the scale in which the images are acquired, the models will not be able to classify them correctly as well.




Fig. 15. Examples of correctly classified instances for the category spherulite. There are rounded spherulite particles in both A and B. However, dolomite cementation is more common in B, which could cause some confusion for classification. In B, radial textures are more evident than in A. For these two images, there are not many differences in particle sizes, but the models are able to generalize considering different scales.




Fig. 16. Examples of correctly classified instances for the category laminite. Laminae from A are somewhat more crenulated than in B. Although illumination conditions were very different for these instances, the best model is able to correctly predict them as being from the same category – laminite.




Fig. 17. Examples of correctly classified instances for the category grainstone. While the reworked particles are more compacted in A, they are more heterogeneous in nature and composition in B, where the interparticle space is more preserved. Even though, porosity is partially reduced by dolomite and silica cementation.




Fig. 18. Examples of correctly classified instances for the category dolomite. Dolomite crystals are represented larger in A than in B. That does not necessarily mean that they are larger, the image may simply be on a different scale. Models were trained without scale information so that they can be used for images acquired by different microscope objective lenses. Even though they were acquired under distinct illumination conditions, both have been correctly classified.




Fig. 19. Examples of correctly classified instances for the category silexite. Power source intensity was higher than it should during the acquisition of A, probably due to darker regions of the thin section while acquiring the photomosaic. In B, illumination conditions were better adjusted – the thin section that originated this instance is more homogeneous. Porosity occurs differently in these instances: while B shows only microporosity, it is possible to verify larger vugular pores in A.

Simply applying all the spectral augmentations in the training instances may suggest to the models that the color channels are not so relevant to the classification problem. For example, adding instances with enhanced blue casting created from all the original instances implies that information related to the blue channel is not so relevant to the classification problem. Chatfield et al. (2014) compared classification accuracies from models trained with RGB images – three color channels – to models trained with the same images converted to grayscale – one color channel. They obtained an approximately 3% drop in accuracy for the evaluated datasets. That is consistent with the drop observed by the model trained after NLM filtering with only spectral augmentations – Model 3. Accuracy from the test dataset dropped from 53.52% obtained in the model trained by the NLM filtered images – Model 2 – to 50.93% obtained by models trained by the same images added spectral augmentations – Model 3.

Even though new data is being added to the training dataset, when applied for all the instances and independently from other augmentation techniques, spectral augmentations may have an effect similar to converting three-color channel images to grayscale images. However, this effect is observed considering only the limited-size original dataset used for training. When applied together with geometric augmentations, which greatly amplifies the number of images used during training, they are able to boost test data accuracy to 73.29% – Model 5. Geometric augmentations alone with NLM filtering – Model 4 – added only a 3% gain to accuracy in relation to the models trained with NLM filtered images – Model 2 –, reaching 56.52%. This result shows the importance of applying both techniques and how they can be relevant to the models' generalization capabilities.

These transformation techniques are very useful for increasing accuracy, but they are not as effective as adding hard data to the training dataset. The closest option for doing that without actually acquiring new data from the microscopes is adding synthetic images created by GANs to the training dataset before applying the other techniques – Model 6. Obviously, it is not the same as adding hard data, but it accomplished a significant increase in test data accuracy, that reached 86.34%. This is close to the validation data accuracy obtained by the last two models – Models 4 and 5: 87.55%. Stabilization of the validation data accuracy in models trained with and without synthetic images, with all the other augmentation techniques in place, suggests that a maximum accuracy has been reached, considering limitations of the original training dataset, such as overlapping between classes. The similar value obtained for test data accuracy indicates that the final model – Model 6 –, that uses synthetic images and all the augmentation techniques, is able to generalize as well as possible considering the original training data.

In fact, when evaluating the images that have been wrongly classified by this model, these limitations become clearer. As shown by its corresponding confusion matrices (Fig. 11F), spherulite and stromatolite are the classes that are not as well predicted. There are images from the test dataset that are labeled as spherulite, however they are intensely dolomitized. Interelement space is fully filled with dolomite crystals and even most of the particles have been recrystallized (Fig. 20A). These images have been classified by the model as dolomites.

Another issue is the presence of amalgamated spherulites, causing the particles to show geometries that resemble stromatolite structures (Fig. 20B). Even though they are amalgamated spherulites in a spherulite context, the model classified these images as stromatolites. Confusion between these two classes is also expected due to their depositional context: transitional forms between calcite spherulites and fascicular calcite aggregates are frequent, which indicates precipitation from the same fluids under slightly different conditions (De Ros 2018; Lima & De Ros, 2019). These transitional forms are difficult to be classified into discrete categories, such as spherulite or stromatolite. That difficulty is reflected on the model.

Some images labeled as stromatolites have been classified as grainstones (Fig. 20C). Labels are derived from thin section analysis and photomosaic images from the entire thin sections. It is possible that clipping these images for creating the original dataset did not include an area large enough to characterize lithofacies. Some of these instances wrongly classified as grainstones are representative of transitional forms labeled as stromatolite due to the context of the thin section from where they have been clipped.

A crenulated laminite has been classified as grainstone (Fig 20D). Its laminae are highlighted by clay minerals and organic matter; however, they are erratic and discontinuous. In the regions dominated by carbonate composition, there are remnants of possible peloids that have been through micritization.




Fig. 20. A) Test instance labeled as spherulite and wrongly predicted as dolomite. In fact, the rock has been through intense dolomitization, interelement space is fully filled with dolomite crystals and particles have been partially recrystallized. B) Test instance labeled as spherulite and wrongly predicted as stromatolite. Coalesced spherulites may show geometries similar to stromatolite fascicular aggregates – highlighted by the dashed red line. The rock may also represent some transitional form between these two categories. C) Test instance labeled as stromatolite and wrongly predicted as grainstone. The clipped area from the photomosaic may not have been large enough to characterize lithofacies. D) Test instance labeled as laminite and wrongly predicted as grainstone. Laminae are erratic and discontinuous, there are remnants of possible micritized peloids, which could have caused the misclassification.

5. Conclusions

A data-centric approach based on data transformation and augmentation more than doubled accuracy on predictions from the test dataset. The model trained with the original training dataset has an accuracy of only 42.24% for the test dataset, while the model trained with all the proposed techniques showed 86.34% of accuracy, both using the same CNN architecture. Considering data availability and standardization, these techniques are the best option for training useful models for industry predictions. Based on a small training dataset, obtained from different sources, a lithofacies classification model has been trained with high accuracy, measured with data from adjacent wells, not used for training.

Application of a pre-convolutional filter in the original images, such as non-local means, reduces noise for the lithofacies classification problem. This simple transformation by itself already results in an 11.28% increase in accuracy. Accuracy results indicate that both spectral and geometric augmentation techniques should be applied together in order to obtain a significant increase in performance. Applying only spectral augmentations in all instances actually decreases model accuracy, considering the initial limited-size dataset. There is a narrow increase in performance when applying only geometric augmentations: 3% for test data. When these techniques are applied together, accuracy increases 19.77% for test data.

Another common issue in datasets obtained in industrial environments is data imbalance. Early models were leaning toward overclassifying grainstone, which was expected considering the larger number of observations for that category. That tendency has been gradually disappearing as augmentations were applied, specially after adding GAN-generated synthetic images, which greatly reduced data imbalance. An additional 13.05% increase in accuracy for test data is observed when adding the synthetic images, resulting in the best-trained model – model 6.

Analyzing each category separately, the performance of the best model reflects the difficulty of a specialist in actually classifying instances into discrete lithofacies, considering overlapping due to transitional forms. Diagenetic lithofacies – dolomite and silexite – performed better than the model's general accuracy, while lithofacies predominantly with in situ depositional structures – spherulite and stromatolite – have had their predictions lower than the model's general accuracy.

6. Acknowledgments

The authors would like to acknowledge Petrobras – Petróleo Brasileiro S.A., specifically the Geological Data Management Department, represented by Jorge Alexandre Lopes Polônia, for the encouragement and guidance through permits for publication. They thank Cristiano de Andrade Gonçalves, for discussions related to the codes used in this paper. They also thank the Integrated Technology for Rock and fluid Analysis (InTRA) Research Group, for guidance during the development of this project. This research was conducted under the Graduate Program from the Departamento de Engenharia de Minas e de Petróleo of Escola Politécnica, Universidade de São Paulo, Brazil.

Code availability section

The codes used in the research are available at: <https://github.com/rafaelrubo/lithofaciesclassification>.

NLM filtering and all the spectral augmentation implementations were made available by Schindelin et al. (2012).

A code written in ImageJ Macro Language has been developed in order to apply all the transformations in one instance. This block of code is available in the “NLM_SpectralAugmentations.ijm” file.

All the geometric augmentations were applied using Tensorflow-Keras Python library. These transformations occur during data loading. They are available in the “GeometricAugmentations.py” file.

Synthetic images were created using a Python implementation of GANs based on Radford et al. (2016). This block of code is available in the “GANSyntheticImages.py” file.

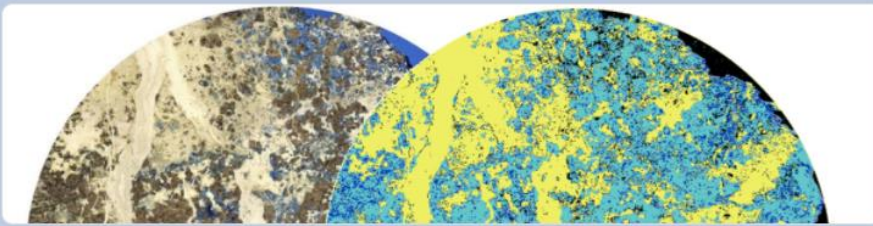
The models were trained using a fixed CNN architecture, also using Tensorflow-Keras Python library. The code for training the models are available in the “TrainingModels.py” file.

References

- Buades BCA, Morel JM (2005) A non-local algorithm for image denoising. *IEEE Computer Vision and Pattern Recognition* 2:60-65. <https://doi.org/10.1109/CVPR.2005.38>
- Chatfield K, Simonyan K, Vedaldi A, Zisserman A (2014) Return of the devil in the details: delving deep into convolutional nets. *Proceedings of BMVC: British Machine Vision Conference*.
<https://doi.org/10.5244/C.28.6>
- Deng J, Dong W, Socher R, Li L, Li K, Fei-Fei L (2009) ImageNet: A large-scale hierarchical image database. *IEEE Conference on Computer Vision and Pattern Recognition* 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>
- De Ros LF (2018) Genesis and Evolution of Aptian Pre salt Carbonate Reservoirs in Southeastern Brazilian Margin. Presentation in Brazilian Petroleum Conference 19-21. Rio de Janeiro, Brazil.
- Dunham RJ (1962) Classification of carbonate rocks according to their depositional texture. *Classification of Carbonate Rocks - a symposium* (Ham, W.E. ed.). The American Association of Petroleum Geologists, AAPG Memoir (1):108-121. Tulsa, EUA.
- Embry AF, Klovan JE (1971) A Late Devonian reef tract on northeastern Banks Island. N.W.T.: *Bulletin of Canadian Petroleum Geology* (19):730-781.
- Folk RL (1959) Practical petrographic classification of limestones. *AAPG Bulletin* (43):1-38.
- Folk RL (1962) Spectral subdivision of limestone types. *Classification of Carbonate Rocks - a symposium* (Ham, W.E. ed.). The American Association of Petroleum Geologists, AAPG Memoir (1):62-84. Tulsa, EUA.
- Geman D, Geman S, Graffigne C, Dong P (1990) Boundary detection by constrained optimization. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 12(7):609-628. <https://doi.org/10.1109/34.56204>
- Hofmann T, Puzicha J, Buhmann J (1998) Unsupervised texture segmentation in a deterministic annealing framework. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 20(8):803-818.
<https://doi.org/10.1109/34.709593>
- Howard AG (2013) Some improvements on deep convolutional neural network based image classification. *CoRR*, abs/1312.5402.
- Jain A, Farrokhnia F (1991) Unsupervised texture segmentation using Gabor filters. *Pattern Recognition* 24(12):1167-1186. [https://doi.org/10.1016/0031-3203\(91\)90143-S](https://doi.org/10.1016/0031-3203(91)90143-S)
- Krizhevsky A, Sutskever I, Hinton GE (2012). Imagenet classification with deep convolutional neural networks. *NIPS Neural Information Processing Systems* 1(4). <https://doi.org/10.1145/3065386>

- LeCun Y, Bottou L, Bengio Y, Haffner P (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE Computer Society Conference 86(11):2278-2324. <https://doi.org/10.1109/5.726791>
- Leevy JL, Khoshgoftaar TM, Bauder RA, Seliya N (2018) A survey on addressing high-class imbalance in big data. Springer Journal of Big Data 5(42). <https://doi.org/10.1186/s40537-018-0151-6>
- Lima BEM, De Ros LF (2019). Deposition, diagenetic and hydrothermal processes in the Aptian Pre Salt lacustrine carbonate reservoirs of the northern Campos Basin, offshore Brazil. Sedimentary Geology (383):55-81. <https://doi.org/10.1016/j.sedgeo.2019.01.006>
- Mao J, Jain A (1992) Texture classification and segmentation using multiresolution simultaneous autoregressive models. Pattern Recognition (25):173-188. [https://doi.org/10.1016/0031-3203\(92\)90099-5](https://doi.org/10.1016/0031-3203(92)90099-5)
- Moreira JLP; Madeira CV; Gil JA, Machado MAP (2007). Bacia de Santos. Boletim de Geociências da Petrobras 15(2):531-549.
- Paleyes A, Urma RG, Lawrence ND (2022). Challenges in Deploying Machine Learning: a Survey of Case Studies. ACM Computing Surveys. <https://doi.org/10.1145/3533378>
- Radford A, Metz L, Chintala S (2016) Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. ICLR: The International Conference on Learning Representations, arXiv:1511.06434v2.
- Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Huang Z, Karpathy A, Khosla A, Bernstein M, Berg AC, Fei-Fei L (2015). ImageNet Large Scale Visual Recognition Challenge. International Journal of Computer Vision (115):211–252. <https://doi.org/10.1007/s11263-015-0816-y>
- Schindelin J, Arganda-Carreras I, Frise E, Kaynig V, Longair M, Pietzsch T, Preibisch S, Rueden C, Saalfeld S, Schimid B, Tinevez JY, White DJ, Hartenstein, V, Eliceiri K, Tomancak P, Cardona A (2012). Fiji: an open-source platform for biological-image analysis. Nature methods 9(7):676-682. <https://doi.org/10.1038/nmeth.2019>
- Terra GJS, Spadini AR, França AB, Sombra CL, Zambonato EE, Juschaks LCS, Arienti, LM, Erthal MM, Blauth M, Franco MP, Matsuda NS, Silva NGC, Moretti Junior PA, D'Avila RSF, Souza RS, Tonietto SN, Anjos SMC, Campinho VS, Winter WR (2010). Classificação de rochas carbonáticas aplicável às bacias sedimentares brasileiras. Boletim de Geociências da Petrobras 18(1), 9-29. Rio de Janeiro, Brazil.
- Wu R, Yan S, Shan Y, Dang Q, Sun G (2015) Deep Image: scaling up image recognition. Computer Vision and Pattern Recognition, arXiv e-prints: 1501.02876.

ANEXO C – Formulário de registro das entrevistas com petrógrafos



Petrografia Digital

Olá!

Este questionário irá contribuir para a minha Tese de Doutorado.

A proposta é avaliar os resultados obtidos pelos modelos de aprendizado de máquina que visam auxiliar a atividade de descrição petrográfica.

São 12 questões simples que envolvem avaliação de imagens.
Tempo estimado: 10 - 15 minutos.



Obrigado pela contribuição!
Saudações geológicas!

Rafael Rubo

Título: Petrografia digital baseada em Inteligência Artificial: quantificação mineralógica, caracterização da porosidade, texturas e litofácies em rochas carbonáticas

Orientador:
Prof. Dr. Cleyton de Carvalho Carneiro (Escola Politécnica da USP)


Hipótese da Tese:
A tese ora em desenvolvimento parte da hipótese de que modelos de machine learning podem aprimorar o processo de descrição de lâminas petrográficas, alcançando resultados quantitativos mais confiáveis, padronizados e rápidos do que a descrição tradicional. Tal hipótese será testada a partir de ferramentas estatísticas e de ciência de dados, para a avaliação da acurácia dos modelos. Adicionalmente, a hipótese será avaliada a partir de entrevistas com petrógrafos por meio de questionários. Esse conjunto de testes possibilitará o desenvolvimento da tese contendo um panorama geral da atividade descritiva interpretada e comparando-a com a utilização dos modelos obtidos por inteligência artificial.

 rafael.rubo@usp.br (não compartilhado) [Alternar conta](#) 


Nome:

Sua resposta _____

Questão 01: Considerando a área definida pela imagem segmentada à direita, estime a porosidade total da rocha.




2 mm



2 mm


- < 1 %
- entre 1 e 3 %
- entre 3 e 6 %
- entre 6 e 9%
- entre 9 e 12%
- entre 12 e 15%
- entre 15 e 18%
- entre 18 e 21%
- acima de 21%

Questão 02: Considerando a imagem a seguir, qual das opções de litofácies você utilizaria para descrevê-la? Escolha a opção que mais se aproxima de sua análise.




- Estromatolito
- Esferulítico
- Laminito
- Grainstone
- Dolomito
- Sillexito

Questão 03: Considerando a imagem a seguir, qual das opções de litofácies você utilizaria para descrevê-la? Escolha a opção que mais se aproxima de sua análise.




- Estromatolito
- Esferulitito
- Laminito
- Grainstone
- Dolomito
- Silexito

Questão 04: Considerando a imagem a seguir, qual das opções de litofácies você utilizaria para descrevê-la? Escolha a opção que mais se aproxima de sua análise.




- Estromatolito
- Esferulítico
- Laminito
- Grainstone
- Dolomito
- Silexito

Questão 05: Considerando a imagem a seguir, qual das opções de litofácies você utilizaria para descrevê-la? Escolha a opção que mais se aproxima de sua análise.



- Estromatolito
- Esferulitito
- Laminito
- Grainstone
- Dolomito
- Sillexito

Questão 06: Considere que a microanálise química (QEMSCAN) de uma lâmina petrográfica identificou que mais de 99% da rocha é composta por calcita, dolomita, quartzo ou poros. Com base na imagem abaixo, obtida por microscopia óptica de luz transmitida, estime o percentual de cada uma destas classes:




Sua resposta


Questão 07: Uma das imagens abaixo é sintética, produzida utilizando redes generativas adversariais para representar um estromatolito. Assinale a imagem que você acredita não ser real. Todas as alternativas foram reduzidas para a mesma resolução da imagem sintética.




Opção 1




Opção 2



Opção 3




Opção 4




Opção 5

Questão 08: Uma das imagens abaixo é sintética, produzida utilizando redes generativas adversariais para representar um esferulítico. Assinale a imagem que você acredita não ser real. Todas as alternativas foram reduzidas para a mesma resolução da imagem sintética.



Opção 1




Opção 2



Opção 3



Opção 4



Opção 5

Questão 09: Uma das imagens abaixo é sintética, produzida utilizando redes generativas adversariais para representar um laminito. Assinale a imagem que você acredita não ser real. Todas as alternativas foram reduzidas para a mesma resolução da imagem sintética.



Opção 1



Opção 2



Opção 3



Opção 4




Opção 5


Questão 10: Uma das imagens abaixo é sintética, produzida utilizando redes generativas adversariais para representar um grainstone. Assinale a imagem que você acredita não ser real. Todas as alternativas foram reduzidas para a mesma resolução da imagem sintética.




Opção 1




Opção 2



Opção 3



Opção 4




Opção 5

Questão 11: Uma das imagens abaixo é sintética, produzida utilizando redes generativas adversariais para representar um dolomito. Assinale a imagem que você acredita não ser real. Todas as alternativas foram reduzidas para a mesma resolução da imagem sintética.



Opção 1



Opção 2



Opção 3



Opção 4



Opção 5

Questão 12: Uma das imagens abaixo é sintética, produzida utilizando redes generativas adversariais para representar um sillexito. Assinale a imagem que você acredita não ser real. Todas as alternativas foram reduzidas para a mesma resolução da imagem sintética.




Opção 1



Opção 2



Opção 3



Opção 4



Opção 5