



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

VICTOR GOMES CARDOSO

**UM MÉTODO EFICIENTE PARA EXTRAÇÃO DE PROPRIEDADES DE
POROSIDADE DE ROCHAS CARBONÁTICAS EM IMAGENS
MICROTOMOGRÁFICAS**

Recife
2020

VICTOR GOMES CARDOSO

**UM MÉTODO EFICIENTE PARA EXTRAÇÃO DE PROPRIEDADES DE
POROSIDADE DE ROCHAS CARBONÁTICAS EM IMAGENS
MICROTOMOGRÁFICAS**

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Área de Concentração: Engenharia da Computação

Orientador: Edna Natividade da Silva Barros

Coorientador: José Antonio Barbosa

Recife
2020

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

C268m Cardoso, Victor Gomes
Um método eficiente para extração de propriedades de porosidade de rochas carbonáticas em imagens microtomográficas / Victor Gomes Cardoso. – 2020. 77 f.: il., fig., tab.

Orientadora: Edna Natividade da Silva Barros.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CIn, Ciência da Computação, Recife, 2020.
Inclui referências.

1. Engenharia da computação. 2. Segmentação de imagens. I. Barros, Edna Natividade da Silva (orientadora). II. Título.

621.39

CDD (23. ed.)

UFPE - CCEN 2020 - 198

Victor Gomes Cardoso

“Um Método Eficiente para Extração de Propriedades de Porosidade de Rochas Carbonáticas em Imagens Microtomográficas”

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação.

Aprovado em: 30/09/2020.

BANCA EXAMINADORA

Prof. Dr. Adriano Augusto de Moraes Sarmiento
Centro de Informática / UFPE

Prof. Dr. Moisés Dantas dos Santos
Departamento de Computação Científica / UFPB

Profa. Dra. Edna Natividade da Silva Barros
Centro de Informática / UFPE
(Orientadora)

AGRADECIMENTOS

Agradeço a Deus por ter me dado forças e sabedoria para superar os desafios impostos durante essa jornada.

Agradeço aos meus pais, Givanilda Gomes e Everaldo Cardoso, por terem me dado todas as condições necessárias para que a educação tivesse um espaço importante na minha vida, apesar de todas as dificuldades.

Agradeço à minha esposa Edlaine Cardoso por ter compartilhado, com longanimidade, os momentos mais importantes dessa trajetória e por ter me incentivado nos períodos de incerteza.

Agradeço à profa. Edna Barros por ter me orientado neste trabalho e pelas valiosas contribuições à minha formação acadêmica e pessoal.

Agradeço ao prof. Antonio Barbosa pelos ensinamentos concedidos no campo da Geologia. Obrigado pela atenção e pelas horas dedicadas ao suporte deste trabalho.

Agradeço ao grupo de pesquisa da pós-graduação pelas contribuições trazidas durante as reuniões. Em especial, agradeço a Victor Sabino pelo companheirismo desde o início do programa de mestrado.

Agradeço a todos do grupo de pesquisa de Imageamento, Caracterização e Simulação de Meios Porosos (ICSMP), vinculado ao DEN-UFPE, por todo suporte técnico fornecido na preparação e escaneamento das amostras de rochas utilizadas no estudo. Faço um agradecimento em especial a Abraão Nova, pelas orientações que auxiliaram na condução do trabalho.

RESUMO

A caracterização de meios porosos consiste num fator crítico para a extração de petróleo e gás natural de rochas-reservatório. A análise de imagens digitais geradas por microtomografia computadorizada de raios-X (μ CT) representa uma maneira importante de construir modelos detalhados de rochas e extrair parâmetros petrofísicos. Este trabalho apresenta um método eficiente de processamento de imagens microtomográficas 2D para a extração de propriedades de sistemas porosos de amostras de rochas. O conjunto de operações proposto permitiu obter de forma automática a porosidade total, a distribuição de tamanho de poros e a orientação geral de poros, aplicados a sete amostras de calcário da Formação Tambaba (Eoceno). Os valores de porosidade extraídos pela nova técnica de segmentação foram comparados com os dados de porosidade obtidos através de ensaios de porosimetria (hélio) dos plugues estudados e por técnicas de segmentação frequentemente implementadas nesse contexto. O erro médio entre os valores experimentais e os valores de porosidade obtidos pelo método desenvolvido foi de 4,47%, o menor entre as técnicas examinadas. Uma comparação dos dados sobre a distribuição da orientação dos poros fornecidos automaticamente pelo novo código e os dados obtidos pelos métodos clássicos mostraram excelente correlação. O tempo de execução necessário para o cálculo automático das propriedades do sistema de poros foi de aproximadamente 9 min por amostra (realizado por um computador com CPU *Intel Core i7* e 8GB de memória RAM). Experimentos adicionais com quantidades menores de fatias forneceram valores semelhantes das propriedades petrofísicas, o que mostrou a robustez da técnica. Os resultados alcançados mostraram o grande potencial da nova técnica de segmentação automática, utilizada na abordagem apresentada, para a extração de propriedades de sistemas porosos de rochas calcárias com precisão e eficiência, em termos de tempo de processamento.

Palavras-chaves: Segmentação de imagens. Microtomografia computadorizada. Extração de propriedades petrofísicas.

ABSTRACT

The characterization of porous media represents a critical issue for recovering oil and gas from reservoir rocks. Analyses of digital images generated by X-ray micro-computed tomography (μ CT) are useful for building detailed models of rocks and extracting petrophysical parameters. This work presents an efficient method of 2D microtomographic images processing for extraction of samples' porous system properties. The new set of operations allowed the automatic computation of the total porosity, pore size distribution and general pores orientation data, of seven plugs of limestone from the Eocene Tambaba Formation. The porosity values extracted by the new segmentation technique were compared against porosity values obtained through porosimetry (helium) essays and with data obtained through the application of other often-used segmentation techniques. The average error between experimental values and the porosity values obtained through the segmentation process is 4,47%, the lowest among the techniques evaluated. A comparison of data on the pore orientation distribution provided automatically by the new code and data obtained through classical methods showed excellent correlation. Computation time spent for the automatic calculation of pore system properties was approximately 9 min per sample (performed in an *Intel Core i7* CPU with 8GB of RAM memory PC). Further experiments of calculations with smaller quantities of slices provided similar values of petrophysical properties, which showed the technique's robustness. The accomplished results showed the new automatic segmentation technique's great potential for the extraction of porous system properties of calcareous rocks with accuracy and efficiency in terms of computational time.

Keywords: Image segmentation. Micro-computed tomography. Petrophysical properties extraction.

LISTA DE FIGURAS

Figura 1 – Representação da obtenção das propriedades de orientação pelo método de alocação de elipse.	19
Figura 2 – Representação do arranjo de aquisição em um sistema de tomografia computadorizada.	20
Figura 3 – Esquema representativo de um tubo de raios-X.	21
Figura 4 – Artefatos em imagens microtomográficas. (a) Artefato circular e (b) Artefato por endurecimento de feixe.	23
Figura 5 – Imagem de (a) amostra de rocha carbonática e a (b) representação 3D de parte do volume da rocha.	23
Figura 6 – Fatias de rocha escaneada. (a) Fatia em bom estado e (b) fatia com falhas de escaneamento.	24
Figura 7 – Impacto da resolução espacial e da quantização em imagens. As figuras (a), (b) e (c) apresentam diferentes resoluções espaciais e as imagens (d), (e) e (f) possuem diferentes valores de quantização.	25
Figura 8 – Imagem (a) microtomográfica de uma rocha calcária e o (b) histograma da imagem (a).	26
Figura 9 – Aplicação da (b) segmentação pelo método de Otsu na (a) imagem em tons de cinza.	27
Figura 10 – Aplicação da segmentação pelo algoritmo <i>Watershed</i> . (a) Imagem de moléculas de lipídio e (b) resultado da segmentação.	28
Figura 11 – Representação de aplicação da operação de dilatação na imagem A pelo elemento estruturante B.	30
Figura 12 – Representação de aplicação da operação de erosão na imagem A pelo elemento estruturante B.	31
Figura 13 – Amostras de rochas calcárias utilizadas no estudo.	35
Figura 14 – Modelo do microtomógrafo utilizado no escaneamento das amostras. . .	36
Figura 15 – Fluxograma da rotina de execução da aplicação.	37
Figura 16 – Representação do impacto do desalinhamento da amostra ao longo do eixo longitudinal do cilindro.(a) Fatias das extremidades da amostra, (b) Imagens segmentadas e (c) Sobreposição das imagens segmentadas.	38
Figura 17 – Imagem microtomográfica da amostra de rocha (a) original e (b) após a operação de detecção de circunferência aplicada à imagem segmentada.	39
Figura 18 – Ajuste automático do posicionamento da região de interesse.	39
Figura 19 – Região de interesse definida para a amostra analisada visualizadas na (a) primeira fatia e (b) última fatia.	40

Figura 20 – Histograma de uma amostra de rocha calcária. As linhas I_{void} e I_{solid} delineiam o pico da região vazia e da região sólida, respectivamente. As linhas J1 e J2 são os limites da região microporosa.	42
Figura 21 – Representação gráfica dos parâmetros $l1$ e $l2$ no histograma.	43
Figura 22 – Representação gráfica dos parâmetros do algoritmo de segmentação proposto.	44
Figura 23 – Representação das categorias de tamanho dos poros detectados. (a) Poros pequenos, (b) poros médios e (c) poros grandes.	45
Figura 24 – Bounding boxes encontrados para os poros grandes da imagem.	45
Figura 25 – Bounding boxes encontrados para os poros grandes da imagem com os ângulos calculados.	46
Figura 26 – Padronização para a representação da orientação dos poros. (a) Ângulos corrigidos e (b) diagrama de roseta.	47
Figura 27 – Exemplos de imagens removidas durante a triagem.	48
Figura 28 – Representação da determinação de ROI (vermelho) na Amostra 1. A região em verde representa a interseção entre a área da rocha na primeira (amarelo) e na última fatia (azul).	49
Figura 29 – Pré-processamento em uma (a) fatia da Amostra 6. (b) Recorte da região de interesse e (c) aplicação de filtro na imagem redimensionada.	50
Figura 30 – Fatia da Amostra 7 segmentada pela técnica proposta. (a) Imagem original e (b) Imagem segmentada (valor de limiar = 2221).	52
Figura 31 – Fatia da Amostra 7 segmentada por diferentes métodos: (a) Método de limiarização Otsu, (b) Watershed e (c) Agrupamento K-means.	52
Figura 32 – Perfil de porosidade das amostras.	53
Figura 33 – Resultados de porosidade obtidos pelas técnicas de segmentação de imagens e pelo porosímetro.	56
Figura 34 – Representação do impacto do algoritmo de segmentação k-means em amostras com composição porosa distintas.	57
Figura 35 – Raiz do erro médio quadrático das técnicas de segmentação analisadas.	58
Figura 36 – Frequência acumulada dos poros conforme a área.	59
Figura 37 – Comparação da representatividade da porosidade de acordo com a área.	60
Figura 38 – Diagramas de roseta para os poros (a) pequenos, (b) médios e (c) grandes da Amostra 5.	61
Figura 39 – Comparação do diagrama de orientação dos poros grandes da Amostra 7.	62
Figura 40 – Correlação entre os diagramas de orientação de poros obtidos pelo método proposto e por técnica clássica com o ImageJ.	62
Figura 41 – Comparação do diagrama de orientação dos poros grandes das amostras.	63

Figura 42 – Representação da alteração da amostragem das imagens da pilha durante os testes de sensibilidade. Considerando (a) 100% do volume, (b) 50% do volume e (c) 25% do volume.	66
Figura 43 – Comparação da representatividade da porosidade de acordo com a área, considerando o processamento de 5% das fatias.	67
Figura 44 – Comparação da distribuição de orientação dos poros grandes após o processamento de 5% e 100% das imagens.	68

LISTA DE TABELAS

Tabela 1 – Dimensões das amostras de rochas utilizadas no estudo.	35
Tabela 2 – Dados gerados pela reconstrução das amostras escaneadas pelo μ CT. .	36
Tabela 3 – Quantidade de imagens analisadas e dimensões da região de interesse. .	49
Tabela 4 – Intervalo com valores de limiarização aplicados na segmentação das amostras.	51
Tabela 5 – Valores de porosidade obtidos pela técnica de segmentação proposta e a representatividade volumétrica da análise.	54
Tabela 6 – Porosidade calculada por diferentes técnicas de segmentação	55
Tabela 7 – Porosidade obtida pelo Porosímetro de Gás Hélio	55
Tabela 8 – Tempo de execução do método proposto.	64
Tabela 9 – Tempo de execução das técnicas de segmentação avaliadas.	65
Tabela 10 – Resultados de porosidade obtidos pelo método proposto considerando frações de 100%, 50%, 25%, 20%, 10% e 5% das imagens.	66
Tabela 11 – Tempo de processamento obtido pelo método proposto considerando frações de 100%, 50%, 25%, 20%, 10% e 5% das imagens.	69

LISTA DE SÍMBOLOS

2D	Bidimensional
3D	Tridimensional
dpi	dots per inch
HU	Hounsfield Unit
pixel	picture element
PVE	Pure Voxel Extraction
ROI	Region of Interest
RV	Representatividade volumétrica
SEM	Scanning Electron Microscope
tiff	Tagged Image File Format
voxel	volume element
XCT	X-ray computed tomography
μ CT	Micro-computed tomography

SUMÁRIO

1	INTRODUÇÃO	14
1.1	MOTIVAÇÃO	14
1.2	PROBLEMA	16
1.3	OBJETIVOS DO TRABALHO	16
1.3.1	Objetivo geral	16
1.3.2	Objetivos específicos	16
1.3.3	Contribuições	16
1.4	ESTRUTURA DA DISSERTAÇÃO	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	PROPRIEDADES PETROFÍSICAS	18
2.1.1	Orientação dos poros	18
2.1.2	Rochas carbonáticas	19
2.2	TOMOGRAFIA COMPUTADORIZADA DE RAIOS-X	20
2.2.1	Escala Hounsfield	22
2.2.2	Limitações da técnica de tomografia computadorizada	22
2.2.3	Imagens microtomográficas de rochas carbonáticas	23
2.3	PROCESSAMENTO DIGITAL DE IMAGENS	24
2.3.1	Histograma	26
2.3.2	Método de Limiarização Otsu	27
2.3.3	Algoritmo Watershed	28
2.3.4	Agrupamento k-means	29
2.3.5	Operações morfológicas	29
2.3.6	Deteccção de contornos em imagens	30
2.4	TRABALHOS RELACIONADOS	31
3	MATERIAIS	35
4	METODOLOGIA	37
4.1	SELEÇÃO DA REGIÃO DE INTERESSE	37
4.2	ALGORITMO DE SEGMENTAÇÃO DE IMAGEM	42
4.3	EXTRAÇÃO DE CARACTERÍSTICAS MORFOLÓGICAS DO MEIO POROSO	44
5	RESULTADOS E DISCUSSÃO	48
5.1	RESULTADOS DA SEGMENTAÇÃO	51
5.2	ANÁLISE DE POROSIDADE	53

5.3	CARACTERIZAÇÃO DOS POROS	58
5.4	DISTRIBUIÇÃO DA ORIENTAÇÃO DOS POROS	61
5.5	TEMPO DE PROCESSAMENTO	64
6	CONCLUSÃO	70
6.1	CONCLUSÃO	70
6.2	TRABALHOS FUTUROS	71
	REFERÊNCIAS	72

1 INTRODUÇÃO

Este capítulo apresenta uma breve contextualização da área de aplicação do trabalho proposto, bem como a motivação e impacto da técnica proposta a partir da descrição do problema que por ele será investigado. Em seguida, são apresentados os objetivos definidos como requisitos do trabalho e por fim, a organização da dissertação é detalhada.

1.1 MOTIVAÇÃO

O petróleo e o gás natural possuem expressiva importância na economia global devido às suas aplicações como matriz energética e como matéria-prima em produtos de diversos segmentos da indústria (PEREIRA, 2010). Estes materiais são formados na natureza devido à decomposição de matéria orgânica em condições específicas de pressão e temperatura em camadas no subsolo de bacias sedimentares. A estrutura rochosa capaz de armazenar o acúmulo desses materiais é chamada de rocha-reservatório (THOMAS, 2001). Como apresentado por Kronbauer (2014), grande parte das reservas desses elementos é encontrada em rochas carbonáticas, pois apresentam porosidade e permeabilidade adequadas para a acumulação desses materiais.

Estudos preliminares de reservatórios fornecem informações que auxiliam na avaliação da viabilidade de prospecção e no planejamento estratégico de exploração desses recursos naturais. Além da composição geológica da região, é fundamental avaliar algumas propriedades do meio poroso contido na formação rochosa, visto que o aspecto mais importante que rege o comportamento físico de uma amostra de rocha está relacionado principalmente com a sua microestrutura (AL-MARZOUQI, 2018). A análise de propriedades petrofísicas fornece dados capazes de quantificar a capacidade de armazenamento, a distribuição e a forma com a qual os fluidos escoarão no processo de extração desses materiais (THOMAS, 2001).

As formas mais comuns de aferição dessas propriedades consistem em experimentos laboratoriais (baseados em intrusão de mercúrio e expansão a gás como principais métodos), ou por processamento de imagens, obtidas a partir de tomografia computadorizada de raios-X (XCT). Embora os métodos laboratoriais, em geral, mostrem-se mais precisos do que as técnicas baseadas em processamento de imagem, os ensaios físicos tendem a ter um custo maior, demandam um maior tempo de preparação e podem alterar a estrutura da amostra coletada (EROFEEV et al., 2019).

Alternativamente, a XCT é uma forma não-destrutiva de obtenção de propriedades petrofísicas e possui grande importância como forma de caracterizar rochas/solos. Com o avanço tecnológico no ramo da XCT, atualmente é possível obter representações volumétricas com resolução espacial cada vez maiores. Os XCTs de resolução micrométrica,

também chamados de microtomógrafos (μ CTs), tem se destacado nesse campo de pesquisa devido à sua capacidade de representar, de maneira precisa, a estrutura interna das rochas por meio de modelos virtuais (rochas digitais) (GUNTORO et al., 2019), oferecendo uma compreensão mais profunda da relação entre a geometria dos poros e as propriedades físicas das rochas.

Parte do sucesso atribuído à análise μ CT está associado ao avanço dos algoritmos de processamento voltados a este tipo de aplicação (SCHLUTER et al., 2014). Diferentes técnicas de processamento de imagens 3D demonstram produzir excelentes resultados na caracterização de minerais. Desde métodos clássicos de segmentação (DENG; FITTS; PETERS, 2016) até algoritmos modernos de aprendizagem de máquina baseados em redes neurais (YUN; LIU; KOVSCEK, 2020) mostraram-se boas ferramentas de computação.

Como a obtenção das propriedades físicas é realizada geralmente a partir do tratamento das microestruturas representadas pela reconstrução 3D das amostras escaneadas (SAXENA; MAVKO, 2015), isso faz com que as análises de rochas digitais demandem muitos recursos computacionais e tempo elevado de processamento (WU; YIN; XIAO, 2018; SAAD; NEGARA; ALI, 2018). Em compensação, abordagens baseadas no processamento das imagens 2D fornecem uma alternativa mais rápida e eficiente para a estimação dessas propriedades (SAXENA et al., 2017).

Além disso, devido às especificidades de cada litologia, é comum que algumas das etapas do fluxo de trabalho demandem intervenções do usuário para determinação ou verificação de parâmetros de ajuste. Em alguns casos, como na análise de rochas carbonáticas, a natureza do arranjo poroso agrega ainda mais complexidade a esse processo. Dado que esse tipo de rocha se destaca por apresentar vasta heterogeneidade espacial dos seus poros (SMODEJ et al., 2019). Esse conjunto de fatores torna o processo de extração de propriedades lento, podendo levar horas até o processamento completo do volume (CHAUHAN et al., 2016).

Adicionalmente, sabe-se que a quantidade de dados demandada pela indústria do petróleo nesse tipo de processamento é elevada. Isso porque os responsáveis pela recuperação desses recursos utilizam-se da estratégia de extrair múltiplas amostras (*core samples*) das regiões de reservatório para serem submetidas à análise (DANDEKAR, 2013), devido à não homogeneidade das propriedades das rochas que compõem essas formações.

Este conjunto de fatores fomentam a busca pelo desenvolvimento de técnicas para a caracterização de rochas-reservatório, realizadas através de μ CT, com uso de abordagens que forneçam resultados precisos, com baixo tempo de processamento. Esses requisitos são prioritários pelo fato de que as informações providas são úteis para a tomada de decisão que impactam diretamente a redução de perdas relativas à prospecção e à maximização da capacidade de extração nas reservas de petróleo e gás.

1.2 PROBLEMA

Dentre os desafios presentes no âmbito da caracterização de rochas-reservatório por imagens microtomográficas, reduzir o custo computacional das análises implicaria em ganhos na aplicabilidade e escalabilidade desta solução (WANG et al., 2019). Técnicas de processamento com alto nível de complexidade e grandes volumes de dados de entrada são os principais fatores que contribuem para que grande parte das técnicas de caracterização do meio poroso tenha um alto custo computacional (SAXENA et al., 2017).

Portanto, o desenvolvimento de um fluxo de processamento de imagens capaz de extrair propriedades petrofísicas de forma precisa e eficiente seria de grande valia nesse contexto. É essencial que, durante a análise, as particularidades do tipo de rocha sejam consideradas para gerar resultados confiáveis.

1.3 OBJETIVOS DO TRABALHO

1.3.1 Objetivo geral

Este trabalho tem como objetivo o desenvolvimento de um método de processamento de imagens, a partir dos dados obtidos pelo escaneamento por tomografia computadorizada de raios X, para a obtenção de características de porosidade em rochas carbonáticas de maneira rápida, mantendo o compromisso com a precisão dos resultados obtidos. O algoritmo desenvolvido será aplicado em amostras de rochas carbonáticas extraídas de formações rochosas, análogas às camadas presentes em reservatórios de pré-sal, localizadas no Nordeste brasileiro.

1.3.2 Objetivos específicos

- Desenvolvimento de uma rotina automatizada de pré-processamento e segmentação de imagens microtomográficas para obtenção de propriedades relativas à porosidade;
- Desenvolvimento de técnicas para calcular o valor de porosidade e extrair propriedades referentes à morfologia dos poros, como a distribuição de tamanho e a distribuição de orientação.
- Avaliação da sensibilidade do método, a partir da redução da quantidade de imagens analisadas como forma de reduzir o tempo de processamento da extração de propriedades petrofísicas.

1.3.3 Contribuições

As principais contribuições deste trabalho incluem a apresentação de uma abordagem de obtenção de propriedades de porosidade em rochas carbonáticas, por meio de um método de processamento de imagens automática e de baixo custo computacional. O método

proposto contribui para reduzir o tempo do processo de caracterização de amostras em estudos preliminares de rochas-reservatório.

1.4 ESTRUTURA DA DISSERTAÇÃO

O texto dessa dissertação está organizado como descrito a seguir. No Capítulo 2, são apresentados conceitos básicos de propriedades petrofísicas, tomografia computadorizada e processamento de imagens. Adicionalmente, este Capítulo aborda os principais trabalhos correlatos a este contexto de aplicações. A descrição dos materiais utilizados como objeto de estudo do trabalho encontra-se no Capítulo 3. O Capítulo 4 apresenta de forma detalhada a abordagem proposta. O Capítulo 5 descreve os experimentos realizados e a análise dos resultados obtidos. A conclusão com as principais contribuições do trabalho e as propostas de trabalhos futuros estão no Capítulo 6.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentados conceitos relevantes acerca dos assuntos correlatos à caracterização de rochas calcárias através de técnicas de segmentação de imagem.

2.1 PROPRIEDADES PETROFÍSICAS

A análise de propriedades petrofísicas em rochas-reservatório fornece estimativas fundamentais para avaliar a viabilidade de exploração para a indústria do petróleo. A verificação da capacidade de armazenamento em reservatórios é realizada através da razão entre o volume dos espaços vazios (também chamado de espaços porosos - V_p) e o volume total (V_t) da rocha (THOMAS, 2001). Essa grandeza, chamada de **porosidade**, é definida por:

$$\phi = \frac{V_p}{V_t} \quad (2.1)$$

Geralmente, os valores de porosidade em reservatórios de petróleo variam entre 5% a 40% (TIAB; DONALDSON, 2004).

O transporte de fluido pelo meio poroso está condicionado a outras propriedades petrofísicas além da porosidade, como a geometria da estrutura dos poros, tamanho dos poros, razão de aspecto, dentre outras características (TAKAHASHI et al., 2013). Segundo Esmaili et al. (2017), há diferentes métodos de obtenção da distribuição de tamanho dos poros e as considerações feitas a partir dessa propriedade ajudam a quantificar características economicamente importantes para o contexto da indústria do petróleo.


2.1.1 Orientação dos poros

A disposição da orientação dos poros fornece algumas informações relevantes sobre a estrutura da rocha. Propriedades relativas à dureza e anisotropia de escoamento de fluido são obtidas a partir desse atributo. Adicionalmente, é possível ter uma melhor compreensão sobre o processo de formação da rocha.

A forma clássica de calcular a orientação dos poros se dá pela estratégia de aplicar à imagem uma elipse que melhor preencha a região do poro detectado e obter a orientação do seu maior eixo, segundo um referencial (EVANS et al., 2009). Os parâmetros calculados por essa abordagem possibilitam quantificar o grau de achatamento do poro (ZDILLA et al., 2016). Esta propriedade, denominada de razão de aspecto (*aspect ratio*), é calculada pela equação 2.2.

$$razão\ de\ aspecto = \frac{eixo\ maior}{eixo\ menor} \quad (2.2)$$

Figura 1 – Representação da obtenção das propriedades de orientação pelo método de alocação de elipse.



Fonte: (KONG et al., 2018) (ADAPTADO).

Dependendo da distribuição de orientações dos poros, pode gerar anisotropia em algumas propriedades na rocha. O trabalho de Griffiths et al. (2017) chegou a conclusão que para o grupo de rochas analisados, a orientação dos poros foi preponderante para determinar a resistência anisotrópica, superando a contribuição referente à geometria dos poros.

2.1.2 Rochas carbonáticas

Rochas carbonáticas ou calcárias são rochas sedimentares, formadas pelo acúmulo de carbonato de cálcio a partir de partes de organismos macroscópicos, que compõem grande parte (cerca de 70%) das reservas de petróleo e gás natural do mundo (TIAB; DONALDSON, 2004). Esse fato impulsionou os estudos sobre esse tipo de rocha à medida em que a concepção aprofundada dos processos de sua formação pode aprimorar a compreensão das propriedades dos reservatórios de petróleo e gás ao redor do mundo. No Brasil, a presença de coquinas, um tipo de rocha calcária, na região do pré-sal elevou a demanda por caracterização dessa rocha.

Em termos petrofísicos, elas se destacam por possuírem uma vasta heterogeneidade relacionada à estrutura dos poros (SMODEJ et al., 2019). Em alguns casos, possuindo uma proporção elevada de poros em escala nanométrica. Esse aspecto traz dificuldades quanto à caracterização das propriedades do meio poroso através de técnicas de processamento de imagens microtomográficas (VIK; BASTESSEN; SKAUGE, 2013).


Diversos trabalhos na literatura apresentaram métodos para quantificar a porosidade de rochas carbonáticas utilizando técnicas avançadas de segmentação de imagem levando em consideração a presença das porosidades como tamanho inferior à resolução do equipamento de medição (porosidade de sub-resolução) (SMAL; GOUZE; RODRIGUEZ, 2018; VIK; BASTESSEN; SKAUGE, 2013). Mas devido às dificuldades intrínsecas ao processo, esta ati-

vidade continua sendo um desafio.

2.2 TOMOGRAFIA COMPUTADORIZADA DE RAIOS-X

A tomografia computadorizada de raios-X é uma tecnologia muito empregada na geologia como forma de obter propriedades de rochas e solos através de seus modelos tridimensionais. O seu funcionamento é dado por um conjunto emissor-detector de raios-X programados para realizar sucessivas medições da intensidade de radiação resultante da interação com o meio permeado, como apresentado na Figura 2.

Figura 2 – Representação do arranjo de aquisição em um sistema de tomografia computadorizada.




Fonte: (HELLIWELL et al., 2013) (ADAPTADO)

O raio-X é uma forma de radiação ionizante gerada artificialmente por meio da aceleração de elétrons contra um material metálico de alto número atômico (NETO et al., 2011). Esse processo ocorre dentro de um compartimento, chamado de tubo de raios-X, que possui dois eletrodos: um cátodo e um ânodo. No cátodo, há um filamento condutor (geralmente feito de tungstênio) por onde circula uma corrente elétrica, responsável por gerar uma nuvem de elétrons em torno deste elemento devido ao efeito termoiônico (HAMANN, 2019).

Uma elevada diferença de potencial (na ordem de milhares de volts), aplicada entre os eletrodos, faz com que os elétrons em volta do filamento sejam atraídos, sob uma alta velocidade, para o ânodo. O ânodo contém uma haste metálica rotatória responsável por receber o impacto dos elétrons, freando-os bruscamente, e por desviar a radiação resultante deste fenômeno. Uma representação esquemática deste arranjo pode ser observada na Figura 3.

O resultado da redução brusca na energia cinética dos elétrons gera radiação eletromagnética, na forma de fótons, caracterizada por alta frequência e alto poder de penetração (HAMANN, 2019). A interação dessa radiação com a matéria gera uma atenuação

Figura 3 – Esquema representativo de um tubo de raios-X.



Fonte: (ROQUE, 2018)

no feixe emitido, reduzindo a quantidade de fótons incidentes no detector. Os principais fenômenos que influenciam nessa interação são: o efeito fotoelétrico, o efeito Compton e a produção de pares (OKUNO; YOSHIMURA, 2010). Essa intensidade do feixe, descrita pela Lei de Beer–Lambert, é definida pela Equação 2.3.

$$I(x) = I^0 \times e^{-\mu x} \quad (2.3)$$

onde $I(x)$ é a intensidade medida no detector, I^0 é a intensidade do feixe incidente original da fonte de raios-X, x é o comprimento do caminho do feixe pelo material, e μ é o coeficiente de atenuação do material, que depende do número atômico e da densidade do material. Esta equação, no entanto, é mais apropriada para feixes monocromáticos. Na prática, os sistemas de raios-X de laboratório normalmente empregam um feixe policromático e o espectro energético nele contido tem relação direta com o efeito dominante na interação da radiação com a matéria (GUNTORO et al., 2019).

A consequência dessa relação faz com que o coeficiente de atenuação do material tenha uma maior dependência do número atômico, para níveis mais baixos de energia (efeito fotoelétrico dominante), e à densidade para maiores níveis (efeito Compton dominante). A escolha do nível energético do tomógrafo tem impacto direto na relação sinal-ruído, na capacidade de penetração e no ajuste do contraste de materiais multifásicos (GUNTORO et al., 2019). Por isso, a escolha adequada dos parâmetros de escaneamento é fundamental para a geração de imagens com maior nitidez.

Uma vez que o processo de escaneamento tenha terminado, é necessário converter o conjunto de dados captados pelos detectores em imagens. Esse processo é chamado de reconstrução. Na reconstrução, são realizadas integrações lineares das intensidades detectadas pelas projeções do volume escaneado para gerar imagens 2D (TAINA; HECK; ELLIOT, 2008). O resultado dessa operação é uma pilha de imagens, que são utilizadas

nas etapas posteriores para análise e visualização do material.

2.2.1 Escala Hounsfield

Frequentemente utilizada em análises envolvendo tomografia de raios-X, a escala de Hounsfield (*Hounsfield Unit* - HU) foi desenvolvida para aplicações no âmbito da medicina em 1980 (HOUNSFIELD, 1980). Trata-se da conversão dos valores de radiodensidade das imagens reconstruídas por novos. Segundo Fonseca et al. (2019), essa transformação pode ser representada pela expressão abaixo:

$$HU = 1000 \frac{\mu - \mu_{ar}}{\mu_{\acute{a}gua} - \mu_{ar}} \quad (2.4)$$

onde, μ_{ar} e $\mu_{\acute{a}gua}$ correspondem ao coeficiente linear de atenuação do ar e da água, respectivamente e μ é o coeficiente de atenuação a ser convertido. Com a aplicação dessa conversão, os valores das intensidades de absorção do ar passam a corresponder a 0 e os da água passam a equivaler a 1000. Portanto, materiais com densidade superior à da água, como é o caso das rochas analisadas, apresentarão intensidades em tons de cinza superior a 1000, conforme essa escala.


2.2.2 Limitações da técnica de tomografia computadorizada

Durante o processo de escaneamento podem haver falhas que acarretem em distorções nas imagens reconstruídas. Essas divergências na representação do volume escaneado são chamadas de artefatos e podem levar a erros na análise dos dados (BRANT; HELMS, 2007). As ocorrências mais frequentes dessas distorções são os artefatos em formato circular (*ring artifacts*) e artefatos formados devido ao endurecimento de feixe (*beam hardening artifacts*) (Figura 4).

Os artefatos circulares são causados por mal funcionamento em alguns detectores do tomógrafo ou por falta de calibração no equipamento. As consequências disso são erros sistemáticos na leitura em pontos dos detectores, causando falhas ao longo de um perímetro circular, como pode ser observado na região central da Figura 4a. A correção deste sinistro pode ser realizada com a recalibração do equipamento e pela implementação de correções por software (BARRETT; KEAT, 2004).

Como o componente de menor energia do espectro de raios-X é mais facilmente atenuado ao passar por uma parte densa, o efeito obtido, caso essa característica não seja tratada, é que as bordas do objeto no volume reconstruído terão intensidades mais fortes, mesmo se o objeto for composto de material homogêneo (TOLLEY; YUE, 2016). Esse efeito é chamado de artefato por endurecimento de feixe. A Figura 4b apresenta a ocorrência deste efeito em uma imagem de rocha. Esta falha pode ser corrigida com a aplicação de filtros físicos no equipamento, calibração ou por compensação por software.

Figura 4 – Artefatos em imagens microtomográficas. (a) Artefato circular e (b) Artefato por endurecimento de feixe.



(a) Presença do efeito causado por artefatos circulares. (b) Efeito causado por artefatos de *beam hardening*.

Fonte: (ROCHE et al., 2010) (ADAPTADO).

2.2.3 Imagens microtomográficas de rochas carbonáticas

Após o processo de escaneamento e reconstrução das imagens, os materiais ganham um modelo virtual, cuja estrutura interna e externa podem ser visualizadas e quantificadas computacionalmente. Na Figura 5a, é possível observar um exemplo de rocha carbonática escaneada ao lado de uma fração do seu equivalente virtual. O volume visualizado na Figura 5b, foi obtido pela renderização das fatias geradas na etapa de reconstrução.

Figura 5 – Imagem de (a) amostra de rocha carbonática e a (b) representação 3D de parte do volume da rocha.




(a) Rocha carbonática. (b) Representação 3D parcial.

Fonte: O autor.

As imagens obtidas pelo processo de μ CT proporcionam aspectos gráficos e analíticos da estrutura interna das rochas. A partir delas é possível distinguir as fases de composição do material e extrair informações sobre o seu meio poroso. A Figura 6 apresenta dois exemplares de fatias de uma amostra de rocha calcária tratada neste trabalho. Na imagem da Figura 6a, é possível notar que a matriz rochosa e os poros estão bem representados, possuindo grande contraste em suas intensidades. No caso da Figura 6b, percebe-se diferenças fortes nas intensidades da matriz, indicando erroneamente a presença de mais de uma fase preponderante na composição da rocha. Esse efeito, gerado no processo de escaneamento, pode implicar erros na análise das imagens.

Figura 6 – Fatias de rocha escaneada. (a) Fatia em bom estado e (b) fatia com falhas de escaneamento.



(a) Fatia de rocha escaneada com boa qualidade. (b) Fatia de rocha escaneada com falhas.

Fonte: O autor.


2.3 PROCESSAMENTO DIGITAL DE IMAGENS

Na computação, as imagens são representadas na forma de matriz. Em imagens monocromáticas, como as que são obtidas pela reconstrução do μ CT, cada elemento da matriz (chamado de pixel - *picture element*) possui uma intensidade luminosa $f(x,y)$, em que x representa o índice das linhas e o y indica o índice das colunas da matriz (GONZALEZ; WOODS, 2002). Devido à discretização em sua representação, a qualidade das imagens digitais depende principalmente de dois fatores: amostragem e quantização.

A amostragem está associada com a quantidade de pixels utilizados para a representação de uma imagem. Este parâmetro está relacionado diretamente com as dimensões da matriz e com a resolução espacial da imagem, medida em dpi (*dots per inch* - pixels por polegada). O efeito de quantização está atrelado à quantidade máxima de níveis de

intensidades luminosas que podem ser representados por pixel, definindo a resolução pelo nível de cinza (ou de cor) da imagem (GONZALEZ; WOODS, 2002). A resolução de cor é definida pela quantidade de bits utilizados na representação do pixel e quanto maior é esse valor, maior é a fidelidade da representação da imagem digital. A Figura 7 apresenta o impacto da amostragem e quantização nas imagens. Levando esses aspectos em consideração, é imprescindível obter imagens com elevado nível de detalhes para extrair, de forma precisa, propriedades petrofísicas, tendo em vista a complexidade associada à estrutura do meio poroso de alguns tipos de rochas.

Figura 7 – Impacto da resolução espacial e da quantização em imagens. As figuras (a), (b) e (c) apresentam diferentes resoluções espaciais e as imagens (d), (e) e (f) possuem diferentes valores de quantização.



Fonte: (JAHNE, 2002) (ADAPTADO).

Esses fatores são determinados no momento da aquisição das imagens pelos dispositivos responsáveis pela captação dos sinais eletromagnéticos. Equipamentos modernos de μ CT conseguem resolução de medição de até $5 \mu\text{m}/\text{pixel}$ (PLESSIS et al., 2017). Quando a informação contida em um pixel aglutina representação de dois ou mais materiais, ele é chamado de *mixel* ou pixel misto (SHAPIRO, 2001). A ocorrência de mixels é frequente na análise de rochas carbonáticas devido a elevada proporção de poros em escala nanométrica. A mesma definição de mixel é aplicada em representações 3D, cuja unidade elementar é chamada de voxel (*volume element*), e são denominados voxels mistos.

2.3.1 Histograma


Uma forma de representar imagens em tons de cinza é por meio do seu histograma. Um histograma, por definição, é expresso pela equação 2.5 (GONZALEZ; WOODS, 2002).

$$h(r_k) = n_k \quad (2.5)$$

onde r_k é o k -ésimo tom de cinza e n_k é o número de pixels que possuem a intensidade de r_k na imagem.

O histograma serve como recurso importante para aplicações de processamento de imagens. Muitos algoritmos se apropriam dessa representação para implementar técnicas de melhoria da imagem, ajuste de parâmetros e compressão (APPIAH; HAYFRON-ACQUAH, 2018). Por possuírem implementação de baixa complexidade computacional e por fornecerem dados estatísticos úteis sobre as imagens, os histogramas são amplamente utilizados em aplicações com restrições de tempo e de recursos de hardware (GONZALEZ; WOODS, 2002).

Figura 8 – Imagem (a) microtomográfica de uma rocha calcária e o (b) histograma da imagem (a).



(a) Imagem em tons de cinza.

(b) Histograma da imagem (a).

Fonte: O autor.

Dentre as operações realizadas a partir da análise do histograma, os algoritmos de segmentação possuem diversas abordagens baseadas em histograma (HAO; LI; LI, 2017). Segmentação de imagem consiste no processo de dividir a imagem em partes que compartilham características similares, chamados segmentos (KAUR; KAUR, 2014). Este procedimento é amplamente utilizado em aplicações médicas, detecção de objetos, serviços de monitoramento, entre outras aplicações. Alguns algoritmos de segmentação baseados

em histograma possuem destaque pela qualidade dos resultados, simplicidade e rapidez na implementação (GOH et al., 2017; CHAUHAN et al., 2016).

2.3.2 Método de Limiarização Otsu

A técnica de segmentação proposta por Otsu (1979), utiliza uma abordagem iterativa para determinar de forma automática um valor de limiar para ser aplicado em toda a imagem. Esta técnica divide a imagens em 2 segmentos: pixels com intensidade inferior ao limiar fazem parte do fundo (*background*) e o restante dos pixels fazem parte do primeiro plano (*foreground*). Essa técnica demonstrou apresentar bons resultados principalmente para histogramas bimodais (SHAPIRO, 2001).

O funcionamento do algoritmo do método de Otsu é baseado na procura pelo mínimo global da soma da variância intraclasse σ_W^2 , cuja expressão é dada pela seguinte equação:

$$\sigma_W^2 = W_b\sigma_b^2 + W_f\sigma_f^2 \quad (2.6)$$

onde W é o peso da classe, obtido pela razão entre o somatório das frequências da classe e o somatório de todas as frequências do histograma. O termo σ^2 é a variância para a classe específica.

Figura 9 – Aplicação da (b) segmentação pelo método de Otsu na (a) imagem em tons de cinza.



(a) Imagem em tons de cinza.

(b) Segmentação da imagem (a).

Fonte: (ZHAN et al., 2015) (ADAPTADO).

Esse cálculo é realizado para todas as intensidades do histograma. No entanto, para tornar o algoritmo mais eficiente, ao invés de calcular o ponto mínimo da variância in-

traclases, utiliza-se o cálculo para maximizar a variância interclasses. Este cálculo é apresentado de forma simplificada pela equação 2.7.


$$\sigma_B^2 = W_b W_f (\mu_b - \mu_f)^2 \quad (2.7)$$

onde μ é a média da frequência dos elementos da classe. Essa forma simplificada acelera a busca do ponto de ótimo porque não é necessário calcular as variâncias diretamente a cada iteração.

2.3.3 Algoritmo Watershed

Diversas aplicações que exploram a extração de propriedades de rochas/solos (LIN et al., 2010; KONG et al., 2018; BONFIM, 2020) utilizam o algoritmo *Watershed* (LANTUEJOUL, 1978) para desempenhar essa tarefa. Essa técnica mostrou-se significativamente mais robusta quando comparada a outras técnicas de limiarização global (LEU et al., 2014).

Figura 10 – Aplicação da segmentação pelo algoritmo *Watershed*. (a) Imagem de moléculas de lipídio e (b) resultado da segmentação.



(a) Imagem em tons de cinza.

(b) Segmentação da imagem (a).

Fonte: (RUSS; DAVIDSON, 2018).

O algoritmo utiliza os atributos de localização e intensidade dos pixels em sua execução. Ele utiliza um conjunto de pixels (chamados de sementes) como critérios de partida da implementação. A partir dos pontos definidos, inicia-se a busca para determinar regiões vizinhas que possuam alto grau de semelhança baseado no cálculo do gradiente da imagem e na utilização de marcadores.

Uma peculiaridade do algoritmo é que a determinação das sementes é fundamental para obter uma segmentação precisa. Como geralmente, essa operação é realizada de

maneira automática, por técnicas de limiarização global, as implicações atreladas à má alocação de sementes podem comprometer o desempenho do algoritmo (LEU et al., 2014).

2.3.4 Agrupamento k-means

Outra técnica de segmentação de imagem bastante usada é o agrupamento k-means (RIDLER; CALVARD, 1978). Trata-se de um algoritmo de aprendizagem de máquina não supervisionado utilizado para classificar os pixels da imagem em uma das k classes. Cada um desses grupos é representado por um ponto no espaço de busca, chamado centroide.

O algoritmo se baseia no agrupamento dos pixels da imagem de acordo com a sua similaridade com os centroides de cada classe. O grau de similaridade entre esses parâmetros é computado pela distância entre eles. Segundo este critério, cada elemento passará a pertencer à classe do centroide mais próximo. O algoritmo calcula uma nova posição para os centroides existentes, baseado no grupo de elementos a ele pertencentes. Esse ciclo continua até que não haja alterações significativas nas posições dos centroides.

De maneira formal, o algoritmo de agrupamento k-means busca encontrar a solução que minimize a função objetivo expressa pela equação 2.8.

$$J = \sum_{i=1}^m \sum_{k=1}^K w_{ik} ||x_i - \mu_k||^2 \quad (2.8)$$

onde $w_{ik} = 1$ se o ponto analisado x_i pertence à classe k , ou $w_{ik} = 0$ caso contrário. O termo μ_k é a posição do centroide da classe k (DABBURA, 2018).

Trabalhos mostraram (QIN; LIU; LIU, 2013; CHAUHAN et al., 2016; EL-NASR; SALEH; ALSHENNAWY, 2020) que essa técnica apresenta boa precisão nos resultados e baixo custo computacional quando aplicada à obtenção de propriedades de porosidade de rochas. Uma desvantagem na utilização deste algoritmo é que a obtenção do máximo global não é garantida e sua precisão é fortemente dependente das condições iniciais dos centroides (PORTER; WILDENSCHILD, 2010).

2.3.5 Operações morfológicas


Operações morfológicas consistem na manipulação da imagem para destacar características relativas à estrutura ou forma do seu conteúdo (GONZALEZ; WOODS, 2002). Geralmente são implementadas através de operações matriciais entre a imagem e um elemento estruturante.

Duas operações morfológicas fundamentais foram usadas: dilatação e erosão. A operação de dilatação da imagem A pelo elemento estruturante B é definida como:

$$A \oplus B = x | (B_x^s), \cap A \neq \emptyset \quad (2.9)$$

em que cada pixel de A será ativo se a interseção entre a versão simétrica do elemento estruturante B^s centrado no pixel x for diferente de zero. O efeito dessa operação pode ser visto na Figura 11.

Figura 11 – Representação de aplicação da operação de dilatação na imagem A pelo elemento estruturante B .



Fonte: (FISHER et al., 2003) (ADAPTADO).

A erosão tem o efeito dual da dilatação e é definida pela equação 2.10.

$$A \ominus B = \{x | B_x \subseteq A\} \quad (2.10)$$


Essa expressão implica que o pixel x , da matriz A , só estará ativo quando o elemento estruturante centrado no pixel x , estiver totalmente contido nessa região de A . A Figura 12 ilustra essa relação. A operação é principalmente utilizada para auxiliar na separação de elementos conectados e para eliminar componentes menores do que o elemento estruturante.

Essas operações servem de base para outras operações similares chamadas de abertura e fechamento. Esse conjunto de operações é frequentemente utilizado em algoritmos de detecção de borda, remoção de ruído e quando deseja-se destacar ou reprimir alguma característica da imagem.

2.3.6 Detecção de contornos em imagens

Um contorno pode ser explicado simplesmente como uma curva que une todos os pontos contínuos (ao longo da fronteira), tendo a mesma cor ou intensidade. Técnicas para detecção de contornos são úteis para análise de formas e detecção e reconhecimento de objetos (OPENCV..., 2020). Neste trabalho, técnicas de detecção de contornos foram utilizadas para analisar a morfologia dos poros individualmente.

Figura 12 – Representação de aplicação da operação de erosão na imagem A pelo elemento estruturante B.



Fonte: (FISHER et al., 2003) (ADAPTADO).

Para auxiliar a análise de contornos, o *OpenCV* dispõe de uma função chamada *findContours*, responsável por encontrar os contornos contidos em uma imagem binária baseado no algoritmo proposto por Suzuki e Abe (1985). Este algoritmo permite obter a localização dos contornos, com isso é possível calcular atributos geométricos como perímetro e área para os contornos encontrados.

2.4 TRABALHOS RELACIONADOS

Nos últimos anos, muitos esforços têm sido dedicados ao estudo do processamento de imagens microtomográficas para a extração de propriedades físicas de rochas. Al-Marzouqi (2018) fez um levantamento sobre as principais características das abordagens empregadas para o estudo de rochas digitais. O autor evidencia o ciclo de trabalho convencional utilizado para o processamento das imagens de μ CT sendo composto majoritariamente pelas etapas de aquisição das imagens 3D, remoção de artefatos, segmentação de imagens e cálculo das propriedades petrofísicas. Esse arranjo de operações pode variar em sua implementação a depender da qualidade das imagens geradas e do tipo de rocha avaliado, podendo agregar mais complexidade à análise com a introdução de mais etapas de filtragem e pós-processamento ao longo do ciclo de trabalho (BERG et al., 2018).

Dentre os processos contidos no fluxo convencional de processamento, as etapas de remoção de artefatos e a segmentação são fundamentais para conferir precisão ao processo de caracterização das amostras. A redução de artefatos nas fatias pode acontecer através da aplicação de filtros digitais ou até mesmo pelo uso de filtro físico inserido na etapa de escaneamento (AL-MARZOUQI, 2018). No estudo realizado por Sell et al. (2016), algumas alternativas foram utilizadas para realizar o aprimoramento das imagens. Neste processo,

um filtro Gaussiano foi aplicado para a suavização das imagens, reduzindo parte dos efeitos dos artefatos. Outros autores indicam que filtros anisotrópicos podem apresentar melhores resultados devido à característica de preservação das bordas contidas na imagem (SCHLUTER et al., 2014; ZAREBA et al., 2018).

Técnicas de segmentação de imagens de rochas digitais estão em constante desenvolvimento. De modo geral, as técnicas de limiarização global demonstraram bons resultados quando aplicados em imagens livres de artefatos e com alto valor na relação de sinal-ruído (BERG et al., 2018). Iassonov, Gebrenegus e Tuller (2009) apresentaram um estudo comparativo de 14 técnicas utilizadas para calcular a porosidade de amostras de composição distintas. Nesse estudo, o método de Otsu foi uma das técnicas de limiarização global que mostraram precisão satisfatória para o cálculo da porosidade.

Ainda considerando essa abordagem de limiarização global, os dados avaliados no trabalho de Farrell e Healy (2017) puderam gerar uma compreensão mais profunda sobre algumas características de formações de arenito em regiões fraturadas, a partir da análise das propriedades físicas obtidas pelo processamento de imagens 2D, geradas por um microscópio eletrônico de varredura (*scanning electron microscope* - SEM).

Na revisão apresentada por Guntoro et al. (2019), é possível notar que uma grande quantidade de algoritmos foi investigada na caracterização de rochas, desde abordagens clássicas até algoritmos modernos de aprendizagem de máquina. Trabalhos recentes mostram como determinadas abordagens trataram essa tarefa para prover bons resultados na quantificação de propriedades petrofísicas. No trabalho de Chauhan et al. (2016), os autores implementaram sete técnicas de aprendizagem de máquina para segmentação de rocha digital (plúgie de andesito). As propriedades extraídas pela análise incluíram a porosidade e informações referentes ao volume dos poros encontrados pela segmentação. Os autores avaliaram a precisão das abordagens comparando os resultados com os dados obtidos por experimentos laboratoriais. Os algoritmos apresentaram boa precisão, produzindo resultados dentro do intervalo de tolerância determinado pelo ensaio físico, na maior parte dos testes.

Dentre as técnicas investigadas nesse estudo, o algoritmo de agrupamento k-means é uma das abordagens de classificação automática mais conhecidas para desempenhar esta tarefa (BERG et al., 2018). Porter e Wildenschild (2010) utilizaram uma versão deste algoritmo para extrair propriedades físicas do meio poroso de amostras sintéticas, cujo resultados mostraram-se bastante precisos com erros inferiores a 2% para o cálculo da porosidade. Recentemente, Sun et al. (2019) avaliaram propriedades em amostras de rochas calcárias utilizando este algoritmo como parte da etapa de segmentação implementada.

O algoritmo watershed é uma das técnicas de segmentação comumente utilizadas para classificar os elementos da imagem em poros e matriz rochosa (AL-MARZOUQI, 2018). No trabalho de Kong et al. (2018), este algoritmo foi utilizado para caracterizar uma amostra sintética e foi obtido um erro de 4,20% no valor da porosidade quando comparado

com os resultados do porosímetro de gás hélio. Além de avaliar a porosidade, foram obtidas as propriedades referentes à morfologia dos poros: distribuição do tamanho, a razão de aspecto, distribuição de orientação e anisotropia. A obtenção dessas propriedades permite compreender melhor as fraquezas na estrutura rochosa, a presença de fraturas e a direção preferencial do escoamento de fluido (FALLAHZADEH et al., 2017). Posteriormente, os autores replicaram o fluxo de trabalho proposto em uma amostra sintética diferente, composta por areia de sílica, e validaram novamente a eficácia da solução proposta (KONG et al., 2019).

Alguns trabalhos focaram em apresentar abordagens para aprimorar a caracterização de rochas calcárias. Freire-Gormaly et al. (2015) exploraram técnicas de segmentação baseadas em limiarização na quantificação dos poros em testemunhos dessa natureza. O trabalho explorou a utilização de duas técnicas de imageamento (μ CT e SEM), associado a alguns métodos de segmentação, para calcular a porosidade de duas amostras de calcários, considerando os poros de diferentes ordens de grandeza (micro e macroporosidades). Os resultados mostraram que o sucesso das técnicas investigadas dependem de fatores como a resolução de escaneamento e o tipo de rocha analisada, destacando a importância do desenvolvimento de métodos robustos para conceder maior precisão às análises nesse campo de pesquisa.

Visando fornecer um método para localizar e quantificar porosidade de sub-resolução, isto é, poros com tamanhos inferiores à resolução de medição, em rochas carbonáticas, Smal, Gouze e Rodriguez (2018) utilizaram uma técnica de segmentação de imagem baseado em limiarização local para desempenhar essa função. Duas imagens de rochas calcárias, obtidas por escaneamento em μ CT com resolução espacial de 5 μ m, foram utilizadas como objeto de estudo. Os resultados de porosidade obtidos, comparados com experimentos realizados em laboratório, mostraram erros de 2,97% e 3,55%.

No trabalho de dissertação de mestrado Nova (2020), foi realizada a quantificação da porosidade de dez rochas carbonáticas através de técnicas de processamentos de imagens aplicadas em imagens obtidas por μ CT e por um método baseado na tomografia computadorizada de raios gama. Os valores de porosidade de ambas as abordagens foram comparados às medições obtidas por experimentos no porosímetro de hélio. A análise dos resultados mostrou que o método de atenuação de raios gama apresentou a melhor taxa de correlação ($R^2 = 0,96$) com os valores do porosímetro, mostrando-se uma excelente alternativa para obtenção do valor de porosidade por meio de uma técnica não-destrutiva.

Considerando apenas as análises em imagens de μ CT, a melhor técnica de segmentação implementada, considerando o critério do coeficiente de correlação, foi o algoritmo de processamento de imagens 3D chamado PVE (*Pure Voxel Extraction*) (ELLIOT; HECK, 2007), cujo R^2 foi igual a 0,702.

É importante ressaltar que sete das dez amostras analisadas por Nova (2020), foram utilizadas como objeto de estudo neste trabalho de dissertação. Este fato permitiu a

comparação dos resultados obtidos com uma abordagem convencional de processamento de imagens 3D.

Poucos trabalhos na literatura apresentam as informações referentes ao tempo de processamento das abordagens para a caracterização de rochas digitais por μ CT. Nova et al. (2020) mostraram que a implementação da abordagem utilizada, através da execução do algoritmo PVE, levou cerca de 2h para extrair o valor de porosidade para um conjunto de plugues de arenito e de rochas calcárias. Os resultados apresentados no trabalho de Chauhan et al. (2016) mostraram que a duração da análise variou entre 15 minutos, para a técnica mais rápida (k-means) e 63 horas, pelo algoritmo de *support vector machine* (SVM). Embora os autores não tenham realizado uma análise detalhada sobre os tempos apresentados no trabalho, sabe-se que processar volumes 3D provenientes de escaneamentos por tomografia computadorizada pode necessitar de um grande tempo de processamento (JU et al., 2018) devido a quantidade de dados processados e à complexidade das operações implementadas.

No estudo apresentado por Porter e Wildenschild (2010), uma das técnicas investigadas para estimar propriedades do meio poroso, considerando amostras contendo mais de uma fase de fluido, mostrou-se computacionalmente custosa, demandando cerca de 4 horas para extrair as informações em volumes com tamanhos típicos de 650x650x515 voxels.

A comparação direta do tempo de processamento entre esses trabalhos nem sempre pode ser realizada devido às diferenças entre as propriedades investigadas, os recursos computacionais disponíveis, o tamanho e a complexidade dos dados processados.

Como a maior parte das propriedades computadas é baseada nas microestruturas 3D das amostras escaneadas, realizar o processamento das fatias 2D surge como uma forma de reduzir o custo computacional da análise. Como apresentado por Saxena et al. (2017), Saxena e Mavko (2015), é possível obter propriedades físicas das rochas de maneira precisa, a partir da análise das imagens 2D, de forma rápida e eficiente. A aplicação deste conceito pode ser explorada em cenários análogos como forma de prover celeridade ao processo de caracterização de propriedades petrofísicas.

3 MATERIAIS

Este trabalho utilizou um conjunto de sete amostras (plugues) de rochas calcárias para análise. Os plugues foram coletados em afloramentos localizados na zona costeira da Bacia da Paraíba, região Nordeste do Brasil. Os testemunhos coletados representam análogos de rochas de reservatórios de hidrocarbonetos, da Formação Tambaba (FILHO et al., 2015), formadas em sistemas de recifes e lagunas. As amostras fazem parte do mesmo conjunto de testemunhos utilizados por Nova (2020).

Tabela 1 – Dimensões das amostras de rochas utilizadas no estudo.

Amostras	Diâmetro (cm)	Altura (cm)	Massa (g)
Amostra 1	$3,753 \pm 0,033$	$5,401 \pm 0,007$	138,25
Amostra 2	$3,773 \pm 0,007$	$3,753 \pm 0,004$	88,55
Amostra 3	$3,755 \pm 0,041$	$5,160 \pm 0,017$	117,92
Amostra 4	$3,761 \pm 0,021$	$7,073 \pm 0,008$	176,48
Amostra 5	$3,768 \pm 0,003$	$7,661 \pm 0,014$	185,14
Amostra 6	$3,769 \pm 0,010$	$3,347 \pm 0,004$	79,66
Amostra 7	$3,755 \pm 0,001$	$7,269 \pm 0,004$	171,04

Fonte: (NOVA, 2020).

As rochas coletadas foram cortadas em formato cilíndrico, com diâmetro médio de 3,76 cm e altura variando entre 3,35 cm e 7,66 cm. As dimensões individuais são apresentadas na Tabela 1. Após a preparação das amostras e das aferições, as rochas seguiram para a etapa de escaneamento no μ CT de raios-X.

Figura 13 – Amostras de rochas calcárias utilizadas no estudo.



Fonte: O autor.

O tomógrafo, de modelo XT H 225 ST fabricado pela *NIKON*, foi utilizado para o escaneamento das amostras. As configurações aplicadas para o imageamento foram definidas como 150 kV, 70 μ A e tempo de integração de 500 ms. Um filtro de alumínio (0,25 mm de espessura) foi inserido para auxiliar no aprimoramento das imagens geradas. A resolução espacial estabelecida foi de 40 μ m/pixel. Todo o processo de escaneamento das amostras e reconstrução das imagens foi conduzido no Laboratório de Tomografia Computadorizada de Raios X (LTC-RX), localizado no Departamento de Energia Nuclear da UFPE (NOVA, 2020).

Figura 14 – Modelo do microtomógrafo utilizado no escaneamento das amostras.



Fonte: (NIKON, 2020).

Após a reconstrução das imagens, foi realizada a conversão dos valores obtidos para a escala de Hounsfield (HU) (HOUNSFIELD, 1980). Cada volume escaneado é representado por um conjunto de imagens 2D, com 16 bits de quantização, na extensão *tiff* (*Tagged Image File Format*). A quantidade de imagens e o volume de dados armazenados para cada amostra pode ser observada na Tabela 2.

Tabela 2 – Dados gerados pela reconstrução das amostras escaneadas pelo μ CT.


Amostras	Quantidade de imagens	Dados armazenados (GB)
Amostra 1	1456	2,88
Amostra 2	1002	1,88
Amostra 3	1353	2,55
Amostra 4	1520	2,74
Amostra 5	1520	2,88
Amostra 6	905	1,70
Amostra 7	1521	2,93

Fonte: O autor.

4 METODOLOGIA

Neste capítulo será apresentada a abordagem proposta pelo trabalho. A partir das imagens geradas na reconstrução das amostras de rochas escaneadas, foi elaborada uma aplicação em *Python 3.7* capaz de extrair características referentes ao meio poroso de maneira automática. Para isso, o método proposto segue o fluxo de operações apresentado na Figura 15. O fluxo proposto é baseado no processamento individual das imagens 2D e na integração dos resultados obtidos ao final da inspeção de todo o volume.

Figura 15 – Fluxograma da rotina de execução da aplicação.



Fonte: O Autor.


As propriedades investigadas pela análise foram: a quantificação da porosidade, a distribuição de poros segundo o seu tamanho e a distribuição da orientação de poros. A técnica proposta permite a obtenção das informações de maneira autônoma e eficiente, não demandando parametrização manual por parte do usuário. Essas características são essenciais para especialistas e técnicos atuando neste campo de aplicação pois, devido à grande quantidade de dados considerados, processos convencionais de análise demandam tempo elevado para extração das propriedades. Por isso, executar a sequência de operações representadas na Figura 15 em um curto período de tempo é essencial para a aumentar a eficiência da abordagem proposta.

4.1 SELEÇÃO DA REGIÃO DE INTERESSE

A primeira etapa do processamento, consiste na determinação da região de interesse (Region of Interest - ROI). Ao invés de se trabalhar com a totalidade da área das fatias, originalmente no formato circular dado que as amostras foram cortadas em cilindros, elaborou-se um algoritmo para obter uma região quadrada inclusa na área circular. Essa estratégia foi adotada para mitigar os efeitos do endurecimento de feixe (*beam hardening*) (MUKUNOKI et al., 2004) e para reduzir o tempo de processamento das imagens ao diminuir a quantidade de dados analisados (ZHANG; XIAO, 2008).

Devido aos pequenos desalinhamentos no posicionamento da amostra no tomógrafo, é muito provável que as fatias obtidas não estejam alinhadas paralelamente ao eixo correspondente à altura do cilindro. O impacto causado por este comportamento implica que fatias distintas podem possuir centros ligeiramente deslocados. Esta característica é evidenciada nas imagens presentes na Figura 16, em que é possível verificar que as imagens não compartilham do mesmo centro em alturas distintas.

Figura 16 – Representação do impacto do desalinhamento da amostra ao longo do eixo longitudinal do cilindro. (a) Fatias das extremidades da amostra, (b) Imagens segmentadas e (c) Sobreposição das imagens segmentadas.




Fonte: O autor.

Levando essa característica em consideração, o algoritmo implementado utiliza a primeira e a última imagem da pilha para determinar a ROI que esteja inclusa na área de interseção de ambas as imagens. Isso implica que para qualquer que seja a fatia analisada no volume selecionado, não haverá regiões externas à rocha contidas na ROI.

O algoritmo recebe como parâmetro de entrada o tamanho inicial do quadrado a ser determinado na figura, em pixels. Em seguida, a primeira e a última imagem da pilha são carregadas (imagem (a) da Figura 16). Após serem importadas, ambas recebem operações morfológicas de fechamento, implementadas utilizando um elemento estruturante de tamanho 5x5. Esta operação foi aplicada para reduzir os efeitos de borda das imagens, permitindo com que extremidades da rocha sejam detectadas com maior clareza.

Logo após esta operação, aplica-se uma segmentação para separar a imagem em 2 classes: rocha e ar (imagem (b) da Figura 16). Com isso, aplica-se um algoritmo de detecção de circunferências, implementado pela função *HoughCircles* presente na biblioteca *OpenCV*, com o objetivo de obter as coordenadas referentes ao centro da rocha, em apenas uma das imagens, para serem utilizadas como ponto de coordenadas centrais (*PC*) da ROI investigada. Esse será o ponto de partida para ajustar um quadrado inscrito nas figuras, como pode ser observado na Figura 17.


Figura 17 – Imagem microtomográfica da amostra de rocha (a) original e (b) após a operação de detecção de circunferência aplicada à imagem segmentada.



Fonte: O Autor.

A partir desta etapa, o algoritmo tentará encontrar de maneira sucessiva, um quadrado de lado W cujos vértices pertençam à região de rocha destacada pela segmentação, na primeira e na última fatia simultaneamente. Quando algum dos vértices não estiver contido na região interna, o quadrado será deslocado no sentido oposto ao(s) ponto(s) de ocorrência da falha, como ilustrado na Figura 18.


Figura 18 – Ajuste automático do posicionamento da região de interesse.



Fonte: O Autor.

A cada movimentação, uma variável de contagem é incrementada e caso atinja o limite máximo de 100 tentativas, definido experimentalmente, o algoritmo reinicia com um valor menor para a variável W . Com isso, o algoritmo reiniciará a busca de uma ROI de área inferior ao que foi definido a princípio. O algoritmo termina quando as condições pré-estabelecidas forem satisfeitas, ou seja, quando os quadrados estiverem devidamente inscritos nas duas fatias, simultaneamente. A Figura 19 apresenta o resultado do algoritmo para uma das amostras utilizadas no trabalho.

Figura 19 – Região de interesse definida para a amostra analisada visualizadas na (a) primeira fatia e (b) última fatia.



Fonte: O Autor.

O Algoritmo 1 apresenta as etapas da seleção da ROI de forma concisa.

As coordenadas e as dimensões provenientes deste algoritmo são fundamentais para o restante das etapas, pois é a partir delas que as imagens tomográficas serão redimensionadas para serem processadas. Conforme apresentado na Figura 15, a preparação das imagens ocorre na etapa de pré-processamento, na qual elas são redimensionadas e filtradas. O filtro selecionado para esta aplicação foi o filtro Gaussiano, cujo efeito implica suavização das transições bruscas nas intensidades entre pixels adjacentes. Sua utilização foi motivada pelo desejo de reduzir ruídos espúrios e minimizar os efeitos causados pelo aparecimento de artefatos em anel.

Durante o desenvolvimento da aplicação, testes com outros filtros foram conduzidos. Dentre as opções avaliadas, o filtro bilateral apresentou excelente performance na remoção dos ruídos, no entanto por ser mais lento que o Gaussiano, foi preterido para a implementação final. É importante ressaltar que o nível de suavização da imagem foi controlado pelo tamanho da janela (kernel) do filtro Gaussiano.

Algoritmo 1: Seleção da ROI do conjunto de imagens.

Input: *numero_de_imagens*, *W*
Output: *coordenadas_da_ROI*

```

1 importa a primeira e a última fatia;
2 aplica a operação morfológica de fechamento nas imagens;
3 aplica a segmentação global nas duas imagens;
4 obtém o centro da circunferência  $(x_c, y_c)$  da última fatia;
5 while final_do_algoritmo == False do
6     numero_de_deslocamentos, validacao = 0;
7     while validacao != 3 do
8         while validacao == 0 do
9             if os vértices da ROI estão inscritos na primeira fatia then
10                 validacao = 1;
11             else
12                 desloca a ROI no sentido oposto aos pontos de falha;
13                 numero_de_deslocamentos += 1;
14                 if numero_de_deslocamentos >= 100 then
15                     break;
16         while validacao == 1 do
17             if os vértices da ROI estão inscritos na última fatia then
18                 validacao = 2;
19             else
20                 desloca a ROI no sentido oposto aos pontos de falha;
21                 numero_de_deslocamentos += 1;
22                 if numero_de_deslocamentos >= 100 then
23                     break;
24         if os vértices da ROI estão inscritos na primeira fatia && validacao == 2
25             then
26                 validacao = 3;
27                 fim_do_algoritmo = True;
28         else
29             validacao = 0;
30         if numero_de_deslocamentos >= 100 then
31             W -= 10;
32             break;
33     return coordenadas_da_ROI;


```

4.2 ALGORITMO DE SEGMENTAÇÃO DE IMAGEM

Após a etapa de pré-processamento, as imagens foram segmentadas com o propósito de distinguir os pixels em poros e matriz rochosa. Para isso, um algoritmo de segmentação por limiarização foi desenvolvido para esta tarefa, tendo como principais requisitos a obtenção de resultados com nível de precisão satisfatórios, de maneira adaptativa e rápida. O algoritmo faz uso da análise do histograma para determinar, de forma automática, o valor de limiarização considerando as intensidades dos pixels detectados nas imagens.

Ao analisar as amostras das rochas calcárias, sabe-se que essas formações rochosas geralmente são compostas por apenas uma fase de mineral e que a composição porosa é bastante heterogênea, possuindo uma fração significativa de porosidade de sub-resolução (VIK; BASTESSEN; SKAUGE, 2013).

Figura 20 – Histograma de uma amostra de rocha calcária. As linhas I_{void} e I_{solid} delineiam o pico da região vazia e da região sólida, respectivamente. As linhas J_1 e J_2 são os limites da região microporosa.



Fonte: (FREIRE-GORMALY et al., 2015).


A heurística utilizada neste método foi baseada na suposição de que as imagens analisadas consistirão de uma representação bimodal e que o valor de limiarização estará contido na região da inclinação ascendente do segundo pico do histograma. Essas premissas foram discutidas anteriormente em trabalhos que consideraram esse tipo de análise (FREIRE-GORMALY et al., 2015) e foram aplicadas visando englobar uma significativa representatividade dos micro-poros, buscando evitar o *overfitting*.

Para a abordagem desenvolvida, o algoritmo utiliza a representação analítica do histograma, representada pelo vetor $(h(x))$, de cada imagem. Como apresentado no Capítulo 2,

h corresponde à quantidade de pixels presentes na imagem, com o valor de radiodensidade x .

A partir dessa representação, o algoritmo utiliza parâmetros intermediários para chegar ao valor de limiar utilizado na segmentação da imagem em análise. Esses parâmetros devem ser um número real no intervalo de $0 < l1 < l2 < 1$, previamente definidos. O limite inferior ($l1$) e o limite superior ($l2$) estão relacionados com o percentual da inclinação de subida do maior pico do histograma. Para melhor ilustrar essa relação, a Figura 21 apresenta a representação gráfica para diferentes valores de $l1$ e $l2$.

Figura 21 – Representação gráfica dos parâmetros $l1$ e $l2$ no histograma.




Fonte: O autor.

Esses limites apresentam uma equivalência no eixo das abcissas ($x1$ e $x2$) que serão utilizados para o cálculo do valor de limiarização através da média aritmética das radiodensidades encontradas. A fim de definir os parâmetros satisfatórios para $l1$ e $l2$, foi realizado uma série de testes para fornecer uma comparação dos resultados de porosidade obtidos com a definição automática do valor de limiarização e os resultados da porosidade obtidos em experimentos de laboratório.

A Figura 22 apresenta informações gráficas indicando como o valor de limiarização é obtido pelo algoritmo. É importante ressaltar que por se tratar de uma análise com operações de baixa complexidade computacional, a segmentação é implementada de forma rápida. Além disso, o valor de saída é ajustado automaticamente conforme a imagem analisada.

Os resultados da segmentação fornecem dados para que as porosidades das fatias sejam calculadas. À medida que as imagens são processadas, as porosidades são armazenadas individualmente num vetor. Ao final da análise, é possível obter um perfil de porosidade ao longo do eixo que acompanha a altura do plugue, bem como obter o valor médio da porosidade da rocha em análise.

Figura 22 – Representação gráfica dos parâmetros do algoritmo de segmentação proposto.



Fonte: O autor.

4.3 EXTRAÇÃO DE CARACTERÍSTICAS MORFOLÓGICAS DO MEIO POROSO


Após a segmentação das imagens, os poros serão processados para que suas propriedades como área, razão de aspecto e orientação sejam extraídas. Por isso, uma rotina de seleção de contornos de poros foi implementada para identificar os poros contidos na imagem individualmente. A implementação deste procedimento foi baseada na função de detecção de contornos *findContours*, disponível na biblioteca *OpenCV*.

A partir da lista de dados com os poros encontrados, é possível ter acesso a algumas propriedades referentes ao formato, tamanho e posição dos mesmos. Para obter as propriedades de área, a função *contourArea* foi utilizada. Os poros encontrados foram agrupados de acordo com sua área em três categorias: pequenos, médios e grandes. Os intervalos de área de cada grupo foram definidos de modo que os poros pequenos tem área inferior a $1,6 \times 10^{-1} \text{mm}^2$, os médios com área entre $1,6 \times 10^{-1} \text{mm}^2$ até $1,92 \text{mm}^2$ e os poros considerados grandes possuem área superior a $1,92 \text{mm}^2$. Em pixels, esses valores são equivalentes a 100 e 1200 pixels². Esses valores foram definidos baseados na área de cobertura dos poros nas imagens.

A contabilização da área de cada poro detectado é fundamental para a obtenção da distribuição de tamanho dos poros. Esta informação é importante na compreensão da estrutura porosa que compõe a amostra de rocha. A partir desta propriedade é possível compreender melhor alguns atributos da rocha como compressibilidade, resistência e permeabilidade (KATE; GOKHALE, 2006). Após a inspeção de todas as imagens disponíveis, são gerados dados para representar a frequência dos poros encontrados conforme a sua

área.


Figura 23 – Representação das categorias de tamanho dos poros detectados. (a) Poros pequenos, (b) poros médios e (c) poros grandes.



Fonte: O autor.

A orientação dos poros também é uma importante propriedade explorada na análise da rocha. A obtenção dessa grandeza foi realizada através da determinação de um retângulo, de menor área possível, capaz de envolver cada poro encontrado (*bounding box*), como nos exemplos apresentados na Figura 24. A aplicação deste recurso permite obter uma simplificação da representação morfológica dos poros por meio de uma aproximação geométrica.

Figura 24 – Bounding boxes encontrados para os poros grandes da imagem.




Fonte: O autor.

A partir das informações das coordenadas dos *bounding boxes* gerados, obteve-se o tamanho dos lados dos retângulos e pôde-se calcular a razão de aspecto. A razão de aspecto é utilizada como critério para definir os poros que seguirão para a análise de orientação, cujo objetivo é quantificar a direção do eixo dominante dos poros individualmente. Foram considerados apenas os poros com razão de aspecto igual ou superior a 1,4. Poros com essa característica apresentam um aspecto mais alongado, exibindo um eixo preferencial para o escoamento de fluxo. A inserção deste critério foi motivada pela necessidade de destacar os eixos preferenciais de deslocamento devido a presença de poros oblongos na rocha (FARRELL; HEALY, 2017).

O ângulo do eixo dominante dos poros encontrados foi calculado pela equação 4.1, através dos vetores obtidos pelas projeções dos *bounding boxes* referentes ao eixo x e ao eixo y. Essa equação resulta em ângulos no intervalo de -90° a 90° , cujo valor central está alinhado com o sentido norte da imagem, conforme apresentado na Figura 25.

$$\hat{\text{ângulo}} = \arctan\left(\frac{\text{eixo } x}{\text{eixo } y}\right) \times \frac{180}{\pi} \quad (4.1)$$

Figura 25 – Bounding boxes encontrados para os poros grandes da imagem com os ângulos calculados.




Fonte: O autor.

Diagramas de roseta foram utilizados para exibir os resultados dos dados computados. Os diagramas de roseta, comumente utilizados em pesquisas na Geologia, como pode ser

visualizado em (MIRANDA et al., 2012), são formas gráficas de representar a distribuição da orientação angular de fraturas ou poros como histogramas polares. Nesta representação, a quantidade de vezes em que os poros são detectados num determinado intervalo angular é proporcional à amplitude da barra naquele intervalo. Como pode ser visto na Figura 26, cada ângulo destacado na imagem à esquerda está associado às barras (em azul) contidas no diagrama de roseta.

Figura 26 – Padronização para a representação da orientação dos poros. (a) Ângulos corrigidos e (b) diagrama de roseta.



Fonte: O autor.

Para obter os valores apresentados na Figura 26 a partir dos dados da Figura 24, foi necessário realizar algumas manipulações para gerar um diagrama que contemple o intervalo total de representação, ou seja, todos os 360°. Neste trabalho, os diagramas de roseta apresentados foram divididos em 20 intervalos 18°, divididos da seguinte maneira: de $[-9^\circ, 9^\circ[$ até $[333^\circ, 351^\circ[$. É válido ressaltar que os intervalos definidos possuem simetria de 180°, visto que trata-se da representação das direções dos poros, portanto não há sentido preferencial.

Ao finalizar a etapa de obtenção da orientação dos poros, o algoritmo trata de repetir os procedimentos descritos a partir da fase de pré-processamento para a próxima fatia do volume. Este ciclo continua até que todas as fatias tenham sido analisadas. Ao concluir o processamento de todas as imagens, é realizado o registro do tempo de execução da aplicação. Em seguida, as informações extraídas são exportadas na forma de arquivos de texto, em formato .csv, e por meio de gráficos.


5 RESULTADOS E DISCUSSÃO

A fim de validar a abordagem desenvolvida em termos de precisão e tempo de execução, o método proposto no Capítulo 4 foi aplicado na análise dos sete plugues das rochas calcárias descritas no Capítulo 3.

Uma vez que as imagens foram reconstruídas e reescaladas, foi realizada uma triagem para eliminar imagens inapropriadas para serem processadas. Elas foram desconsideradas por apresentarem falhas graves na representação virtual da rocha. Do total de 9276 imagens disponíveis, foram eliminadas 1326 unidades (14,29%) nesse processo. Geralmente, a ocorrência dessas falhas encontram-se nas fatias localizadas próximas às extremidades da pilha. Alguns exemplares das fatias removidas podem ser observados no Figura 27.

Após a remoção das imagens defeituosas, o processamento dos dados foi conduzido utilizando a abordagem proposta. Em seguida, foram calculados os valores da porosidade de cada amostra, as informações sobre as áreas dos poros e a distribuição dos poros relativos à orientação. Além disso, foram realizados registros do tempo de execução da processamento de cada amostra como critério de avaliação do custo computacional da técnica proposta.

Figura 27 – Exemplos de imagens removidas durante a triagem.



Fonte: O autor.

Como apresentado na Figura 15, a primeira etapa do método proposto consiste no pré-processamento das imagens. O algoritmo de seleção da região de interesse se encarrega de

extrair uma área, de forma quadrada, da região da rocha para ser utilizada no restante do processamento. A dimensão inicial definida para a ROI foi de 650x650 pixels. O algoritmo de seleção da ROI convergiu para todas as amostras, porém não encontrou a área máxima da ROI em todos os casos. Resultando em dimensões específicas para diferentes amostras como pode ser visto na Tabela 3.


Tabela 3 – Quantidade de imagens analisadas e dimensões da região de interesse.

Amostras	Quantidade de Imagens	Dimensões da ROI (pixels)	Coordenadas do centro da ROI
Amostra 1	1250	640x640	518,530
Amostra 2	700	650x650	494,518
Amostra 3	1200	640x640	520,522
Amostra 4	1370	650x650	506,500
Amostra 5	1350	650x650	512,508
Amostra 6	640	650x650	514,518
Amostra 7	1440	640x640	524,534

Fonte: O autor.

Os casos em que o algoritmo não foi bem sucedido na primeira tentativa, buscando encontrar uma ROI de 650x650, podem estar relacionados a um desvio significativo entre as fatias das extremidades ou com a forma com que o algoritmo aplica os movimentos do ROI para corrigir as divergências. Pode ser que a movimentação no sentido oposto aos pontos de falha não seja a melhor opção em algumas circunstâncias.

Figura 28 – Representação da determinação de ROI (vermelho) na Amostra 1. A região em verde representa a interseção entre a área da rocha na primeira (amarelo) e na última fatia (azul).




Fonte: O autor.

No caso da Amostra 1, foi observado que a diferença das coordenadas centrais da primeira e da última fatia resultaram em condições de contorno mais restritas para a determinação de um quadrado com 650 pixels de lado, como apresentado na Figura 28. Nota-se que da forma em que está apresentada na figura, essa não seria uma ROI válida por falhar no vértice inferior esquerdo. Como este pode ser um cenário sem solução possível, o algoritmo reduz o tamanho da ROI assim que atingir o limite máximo de iterações permitidas.

Em situações em que é possível determinar uma ROI na área disponível, é importante considerar a forma com a qual o algoritmo aplica as correções em termos de direção e em relação à amplitude do passo realizado em número de pixels. Ele foi programado para responder de forma determinística a cada correção necessária, movendo-se no sentido oposto ao ponto de falha com passo de 2 pixels. No entanto, nem sempre a movimentação realizada por esta regra é a melhor opção possível. Mesmo com essas restrições, apenas as amostras 1, 3 e 7 tiveram área da ROI inferior a 650x650 pixels.

Figura 29 – Pré-processamento em uma (a) fatia da Amostra 6. (b) Recorte da região de interesse e (c) aplicação de filtro na imagem redimensionada.



Fonte: O autor.

Uma vez que a ROI tenha sido determinada, o processo de análise das imagens é

iniciado. A partir desta etapa, cada imagem selecionada recebe o mesmo conjunto de operações para obtenção das características do meio poroso nela contido. Iniciando pelo recorte da ROI e aplicação do filtro Gaussiano, com kernel de tamanho 5x5. Este parâmetro foi definido de modo experimental e projetado para que o filtro não tornasse a imagem muito suavizada, ao ponto de perder a representação das curvas de contorno dos poros mais evidentes. A preservação dessas características pode ser observada nas Figuras 29.b e 29.c.

5.1 RESULTADOS DA SEGMENTAÇÃO

Após o pré-processamento, as imagens foram conduzidas para a etapa de segmentação com a implementação do algoritmo de limiarização global proposto. Os valores dos parâmetros determinados para o algoritmo foram de $l1=0,3$ e $l2=0,7$. Esses valores foram atribuídos após uma sequência de testes em que os valores de validação foram considerados. Com isso, os valores de limiar encontrados para cada amostra podem ser vistos na Tabela 4.

Tabela 4 – Intervalo com valores de limiarização aplicados na segmentação das amostras.


Amostras	Valor de limiarização		
	Mínimo	Máximo	Médio
Amostra 1	2160	2315	2272
Amostra 2	2034	2222	2167
Amostra 3	1788	2151	2113
Amostra 4	2069	2216	2160
Amostra 5	2067	2401	2229
Amostra 6	2139	2266	2235
Amostra 7	2148	2263	2220

Fonte: O autor.

O resultado da segmentação em algumas imagens pode ser visto na Figura 30, para as amostras utilizadas no estudo. Como não há um *ground truth* para o conjunto de dados no estudo, a validação deste processo foi realizada pela comparação dos valores gerais de porosidade obtidos por essa técnica e por ensaios físicos realizados em laboratório.

Além da técnica de segmentação proposta, ao longo do estudo foram implementadas outras técnicas para avaliação como a limiarização pelo método de Otsu, Watershed e agrupamento por k-means. Estes algoritmos foram escolhidos por terem apresentado bons resultados na caracterização de minerais a partir de imagens de μ CT, como aponta o *review* realizado por Guntoro et al. (2019). Apesar dos métodos terem demonstrado bons resultados na análise de rochas de outra natureza (LEU et al., 2014; TAUD et al., 2005), a implementação desses métodos ao conjunto de dados disponíveis neste trabalho foi fundamental para avaliar o desempenho das estratégias em termos de precisão e em relação


Figura 30 – Fatia da Amostra 7 segmentada pela técnica proposta. (a) Imagem original e (b) Imagem segmentada (valor de limiar = 2221).



Fonte: O autor.

ao tempo de execução. A Figura 31 apresenta o resultado da segmentação utilizando as técnicas citadas.

Figura 31 – Fatia da Amostra 7 segmentada por diferentes métodos: (a) Método de limiarização Otsu, (b) Watershed e (c) Agrupamento K-means.




Fonte: O autor.

A partir da comparação entre as Figuras 30 e 31 é possível observar que o método de segmentação proposto considera uma maior fração de região porosa contida na imagem. Este comportamento foi determinante para considerar uma maior proporção dos pixels mistos e como forma de compensar a dificuldade de determinar a fração da porosidade de sub-resolução.

5.2 ANÁLISE DE POROSIDADE

A análise de porosidade obtida pela técnica de segmentação proposta das sete amostras, gerou as curvas de porosidade mostradas na Figura 32. Por meio das informações contidas nas curvas é possível avaliar como a porosidade varia nos planos transversais ao longo do eixo correspondente à altura dos plugues.

Figura 32 – Perfil de porosidade das amostras.



Fonte: O autor.

A porosidade média das amostras é apresentada na Tabela 5, juntamente com o percentual do volume analisado comparado ao volume total da amostra. Como resultado do recorte das imagens devido à seleção da região de interesse, há uma redução na representatividade volumétrica (RV), expressa pela equação 5.1, da rocha sob análise de até 40,76% devido apenas a este fator. Considerando também as fatias removidas antes do início da análise, a representatividade volumétrica média foi de 48,11%.

$$RV = \frac{\text{volume analisado}}{\text{volume total}} \quad (5.1)$$

Tabela 5 – Valores de porosidade obtidos pela técnica de segmentação proposta e a representatividade volumétrica da análise.

Amostras	Porosidade (%)	Representatividade volumétrica (%)
Amostra 1	13,62	54,84
Amostra 2	15,30	45,11
Amostra 3	21,35	55,05
Amostra 4	17,64	47,14
Amostra 5	23,36	42,73
Amostra 6	24,91	45,00
Amostra 7	27,00	46,89

Fonte: O autor.

Como critério de comparação, os valores de porosidade provenientes da segmentação das outras técnicas implementadas neste trabalho e por Nova (2020) estão apresentados na Tabela 6. Os dados obtidos por Nova (2020) foram utilizados pelo fato do estudo ter sido aplicado ao mesmo conjunto de rochas aqui analisados. A técnica selecionada do trabalho de Nova (2020) foi a técnica de *Pure Voxel Extraction* (PVE) devido à sua relevância no campo de caracterização de porosidade em rochas e minerais (COSTA et al., 2018) e pela boa precisão apresentada nos trabalhos citados.

A validação dos valores de porosidade obtidos foi feita através da comparação com os resultados de experimentos realizados em laboratório com um porosímetro de gás hélio. Os ensaios foram realizados no Laboratório de Engenharia de Reservatórios de Petróleo (LABRES), vinculado ao Departamento de Engenharia de Petróleo (DPET) da Universidade Federal do Rio Grande do Norte (UFRN). Os resultados deste ensaio estão mostrados na Tabela 7.

A análise de erro das técnicas de segmentação avaliadas indicam que algumas delas não conseguiram representar as porosidades de maneira satisfatória. A Figura 33 deixa este fato evidente ao apresentar graficamente todos os resultados de porosidade obtidos pela técnica proposta, pelas outras técnicas de segmentação juntamente com os valores adquiridos pelo porosímetro.

Tabela 6 – Porosidade calculada por diferentes técnicas de segmentação

Amostras	Porosidade (%)			
	Otsu	Watershed	K-means	PVE
Amostra 1	39,27	35,20	37,30	6,78
Amostra 2	18,63	4,13	20,88	17,59
Amostra 3	8,23	6,20	16,95	22,78
Amostra 4	8,27	3,98	18,56	11,74
Amostra 5	15,83	7,23	18,05	22,87
Amostra 6	14,09	8,40	17,89	26,17
Amostra 7	8,91	8,48	14,06	18,45

Fonte: O autor.

Tabela 7 – Porosidade obtida pelo Porosímetro de Gás Hélio

Amostras	Porosidade (%)
Amostra 1	16,17
Amostra 2	24,38
Amostra 3	27,29
Amostra 4	21,05
Amostra 5	22,71
Amostra 6	24,39
Amostra 7	25,21


Fonte: (NOVA, 2020).

Como pôde ser observado no gráfico da Figura 31, as implementações da segmentação pelos métodos de Otsu e por Watershed destacaram majoritariamente os poros mais evidentes. O fato de não considerarem com algum grau de relevância a proporção das porosidades intermediárias impactou diretamente num valor de porosidade inferior ao calculado pelo porosímetro.

A técnica de agrupamento por k-means apresentou baixas taxas de erro para a maioria das amostras analisadas e obteve bons resultados como forma de extrair características petrofísicas desse conjunto de rochas (CARDOSO; BARROS; BARBOSA, 2020). No entanto, durante a análise desse algoritmo, notou-se que o mesmo apresentava um comportamento indesejado ao ser aplicado nesse contexto. Observou-se que em imagens com elevado percentual de poros, o valor do limiar de segmentação sofre uma redução quando comparado com imagens com menos poros evidentes. Isso implica que a porosidade calculada possui comportamento inversamente proporcional ao esperado.

Essa característica fica evidente ao se comparar os resultados obtidos entre os resultados da Amostra 1 e a Amostra 7, por se tratar de amostras com estrutura porosa muito divergentes, exemplificada na Figura 34. A Amostra 1 é o testemunho com a maior pre-

Figura 33 – Resultados de porosidade obtidos pelas técnicas de segmentação de imagens e pelo porosímetro.



Fonte: O autor.


dominância de poros de sub-resolução, dentre as amostras utilizadas no estudo, e quase não há grandes poros evidentes nas imagens escaneadas. Pela dificuldade em quantificar os poros nessas condições a partir da segmentação, este é o exemplar mais desafiador em termos de extração de porosidade. Já a Amostra 7, apresenta uma diversidade maior de poros, contendo muitos poros considerados médios e grandes.

Ao comparar as porosidades das amostras 1 e 7, respectivamente, obtidas pelo porosímetro (16,17% e 25,21%), com os valores calculados utilizando o algoritmo de k-means (37,30% e 14,06%), nota-se que houve uma consideração excessiva da porosidade para a Amostra 1 e uma sub-quantificação de poros para o plugue número 7. Esse comportamento foi similar também nas técnicas de limiarização pelo método de Otsu e Watershed. Dentre as abordagens já conhecidas na literatura e que foram apresentadas neste trabalho, a técnica baseada no algoritmo de PVE mostrou-se como sendo a mais confiável, apresentando um baixo valor de erro e alto índice de correlação quando comparados aos valores obtidos pelo porosímetro ($R^2 = 0,70$) (NOVA, 2020). Neste caso, o valor de R^2 indica o grau de dependência linear entre as medições de porosidade.

Considerando a análise de erro para a porosidade entre todas as técnicas discutidas, observa-se que os resultados obtidos pela técnica de segmentação proposta apresentaram baixa taxa de erro, resultando na menor raiz do erro médio quadrático (RMSE) dentre elas (4,47%), como pode ser visto na Figura 35. Consequentemente, o valor médio do erro absoluto do algoritmo proposto também foi o menor dentre as análises, com valor igual a 3,42%.


A heurística utilizada para o ajuste dinâmico do limiar corroborou a capacidade do

Figura 34 – Representação do impacto do algoritmo de segmentação k-means em amostras com composição porosa distintas.



(a) Fatia da Amostra 1.

(b) Fatia da Amostra 7.




(c) Segmentação da fatia da Amostra 1.

(d) Segmentação da fatia da Amostra 7.

Fonte: O autor.

algoritmo em se adaptar à variação dos dados de entrada de maneira satisfatória. A técnica proposta mostrou-se robusta ao tratar amostras com composição porosa variada, mantendo a consistência das inferências para a maior parte dos casos.

Figura 35 – Raiz do erro médio quadrático das técnicas de segmentação analisadas.



Fonte: O autor.

5.3 CARACTERIZAÇÃO DOS POROS


Na sequência do fluxo proposto, o algoritmo se encarrega de extrair características morfológicas dos poros destacados na etapa de segmentação. Ao serem individualizados pela técnica de detecção de contornos, a área de cada poro é contabilizada. Ao final do processamento de todas as imagens, pode-se representar a distribuição dos poros conforme a área presente no volume das rochas analisadas.

A Figura 36 apresenta a frequência acumulada dos poros encontrados de acordo com a sua área. Esta é uma forma de expressar traços da composição da porosidade de maneira mais detalhada, levando em consideração também a morfologia dos elementos do meio poroso.

A Figura 37 exhibe a comparação da composição das porosidades das amostras em relação à área. Percebe-se que a formação da porosidade entre as amostras diverge consideravelmente. Por meio do gráfico, pode-se dividir as amostras analisadas em 2 sub-grupos. O primeiro sub-grupo é representado pelas amostras cuja composição porosa é predominantemente formada por poros de áreas pequenas. Este é o caso das amostras 1, 2 e 4. Essa característica está atrelada diretamente aos valores de porosidade medidos, dado que as amostras com menor percentual de poros em sua composição fazem parte deste conjunto.

No restante das amostras, nota-se que a proporção de poros grandes representam um valor considerável na porosidade total do plugue. Para ilustrar este fator basta observar o comportamento das curvas para áreas de até 50 mm². No caso da Amostra 6, os poros com área igual ou inferior a este valor correspondem a cerca de 51,4% do valor total de porosidade, enquanto que no caso da Amostra 1 esse intervalo seria correspondente a

Figura 36 – Frequência acumulada dos poros conforme a área.




Fonte: O autor.

94,3% presente no plugue.

A análise do erro desses dois sub-grupos ratifica quantitativamente a dificuldade dos algoritmos de segmentação em quantificar a porosidade em rochas cuja proporção de porosidades de sub-resolução é expressivo. Constatou-se uma taxa de erro 85% superior para as amostras com maior representatividade dos micro-poros ($RMSE = 5,79$), quando

Figura 37 – Comparação da representatividade da porosidade de acordo com a área.




Fonte: O autor.

comparado com o valor das amostras do sub-grupo 2 ($RMSE = 3,13$).

5.4 DISTRIBUIÇÃO DA ORIENTAÇÃO DOS POROS

Além da caracterização realizada em razão da área, foram obtidos dados sobre a orientação dos poros encontrados. Esses resultados são fundamentais para compreender melhor os casos de anisotropia e avaliar de maneira apropriada condições referentes à dinâmica de escoamento dos fluidos na região. Os diagramas de roseta foram utilizados como objetos gráficos de representação da distribuição da orientação dos poros obtidos pela técnica proposta.

Figura 38 – Diagramas de roseta para os poros (a) pequenos, (b) médios e (c) grandes da Amostra 5.




Fonte: O autor.

Conforme proposto no algoritmo, os poros encontrados foram divididos em três classes, conforme a sua área. A Figura 38 apresenta os resultados dessa análise para a Amostra 5. Nota-se que cada classe de poros apresenta regiões de dominância distintas. Como as orientações dos poros de maior área tendem a ser mais relevantes pela capacidade de condução de fluido, serão apresentados os resultados obtidos para os poros dessa categoria para todas as amostras.

Como forma de validação desses resultados, foi conduzido em paralelo o processamento do mesmo conjunto de amostras utilizando o software *ImageJ* e a técnica de segmentação de limiarização pelo método de Otsu. Apesar desta técnica não ter apresentado bons resultados para o cálculo da porosidade, mostrou desempenho razoável na determinação dos macro-poros. Por isso, ela foi utilizada para obter valores de referência para comparação da orientação dos poros grandes. A obtenção dos ângulos foi realizada a partir do recurso que consiste na aplicação de uma elipse nos poros encontrados e com isso, calcular a orientação da elipse de acordo com o posicionamento dos seus eixos. Trata-se de uma técnica tradicional da literatura, usualmente aplicada nesse contexto (BONFIM, 2020).

A Figura 39 contém os diagramas de roseta obtidos por ambos os métodos. Na Figura 39a é possível verificar o resultado da análise sobre a orientação dos poros através da abordagem proposta. A imagem à direita, Figura 39b, contém a representação obtida

Figura 39 – Comparação do diagrama de orientação dos poros grandes da Amostra 7.




Fonte: O autor.

usando os recursos do ImageJ. Essa forma de comparar os resultados foi replicada para as outras amostras e apresentadas na Figura 41.

Os diagramas gerados apresentaram alto grau de semelhança entre os modelos obtidos e os dados de referência para a maioria das amostras. A correlação entre os resultados, expressa pelo coeficiente de determinação (R^2), mostra que os modelos encontrados para 5 amostras apresentaram valores superiores a 77%.


Figura 40 – Correlação entre os diagramas de orientação de poros obtidos pelo método proposto e por técnica clássica com o ImageJ.



Fonte: O autor.

O sucesso dessa análise pode ser atribuído ao fato das técnicas de segmentação utilizadas terem apresentado resultados similares. Para as amostras 1 e 2, percebe-se que não houve alto grau de similaridade entre as representações como nos outros casos. Um dos motivos associados a essa discrepância está na dificuldade de segmentação para as amostras com maior concentração de poros de menor área, como pode ser visto na Figura 36. Para esses casos, algoritmos de segmentação mais sofisticados são necessários para prover informações mais precisas quanto à morfologia dos poros.

Figura 41 – Comparação do diagrama de orientação dos poros grandes das amostras.



Fonte: O autor.

5.5 TEMPO DE PROCESSAMENTO

Como parte fundamental do estudo, o tempo de execução da implementação da técnica proposta foi registrado para cada amostra. Os tempos podem ser visualizados na Tabela 8 e mostram que a técnica proposta levou em média 08:56s para analisar os dados de uma amostra, representada por 1136 imagens em média. Esses valores foram obtidos pela execução em um computador com as seguintes configurações: processador Intel i7-4500 (1,8GHz - 2,4GHz), 8GB de memória RAM e GPU *Nvidia Geforce* 840M. Embora presente no computador, o processamento em GPU não foi constatado durante a execução das análises.

Tabela 8 – Tempo de execução do método proposto.

Amostras	Tempo (min:s)
Amostra 1	11:06
Amostra 2	6:56
Amostra 3	9:16
Amostra 4	13:23
Amostra 5	5:31
Amostra 6	3:41
Amostra 7	12:41
Tempo médio	8:56

Fonte: O autor.

Os resultados mostraram que o tempo de processamento para o algoritmo proposto não está associado apenas ao volume do conjunto de dados de entrada. Esse aspecto pode ser notado pela comparação entre os tempos de análise das Amostras 4 e 5. Como apresentado na Tabela 3, apesar destas amostras apresentarem volumes de dados muito similares, a execução das análises tiveram durações bem discrepantes. Este comportamento pode ser justificado pelo fato da análise morfológica dos poros depender da quantidade de poros destacados na etapa de segmentação.

Comparando esses resultados com o tempo de processamento das outras técnicas de segmentação aplicadas (Otsu, Watershed e k-means) ao mesmo conjunto de dados, constatou-se que o algoritmo proposto apresentou o 2º menor tempo médio, ficando atrás apenas do método de Otsu (5:58s). Dois fatores foram preponderantes para que esta técnica tivesse um tempo tão reduzido: a velocidade do algoritmo e a influência da sub-detecção de poros, o que tornou a etapa de análise morfológica mais rápida. Os resultados da medição dessa análise podem ser vistos na Tabela 9. O tempo de processamento do algoritmo de PVE, não foi apresentado no trabalho publicado, por isso não foi utilizado como elemento de comparação.

Sabe-se que grande parte dos softwares comerciais demandam um tempo significativo

Tabela 9 – Tempo de execução das técnicas de segmentação avaliadas.

Amostras	Tempo de processamento (min:s)		
	Otsu	Watershed	K-means
Amostra 1	10:16	14:10	12:35
Amostra 2	4:01	8:43	6:24
Amostra 3	5:08	13:58	10:36
Amostra 4	6:31	17:12	13:49
Amostra 5	4:38	16:03	12:43
Amostra 6	2:22	7:53	5:30
Amostra 7	5:13	12:33	14:29
Tempo médio	5:58	15:45	10:52

Fonte: O autor.

para extração de algumas características petrofísicas de rochas digitais devido a diversos fatores: o volume elevado dos dados de entrada, as múltiplas etapas de parametrização e a complexidade computacional na execução dos algoritmos são as principais causas desse gargalo. Dependendo dos algoritmos implementados, além da demanda de tempo, há requisitos restritos sobre a capacidade computacional da máquina que executará as tarefas.


Casos como este podem ser observados no trabalho de Chauhan et al. (2016), cuja aplicação levou 15:35s, no melhor dos casos, para extrair informações do meio poroso de 10 fatias de um plugue de arenito. Em Bonfim (2020), a autora realizou análise de fraturas em imagens de formato 1000 x 1000 pixels e obteve tempo médio de execução de 2,76 segundos por imagem.

Nesse estudo, ao todo foram analisadas 7950 fatias, resultando em um tempo médio de execução de 0,47s por fatia. É válido ressaltar que a obtenção desses resultados não dependeu de parametrizações por parte do usuário. Todos os procedimentos foram realizados de maneira automática desde a importação dos dados até a exportação dos resultados.

Visando reduzir o tempo médio da análise por amostra, foram realizados testes de sensibilidade para avaliar como o sistema proposto se comporta ao extrair as mesmas propriedades considerando um número menor de fatias por volume. Os testes foram conduzidos a partir de execuções adicionais do método proposto em que, ao invés de importar fatias subsequentes da pilha para serem analisadas, foram importadas imagens igualmente espaçadas, como pode ser visto na Figura 42. A consequência direta provocada por esta alteração é refletida na redução do tempo de processamento demandado por amostra.

A implementação desses experimentos permitiu avaliar o impacto das novas condições sobre os resultados obtidos anteriormente. A Tabela 10 apresenta os valores de porosidade obtidos nos testes de sensibilidade. Nota-se que a dispersão da porosidade foi muito baixa em todos os casos, de modo que os desvios padrões calculados para as novas medições

Figura 42 – Representação da alteração da amostragem das imagens da pilha durante os testes de sensibilidade. Considerando (a) 100% do volume, (b) 50% do volume e (c) 25% do volume.



Fonte: O autor.

foram inferiores a 0,1% em relação ao valor computado com 100% das imagens. No pior cenário, quando 1/20 das fatias foram utilizadas, o valor do RMSE aumentou em apenas 0,05%, equivalente a uma piora de 1,06% quando comparado ao valor original. A consistência das medições pode ser atribuída à relação de continuidade da porosidade ao longo da amostra, como pode ser observado nos perfis exibidos na Figura 32, em que as taxas de amostragem empregadas foram capazes de coletar as principais características da curva de porosidade das amostras.

Tabela 10 – Resultados de porosidade obtidos pelo método proposto considerando frações de 100%, 50%, 25%, 20%, 10% e 5% das imagens.


Fração dos dados analisados	Porosidade (%)						
	Amostra 1	Amostra 2	Amostra 3	Amostra 4	Amostra 5	Amostra 6	Amostra 7
100%	13,62	15,30	21,35	17,64	23,36	24,91	27,00
50%	13,62	15,34	21,36	17,62	23,35	24,90	27,02
25%	13,61	15,33	21,35	17,60	23,36	24,88	27,02
20%	13,64	15,29	21,28	17,62	23,33	24,87	27,02
10%	13,62	15,30	21,29	17,59	23,32	24,79	27,04
5%	13,65	15,21	21,25	17,56	23,20	24,76	27,02

Fonte: O autor.

Além da porosidade, os dados relacionados à distribuição da área dos poros também foram avaliados. O gráfico da composição das porosidades das amostras de acordo com o tamanho dos poros encontrados é exibido na Figura 43, para o teste de sensibilidade conduzido com 5% das imagens. Qualitativamente, nota-se que os traços da composição da porosidade mantiveram-se muito similares aos obtidos pela inspeção de todas as fatias

disponíveis para cada rocha (Figura 36). Analiticamente, pode-se constatar a semelhança entre as curvas através do cálculo dos coeficientes de correlação, cujo valor médio para as sete amostras foi igual a 0,998. A principal diferença notada entre as curvas obtidas neste caso, com as curvas apresentadas na Figura 36, está associada à aparência discretizada para algumas rochas. O surgimento deste comportamento é devido à quantidade reduzida de classes de poros contabilizados. Este fato ocasionou transições mais bruscas entre poros detectados com áreas distintas.

Figura 43 – Comparação da representatividade da porosidade de acordo com a área, considerando o processamento de 5% das fatias.




Fonte: O autor.

A análise do teste de sensibilidade segue com a verificação dos diagramas com as orientações dos poros encontrados. Assim como no fluxo original, a cada execução com um número reduzido de imagens foram armazenados as distribuições de orientação dos poros detectados. Para comparar os resultados, os diagramas obtidos com processamento completo das imagens foram utilizados como modelos de referência. Apenas os diagramas com a representação dos poros grandes foram utilizados pela relevância em seu significado físico. Foi observado que as direções com maior dominância foram preservadas em todas as imagens amostradas. Preponderantemente, houve apenas uma mudança de escala nas amplitudes dos eixos, devido à redução na quantidade de poros detectados.

Em relação ao tempo de processamento, houve uma redução significativa na duração dos experimentos, como esperado. A partir dos dados apresentados na Tabela 11, verifica-se que essa redução foi proporcional à fração do volume total analisado em cada execução. O tempo médio de processamento dos plugues foi reduzido de 8:56s para 0:23s quando apenas 5% das imagens foram utilizadas na análise. É válido ressaltar que a precisão

Figura 44 – Comparação da distribuição de orientação dos poros grandes após o processamento de 5% e 100% das imagens.



Fonte: O autor.

dos resultados avaliados neste trabalho não foram afetadas de maneira impactante pela diminuição no número de imagens analisadas.

Portanto, esses experimentos demonstraram que ao importar fatias igualmente espaçadas num conjunto de imagens microtomográficas foi possível reduzir o tempo de aquisição de algumas propriedades petrofísicas para o conjunto de amostras analisados. Uma hipótese que poderia justificar este resultado está relacionado à composição das microestruturas contidas no volume apresentarem continuidade capaz de ser representada pela

Tabela 11 – Tempo de processamento obtido pelo método proposto considerando frações de 100%, 50%, 25%, 20%, 10% e 5% das imagens.

Fração dos dados analisados	Tempo de processamento (min:s)						
	Amostra 1	Amostra 2	Amostra 3	Amostra 4	Amostra 5	Amostra 6	Amostra 7
100%	11:06	6:56	9:16	13:23	5:31	3:41	12:41
50%	6:08	3:13	4:33	6:05	3:52	2:09	5:42
25%	2:28	1:26	2:06	2:36	1:33	0:46	1:51
20%	2:08	1:18	1:56	2:24	1:23	0:41	1:42
10%	1:02	0:33	0:46	1:02	0:27	0:19	0:47
5%	0:30	0:20	0:23	0:36	0:16	0:10	0:24

Fonte: O autor.

taxa de amostragem espacial utilizada nos experimentos.

6 CONCLUSÃO

6.1 CONCLUSÃO

Este trabalho apresentou uma abordagem para extração de propriedades petrofísicas do meio poroso em imagens microtomográficas 2D de rochas carbonáticas. O método proposto inclui uma técnica de segmentação de imagens, baseada na análise do histograma, para calcular os valores de porosidade, a área e a orientação dos poros.

Todos os procedimentos contidos no fluxo da análise foram desenvolvidos para se adaptar de maneira autônoma aos diferentes conjuntos de imagens de entrada utilizadas no estudo. Por isso, o algoritmo foi elaborado para selecionar e calcular as propriedades automaticamente, após o carregamento das imagens.

No total foram analisadas sete amostras de rochas calcárias escaneadas em μ CT de raios-X. Os resultados dos cálculos de porosidade foram comparados com diferentes técnicas de segmentação presentes na literatura e por ensaios laboratoriais utilizando um porosímetro de gás hélio como forma de validação dos resultados. Os resultados indicaram que o método proposto apresentou o menor índice de erro dentre as técnicas discutidas. O processamento das amostras apresentou uma redução da taxa de erro de 30,6% , em comparação com a abordagem clássica baseada na segmentação das imagens 3D disponível na literatura. Além da boa precisão, o algoritmo desenvolvido mostrou responder bem à diversidade da estrutura morfológica característica desse tipo de formação rochosa.

O método proposto também foi capaz de quantificar os poros conforme sua área e expressar essa informação de forma gráfica, provendo informações adicionais sobre a composição da porosidade da rocha. Os resultados dessa análise mostraram relação direta com as porosidades de referência obtidas.

Além das áreas dos poros, também foram extraídas as informações sobre a orientação dos poros. Como forma de validação, essas informações foram coletadas por um método clássico (método de Otsu) e realizado em um software aberto e comparados com a técnica proposta. Os resultados indicaram consistência para a maior parte das amostras. Os casos em que as divergências foram mais significativas ocorreram na amostras em que o método clássico apresentou maior dificuldade de segmentação das imagens.

O tempo de execução para realizar a análise foi em média de 8:56s por amostra, o que representa um excelente valor quando comparado com outras abordagens apresentadas em aplicações similares. Experimentos adicionais mostraram ser possível reduzir o tempo de processamento em 95,7%, sem penalizar a extração de propriedades do algoritmo original. A implementação de algoritmos rápidos de caracterização possui um papel importante na indústria do petróleo por permitir o processamento de um grande número de amostras de forma eficiente. É importante ressaltar que os códigos implementados não exigiram

um computador de alto desempenho para executar a caracterização, portanto a utilização de máquina com maior desempenho computacional provavelmente reduzirá o tempo de análise das amostras.

6.2 TRABALHOS FUTUROS

Sugere-se como trabalhos futuros aumentar o número amostras de rochas carbonáticas analisadas e testar a abordagem proposta em outras litologias para avaliar sua aplicabilidade. Além disso, utilizar a GPU para a execução do método proposto, na tentativa de acelerar o desempenho do fluxo de trabalho. Por fim, desenvolver uma interface gráfica para o usuário.

REFERÊNCIAS

- AL-MARZOUQI, H. Digital rock physics: Using ct scans to compute rock properties. *IEEE Signal Processing Magazine*, IEEE, v. 35, 3 2018.
- APPIAH, O.; HAYFRON-ACQUAH, J. Fast generation of image's histogram using approximation technique for image processing algorithms. *International Journal of Image, Graphics and Signal Processing*, v. 10, p. 25–35, 03 2018.
- BARRETT, J.; KEAT, N. Artifacts in ct: Recognition and avoidance. *Radiographics : a review publication of the Radiological Society of North America, Inc*, v. 24, p. 1679–91, 11 2004.
- BERG, S.; SAXENA, N.; SHAIK, M.; PRADHAN, C. Generation of ground truth images to validate micro-ct image-processing pipelines. *The Leading Edge*, Society of Exploration Geophysicists, v. 37, 06 2018.
- BONFIM, L. d. S. *Ferramenta para Caracterização de Poros e Fraturas em Imagens Microtomográficas de Amostras de Reservatórios de Petróleo*. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2020.
- BRANT, W. E.; HELMS, C. A. *Fundamentals of Diagnostic Radiology*. 3th edition. ed. [S.l.]: LWW, 2007.
- CARDOSO, V. G.; BARROS, E. N. S.; BARBOSA, J. A. Porosity features extraction based on image segmentation technique applying k-means clustering algorithm. *Rio Oil & Gas*, 2020.
- CHAUHAN, S.; RUHAAK, W.; KHAN, F.; ENZMANN, F.; MIELKE, P.; KERSTEN, M.; SASS. Processing of rock core microtomography images: Using seven different machine learning algorithms. *Computers and Geosciences*, v. 86, p. "120–128", 01 2016.
- COSTA, L.; ANTONINO, A.; HECK, R.; COUTINHO, A.; VASCONCELOS, T.; MACHADO, C. X-ray computed microtomography in the evaluation of the porous system of soils. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 22, p. 249–254, 04 2018.
- DABBURA, I. *K-means Clustering: Algorithm, Applications, Evaluation Methods, and Drawbacks*. 2018. Disponível em: <<https://towardsdatascience.com/k-means-clustering-algorithm-applications-evaluation-methods-and-drawbacks-aa03e644b48a>>. Acesso em: 06 set. 2020.
- DANDEKAR, A. Y. *Petroleum Reservoir Rock and Fluid Properties*. [S.l.]: Taylor and Francis, 2013. ISBN 978-1-4398-7645-9, 978-1-62870-693-2.
- DENG, H.; FITTS, J.; PETERS, C. Quantifying fracture geometry with x-ray tomography: Technique of iterative local thresholding (tilt) for 3d image segmentation. *Computational Geosciences*, v. 20, 02 2016.
- EL-NASR, A. A.; SALEH, A.; ALSHENNAWY, A. Porosity measurement of iron oxide by using computer vision system. p. 653–659, 01 2020.

ELLIOT, T.; HECK, R. A comparison of optical and x-ray ct technique for void analysis in soil thin section. *Geoderma*, v. 141, p. 60–70, 09 2007.

EROFEEV, A.; ORLOV, D.; RYZHOV, A.; KOROTEEV, D. Prediction of porosity and permeability alteration based on machine learning algorithms. 02 2019.

ESMAILI, M.; SHADIZADEH, S. R.; HABIBNIA, B.; NESHAT, J.; NORUZI-MASIR, B.; BAKHSHI, P. Quantification of pore size distribution in reservoir rocks using mri logging: A case study of south pars gas field. *Applied Radiation and Isotopes*, v. 130, p. 172–187, 09 2017.

EVANS, T.; CHALL, S.; ZHAO, X.; RHYNE, T.-M. Visualization and analysis of microstructure in three-dimensional discrete numerical models. *Journal of Computing in Civil Engineering - J COMPUT CIVIL ENG*, v. 23, 09 2009.

FALLAHZADEH, S.; AGHAJANPOUR, A.; KHATIBI, S.; HOSSAIN, M.; KADKHODAIE, A. Full waveform acoustic data as an aid in reducing uncertainty of mud window design in the absence of leak-off test. *Journal of Natural Gas Science and Engineering*, v. 45, p. 786–796, 2017.

FARRELL, N.; HEALY, D. Anisotropic pore fabrics in faulted porous sandstones. *Journal of Structural Geology*, v. 104, 09 2017.

FILHO, O.; ALENCAR, M.; BARBOSA, J.; NEUMANN, V. Proposta de formalização da formação tambaba, eoceno da bacia paraíba, ne do brasil. *Estudos Geológicos*, v. 25, p. 61–81, 12 2015.

FISHER, R.; PERKINS, S.; WALKER, A.; WOLFART, E. *Morphology*. 2003. Disponível em: <<http://homepages.inf.ed.ac.uk/rbf/HIPR2/morops.htm>>. Acesso em: 08 set. 2020.

FONSECA, A.; COSTA, L.; DANTAS, C.; HECK, R.; MELO, S.; ANTONINO, A.; BARBOSA, E. Precise determination of soil structure parameters in a x-ray and γ -ray ct combination methodology. *Progress in Nuclear Energy*, v. 114, p. 138 – 144, 2019. ISSN 0149-1970.

FREIRE-GORMALY, M.; ELLIS, J.; BAZYLAK, A.; MACLEAN, H. Comparing thresholding techniques for quantifying the dual porosity of indiana limestone and pink dolomite. *Microporous and Mesoporous Materials*, v. 207, 05 2015.

GOH, T.; BASAH, S.; YAZID, H.; SAFAR, M.; SAAD, F. A. Performance analysis of image thresholding: Otsu technique. *Measurement*, v. 114, 09 2017.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 2nd edition. ed. [S.l.]: Prentice Hall, 2002. ISBN 0-201-18075-8.

GRIFFITHS, L.; HEAP, M. J.; XU, T.; CHEN, C.; BAUD, P. The influence of pore geometry and orientation on the strength and stiffness of porous rock. *Journal of Structural Geology*, v. 96, 02 2017.

GUNTORO, P.; GHORBANI, Y.; KOCH, P.-H.; ROSENKRANZ, J. X-ray microcomputed tomography (μ ct) for mineral characterization: A review of data analysis methods. *Minerals*, v. 9, 03 2019.

- HAMANN, J. *Entenda como funciona a produção dos raios X*. 2019. Disponível em: <<http://conter.gov.br/site/noticia/ampola>>. Acesso em: 05 set. 2020.
- HAO, D.; LI, Q.; LI, C. Histogram-based image segmentation using variational mode decomposition and correlation coefficients. *Signal, Image and Video Processing*, v. 11, p. 1–8, 04 2017.
- HELLIWELL, J. R.; STURROCK, C. J.; GRAYLING, K. M.; TRACY, S. R.; FLAVEL, R. J.; YOUNG, I. M.; WHALLEY, W. R.; MOONEY, S. J. Applications of x-ray computed tomography for examining biophysical interactions and structural development in soil systems: a review. *European Journal of Soil Science*, v. 64, p. 279–297, 06 2013.
- HOUNSFIELD, G. Computed medical imaging. *Science (New York, N.Y.)*, v. 210, p. 22–8, 11 1980.
- IASSONOV, P.; GEBRENEGUS, T.; TULLER, M. Segmentation of x-ray computed tomography images of porous materials: A crucial step for characterization and quantitative analysis of pore structures. *Water Resources Research*, v. 45, 09 2009.
- JAHNE, B. *Digital image processing*. 5th. ed. [S.l.]: Springer, 2002. ISBN 9783540677543, 3-540-67754-2.
- JU, Y.; SUN, H.; XING, M.; WANG, X.; ZHENG, J. Numerical analysis of the failure process of soil-rock mixtures through computed tomography and pfc3d models. *Int J Coal Sci Technol*, v. 5, p. 126–141, 1 2018.
- KATE, J. M.; GOKHALE, C. S. Extracting regions of interest in biomedical images. *Engineering Geology*, v. 84, p. 48–69, 03 2006.
- KAUR, D.; KAUR, Y. Various image segmentation techniques: A review. *International Journal of Computer Science and Mobile Computing*, v. 3, p. 809–814, 05 2014.
- KONG, L.; OSTADHASSAN, M.; HOU, X.; MANN, M.; LI, C. Microstructure characteristics and fractal analysis of 3d-printed sandstone using micro-ct and sem-eds. *Journal of Petroleum Science and Engineering*, Elsevier Science, v. 175, 04 2019.
- KONG, L.; OSTADHASSAN, M.; LI, C.; TAMIMI, N. Pore characterization of 3d-printed gypsum rocks: A comprehensive approach. *Journal of Materials Science*, v. 53, p. 5063–5078, 04 2018.
- KRONBAUER, D. P. *Determinação de propriedades petrofísicas de rochas reservatórios usando modelos de redes de poros*. Tese (Doutorado) — Universidade Federal de Santa Catarina, 2014.
- LANTUEJOUL, C. *La squelettisation et son application aux mesures topologiques des mosaïques polycristallines*. Tese (Doutorado) — Ecole des Mines, 1978.
- LEU, L.; BERG, S.; ENZMANN, F.; ARMSTRONG, R.; KERSTEN, M. Fast x-ray micro-tomography of multiphase flow in berea sandstone: A sensitivity study on image processing. *Transport in Porous Media*, v. 105, 09 2014.
- LIN, C. L.; VIDELA, A. R.; YU, Q.; MILLER, J. D. Characterization and analysis of porous, brittle solid structures by x-ray micro computed tomography. *JOM: The Journal of The Minerals, Metals & Materials Society (TMS)*, v. 62, n. 12, p. 86 – 89, 2010. ISSN 10474838.

- MIRANDA, T.; FILHO, J.; NEVES, B.; BARBOSA, J. Estudo do comportamento geológico-estrutural dos depósitos cretácicos do sistema aquífero apodi, bacia potiguar, ne do brasil. *Estudos Geológicos*, v. 22, p. 3–19, 01 2012.
- MUKUNOKI, T.; OTANI, J.; OBARA, Y.; KANEKO, K. Artifacts of x-ray ct data in the analysis of geomaterial properties. *X-CT for Geomaterials: Soils, Concrete, Rocks*, p. 95–101, 2004.
- NETO, J.; FIORI, A.; LOPES, A.; MARCHESE, C.; PINTO-COELHO, C.; VASCONCELLOS, E.; SILVA, G.; SECCHI, R. A microtomografia computadorizada de raios x integrada à petrografia no estudo tridimensional de porosidade em rochas. *Revista Brasileira de Geociências*, v. 41, p. 498–508, 09 2011.
- NIKON. *XT H 225 ST – Industrial CT scanning*. 2020. Disponível em: <<https://www.nikonmetrology.com/en-us/product/xt-h-225-st>>. Acesso em: 10 set. 2020.
- NOVA, A. *Quantificação da Porosidade em Rochas Calcárias por meio de Tomografia Computadorizada de Raio X e de Raios Gama*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2020.
- NOVA, A.; RIBEIRO, F.; OLIVEIRA, P.; AMANCIO, D.; MACHADO, C.; CAROLINA, A.; PAIXÃO, M.; ANTONINO, A.; BARBOSA, E.; BARBOSA, A.; LOURENÇO, M.; RODRIGUES; HECK, R. Using gammaray and x-ray computed tomography for porosity quantification of reservoir analogue rocks. *EGU General Assembly 2020*, p. 4–8, 5 2020.
- OKUNO, E.; YOSHIMURA, E. M. *Física das radiações*. 1st edition. ed. [S.l.]: LWW, 2010. ISBN 978-85-7975-005-2.
- OPENCV - Open Source Computer Vision Library. 2020. Disponível em: <<https://opencv.org/>>. Acesso em: 08 set. 2020.
- OTSU, N. A threshold selection method from gray-level histograms. *Systems, Man and Cybernetics, IEEE Transactions on*, v. 9, p. 62–66, 01 1979.
- PEREIRA, F. *PETRÓLEO E PETROQUÍMICA*. 2010.
- PLESSIS, A. D.; BROECKHOVEN, C.; GUELPA, A.; ROUX, S. Laboratory x-ray micro-computed tomography: a user guideline for biological samples. *GigaScience*, v. 6, 04 2017.
- PORTER, M.; WILDENSCHILD, D. Image analysis algorithms for estimating porous media multiphase flow variables from computed microtomography data: a validation study. *Computational Geosciences*, v. 14, p. 15 – 30, 1 2010.
- QIN, D.; LIU, H.; LIU, J. Application of improved k- means algorithm in microvadosé image segmentation. v. 18, p. 3749–3759, 01 2013.
- RIDLER, T.; CALVARD, S. Picture thresholding using an iterative selection method. *IEEE Transactions on Systems, Man, and Cybernetics - TSMC*, v. 8, p. 630–632, 08 1978.
- ROCHE, R.; ABEL, R.; JOHNSON, K.; PERRY, C. Quantification of porosity in acropora pulchra (brook 1891) using x-ray micro-computed tomography techniques. *Journal of Experimental Marine Biology and Ecology*, v. 396, 12 2010.

ROQUE, R. *X-ray imaging using 100 μm thick Gas Electron Multipliers operating in Kr-CO₂ mixtures*. Tese (Doutorado), 06 2018.

RUSS, J. C.; DAVIDSON, M. W. *Watershed separation*. 2018. Disponível em: <<https://micro.magnet.fsu.edu/primer/java/digitalimaging/russ/edmsegmentation/index.html>>. Acesso em: 06 set. 2020.

SAAD, B.; NEGARA, A.; ALI, S. S. [society of petroleum engineers abu dhabi international petroleum exhibition & conference - abu dhabi, uae (2018-11-12)] abu dhabi international petroleum exhibition & conference - digital rock physics combined with machine learning for rock mechanical properties characterization. 2018.

SAXENA, N.; HOFMANN, R.; ALPAK, F.; BERG, S.; DIETDERICH, J.; AGARWAL, U.; TANDON, K.; HUNTER, S.; FREEMAN, J.; WILSON, O. References and benchmarks for pore-scale flow simulated using micro-ct images of porous media and digital rocks. *Advances in Water Resources*, v. 109, 09 2017.

SAXENA, N.; MAVKO, G. Estimating elastic moduli of rocks from thin sections: Digital rock study of 3d properties from 2d images. *Computers & Geosciences*, Elsevier Science, 12 2015.

SAXENA, N.; MAVKO, G.; HOFMANN, R.; SRISUTTHIYAKORN, N. Estimating permeability from thin sections without reconstruction: Digital rock study of 3d properties from 2d images. *Computers & Geosciences*, Elsevier Science, v. 102, 05 2017.

SCHLUTER, S.; SHEPPARD, A.; BROWN, K.; WILDENSCHILD, D. Image processing of multiphase images obtained via x-ray microtomography: A review. *Water Resources Research*, v. 50, 04 2014.

SELL, K.; SAENGER, E. H.; FALENTY, A.; CHAOUACHI, M.; HABERTHÜR, D.; ENZMANN, F.; KUHS, W. F.; KERSTEN, M. On the path to the digital rock physics of gas hydrate-bearing sediments processing of in situ synchrotron-tomography data. *Solid Earth*, v. 7, 08 2016.

SHAPIRO, G. C. S. L. G. *Computer Vision*. [S.l.]: Prentice Hall, 2001. ISBN 9780130307965,0130307963.

SMAL, P.; GOUZE, P.; RODRIGUEZ, O. An automatic segmentation algorithm for retrieving sub-resolution porosity from x-ray tomography images. *Journal of Petroleum Science and Engineering*, v. 166, 03 2018.

SMODEJ, J.; REUNING, L.; BECKER, S.; KUKLA, P. Micro- and nano-pores in intrasalt, microbialite-dominated carbonate reservoirs, ara group, south-oman salt basin. *Marine and Petroleum Geology*, v. 104, 03 2019.

SUN, H.; BELHAJ, H.; TAO, G.; VEGA, S.; LIU, L. Rock properties evaluation for carbonate reservoir characterization with multi-scale digital rock images. *Journal of Petroleum Science and Engineering*, Elsevier Science, v. 175, 04 2019.

SUZUKI, S.; ABE, K. Topological structural analysis of digitized binary images by border following. *Computer Vision, Graphics, and Image Processing*, v. 30, p. 32–46, 03 1985.

- TAINA, I.; HECK, R.; ELLIOT, T. Application of x-ray computed tomography to soil science: A literature review. *Canadian Journal of Soil Science*, v. 88, p. 1–19, 02 2008.
- TAKAHASHI, M.; KATO, M.; CHANGWAN, A.; URUSHIMATSU, Y.; MICHIGUCHI, Y.; PARK, H. 3d and geometric information of the pore structure in pressurized clastic sandstone. *Advances in Computed Tomography for Geomaterials: GeoX 2010*, p. 328–335, 01 2013.
- TAUD, H.; MARTINEZ-ANGELES, R.; PARROT, J.-F.; HERNANDEZ-ESCOBEDO, L. Porosity estimation method by x-ray computed tomography. *Journal of Petroleum Science and Engineering*, v. 47, p. 209–217, 06 2005.
- THOMAS, J. E. *Fundamentos de Engenharia de Petróleo*. Rio de Janeiro: Editora Interciência, 2001. ISBN 85-7193-046-5.
- TIAB, D.; DONALDSON, E. C. *Petrophysics: theory and practice of measuring reservoir rock and fluid transport properties*. Burlington: [s.n.], 2004. ISBN 0-7506-7711-2.
- TOLLEY, G.; YUE, S. *Beam Hardening – What is it and how to reduce it*. 2016. Disponível em: <<https://4nsi.com/blog/2016/02/12/beam-hardening/>>. Acesso em: 05 set. 2020.
- VIK, B.; BASTESEN, E.; SKAUGE, A. Evaluation of representative elementary volume for a vuggy carbonate rock—part: Porosity, permeability, and dispersivity. *Journal of Petroleum Science and Engineering*, v. 112, p. 36 – 47, 2013. ISSN 0920-4105. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0920410513000934>>.
- WANG, Y.; CHUNG, T.; ARMSTRONG, R.; MCCLURE J; MOSTAGHIMI, P. Computations of permeability of large rock images by dual grid domain decomposition. *Advances in Water Resources*, Elsevier Science, 2 2019.
- WU, J.; YIN, X.; XIAO, H. Seeing permeability from images: Fast prediction with convolutional neural networks. *Science Bulletin*, 08 2018.
- YUN, W.; LIU, Y.; KOVSCEK, A. Deep learning for automated characterization of pore-scale wettability. *Advances in Water Resources*, v. 144, p. 103708, 07 2020.
- ZAREBA, M.; DANEK, T.; PILECKI, Z.; DUBIŃSKI, J.; MARCAK, H.; DEC, J. Nonlinear anisotropic diffusion techniques for seismic signal enhancing - carpathian foredeep study. *E3S Web of Conferences*, v. 66, 2018.
- ZDILLA, M. J.; HATFIELD, S. A.; MCLEAN, K. A.; CYRUS, L. M.; LASLO, J. M.; LAMBERT, H. W. Circularity, solidity, axes of a best fit ellipse, aspect ratio, and roundness of the foramen ovale: A morphometric analysis with neurosurgical considerations. *The Journal of craniofacial surgery*, v. 27, p. 222–228, 2016.
- ZHAN, K.; SHI, J.; LI, Q.; TENG, J.; WANG, M. Image segmentation using fast linking scm. In: . [S.l.: s.n.], 2015.
- ZHANG, Q.; XIAO, H. Extracting regions of interest in biomedical images. *Future BioMedical Information Engineering, International Seminar on*, v. 0, p. 3–6, 12 2008.