



Programa de Pós-Graduação em

Computação Aplicada

Doutorado Acadêmico

Ademir Marques Junior

Detecção e análise de redes de fraturas em afloramentos por
métodos de visão computacional adaptativos

São Leopoldo, 2022

Ademir Marques Junior

**DETECÇÃO E ANÁLISE DE REDES DE FRATURAS EM AFLORAMENTOS POR
MÉTODOS DE VISÃO COMPUTACIONAL ADAPTATIVOS**

Tese apresentada como requisito parcial para a
obtenção do título de Doutor, pelo Programa de
Pós-Graduação em Computação Aplicada da
Universidade do Vale do Rio dos Sinos -
UNISINOS

Orientador:
Prof. Dr. Maurício Veronez

Coorientador:
Prof. Dr. Luiz Gonzaga Jr.

São Leopoldo
2022

M357d

Marques Junior, Ademir.

Detecção e análise de redes de fraturas em afloramentos por métodos de visão computacional adaptativos / Ademir Marques Junior. – 2022.

126 f. : il. ; 30 cm.

Tese (doutorado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2022.

“Orientador: Prof. Dr. Maurício Veronez ; coorientador: Prof. Dr. Luiz Gonzaga Jr.”.

1. Segmentação. 2. Fraturas. 3. Visão Computacional. 4. Redes de fratura discreta. 5. Técnicas de aquisição de imagem. 6. Afloramentos. 7. Geologia. I. Título.

CDU 004.932:55

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecário: Flávio Nunes – CRB 10/1298)

AGRADECIMENTOS

Agradeço primeiramente a minha mãe e irmã, e em especial ao meu pai que não está mais conosco, a quem eu agradeço a minha formação como pessoa.

Agradeço especialmente a Graciela Racolte com quem tenho admiração como pessoa e como parceira que ajudou a evoluir o tema de interpretação de fraturas ao longo de três anos desta pesquisa. Faço um agradecimento especial também à Eniuce Menezes pela parceria e trabalhos em conjunto, e em quem me espelho como pesquisador.

Agradeço também os meus amigos e colegas de Vizlab que também contribuíram para essa jornada, em especial à Vinícius Sales, Daniel Zanotta, Alysson, Horota, Lucas, Tainá e Bachi.

Agradeço aos meus amigos de Rio Grande do Sul e casa Cardoner: Filipe, Kátia, Rosane, Poliana, Fernanda, Antônio e Rayssa pelo apoio principalmente durante a pandemia. E aos amigos demais tempo Fernando, Natália, Suely, Rezende, Carla e Cristina.

Agradeço o suporte dos meus amigos de Fatec Jaú, que apostaram na minha jornada do doutorado quando eu saí da instituição, os professores Valéria Validório, Cida Zem, Magaly, Flávio Ventura, Marcos Bonifácio, e em especial à professora Dalva parceira de projetos que foi a pessoa que me apresentou a oportunidade de ser bolsista Petrobrás. Lembro ainda dos amigos professores que se foram nesses últimos anos como a Flávia Toledo e o professor Kiko que foi levado pela Covid-19.

Agradeço ainda aos meus orientadores Dr Maurício Veronez e Dr Luiz Gonzaga Jr pelas oportunidades de pesquisa e aprendizados nesses quatro anos. Por fim agradeço à Petrobras pelo financiamento da pesquisa e à Carol Cazarin que acompanhou este trabalho e fez a ponte com outros projetos de pesquisa voltados à interpretação de fraturas.

“Every day is a journey, and the journey itself is home.”.
(Matsuo Basho)

RESUMO

A identificação de fraturas e descontinuidades tem grande importância na estimativa de escoamento de fluidos em reservatórios de hidrocarbonetos, pois influenciam nas propriedades de porosidade e permeabilidade. Devido à inacessibilidade e escassez de dados de reservatório, a caracterização das fraturas é geralmente avaliada através do estudo de análogos de afloramentos por sensoriamento remoto ou observações *in situ* por um especialista. Considerando os métodos de sensoriamento remoto, a aquisição de Veículos Aéreos Não Tripulados (VANT) combinada com a fotogrametria *Structure from Motion* (SfM) é uma forma de baixo custo para gerar produtos como imagens ortorretificadas, permitindo métodos manuais e automatizados de detecção de delineamentos de fratura e descontinuidades para a obtenção dos modelos de rede de fratura discreta (*Discrete Fracture Networks* - DFN). Abordagens de visão computacional e processamento de imagens com o objetivo de segmentar as áreas de interesse por segmentação semântica ou de detecção de bordas e vales, comumente usadas para detectar e caracterizar a rede de fraturas, têm sido utilizadas na literatura, porém apresentam peculiaridades ou são otimizadas para cada tipo de afloramento e suas peculiaridades. Os afloramentos que passaram por processo de carstificação, principalmente, apresentam alto nível de fraturamento devido a dissolução causada por intemperismo e pela posterior quebra e erosão do meio rochoso. Este cenário aliado à presença de vegetação e à áreas com iluminação irregular ou sombra contribuem para o desafio da detecção automática de fraturas em imagens de afloramento. As técnicas de segmentação por limiarização ou binarização empregada por trabalhos anteriores na segmentação de fraturas, trazem a dificuldade de se estabelecer um limiar global aplicável à toda a imagem sem gerar muitos falsos positivos e negativos na detecção. Uma alternativa já empregada na biomedicina e reconhecimento de caracteres é uso de técnicas de segmentação adaptativa de limiares locais, que são o foco deste trabalho. Para otimizar a detecção de fraturas em regiões cársticas altamente fraturadas propomos o uso e avaliação destes métodos adaptativos. Em testes preliminares a segmentação adaptativa local Sauvola apresentou o melhor resultado quando comparada ao *ground truth* anotado manualmente. Este trabalho propõe também o uso de técnicas de redução de ruído binário para a criação do método de segmentação de fraturas apresentado, que é complementado por um método de detecção de segmentos de fratura que identifica dados topológicos de fratura como nodos e terminações. Os resultados apresentados trazem ainda a combinação de aquisições por VANT em diferentes horários do dia para avaliação da influência da posição do sol na detecção de fraturas e o viés de interpretação. Essa análise é realizada sobre ortofotos do afloramento de rochas carbonáticas carstificadas do Lajedo do Rosário, pertencente à formação Jandaíra, no Rio Grande do Norte. Com a metodologia proposta adquirimos dados de fratura mais precisos sobre a área de estudo, seguindo estatísticas direcionais de trabalhos anteriores realizados na região. Complementarmente à análise direcional, o modelo DFN e suas estatísticas de comprimento e abertura seguem as distribuições esperadas para este tipo de afloramento, enquanto a conectividade da rede de fraturas também é analisada. A partir da metodologia proposta foi possível gerar modelos DFN mais fiéis aos dados de campo, reduzindo o impacto de agentes externos ao meio rochoso como a posição solar e a presença de vegetação, fornecendo dados de mais qualidade à modelagem estocástica e à modelagem de reservatórios.

Palavras-chave: Segmentação. Fraturas. Visão Computacional. Redes de fratura discreta. Técnicas de aquisição de imagem. Afloramentos. Geologia.

ABSTRACT

The identification of fractures and discontinuities is of great importance in the estimation of fluid flow in hydrocarbon reservoirs, as they influence the porosity and permeability properties. Due to the inaccessibility and scarcity of reservoir data, fracture characterization is usually evaluated by studying outcrop analogues by remote sensing or in-situ observations by an expert. Considering the remote sensing methods, the acquisition of Unmanned Aerial Vehicles (UAV) combined with Structure from Motion photogrammetry (SfM) is a low-cost way to generate products such as orthorectified images, allowing manual and automated methods of detection of fracture designs and discontinuities to obtain discrete fracture network models (Discrete Fracture Networks - DFN). Computer vision and image processing approaches with the objective of segmenting the areas of interest by semantic segmentation or edge and valley detection, commonly used to detect and characterize the fracture network, have been used in the literature, but they have peculiarities or are optimized for each outcrop type and its peculiarities. The outcrops that have undergone a karstification process, mainly, show a high level of fracturing due to the dissolution caused by weathering and the subsequent breakage and erosion of the rocky medium. This scenario, together with the presence of vegetation and areas with irregular lighting or shade, contribute to the challenge of automatic fracture detection in outcrop images. The segmentation techniques by thresholding or binarization employed by previous works in fracture segmentation, bring the difficulty of establishing a global threshold applicable to the entire image without generating a large number of false positives and negatives in the detection. An alternative already used in biomedicine and character recognition is the use of local threshold adaptive segmentation techniques, which are the focus of this work. To optimize the detection of fractures in highly fractured karst regions, we propose the use and evaluation of these adaptive methods. In preliminary tests, the Sauvola local adaptive segmentation presented the best result when compared to the manually annotated ground truth. This work also proposes the use of binary noise reduction techniques to create the fracture segmentation method presented, which is complemented by a fracture segment detection method that identifies topological fracture data such as nodes and terminations. The results presented also bring the combination of UAV acquisitions at different times of the day to evaluate the influence of the position of the sun in the detection of fractures and the interpretation bias. This analysis is carried out on orthophotos of the outcrop of karstified carbonate rocks from Lajedo do Rosário, belonging to the Jandaíra formation, in Rio Grande do Norte. With the proposed methodology, we acquired more accurate fracture data over the study area, following directional statistics from previous works carried out in the region. In addition to the directional analysis, the DFN model and its length and opening statistics follow the expected distributions for this type of outcrop, while the fracture network connectivity is also analyzed. From the proposed methodology, it was possible to generate DFN models more faithful to the field truth, reducing the impact of external agents to the rocky environment such as the solar position and the presence of vegetation, providing more quality data for stochastic modeling and reservoir modeling.

Keywords: Segmentation. Fractures. Computer vision. Discrete Fracture Network. Image acquisition techniques. Outcrops. Geology.

LISTA DE FIGURAS

1	Exemplos de fraturas em diferentes escalas e tipos: a) falhas, b) juntas; c) veios.	27
2	Exemplos de afloramentos rochosos.	28
3	Fluxo mais comum do processamento fotogramétrico digital SfM/MVS para a geração de modelos 3D.	29
4	Métodos de amostragem e obtenção de dados de fraturas.	31
5	Modelo DFN com informação espacial (à esquerda), modelo DFN com informações de juntas estacadas (centro), e modelo DFN com intensidade variável ao longo do modelo (à direita).	32
6	Sistema de índices P_{xy} dado os espaços amostrais e dados de fratura observados.	33
7	Interações entre fraturas e tipos de nodos: nodos I em fraturas isoladas (a) e em aproximação (b); nodos Y em fraturas adjacentes (c) e em fraturas em deslocamento (d); nodos X em fraturas que se cruzam (e).	34
8	Fluxo de levantamentos de dados geológicos desde o levantamento de campo e digital até a criação dos modelos DFN e reamostragem à escala de reservatórios.	35
9	Sistema de coordenadas em uma imagem digital	37
10	Aplicação de filtro de vizinhança $h(x, y)$ a uma imagem $f(x, y)$, gerando uma imagem $g(x, y)$	38
11	Exemplos de aplicações de filtros convolutivos baseados derivadas de primeira (b) e segunda ordem (c) em um perfil unidimensional (a).	40
12	<i>Non-maximum suppression</i> dada uma posição (u, v) . A direção do gradiente é discretizada em quatro direções (a), dado o perfil na direção do gradiente (b), somente o píxel central de maior magnitude é mantido	42
13	Perfil de fratura em uma dimensão e perfil aproximado pelo algoritmo de Steger.	43
14	Operações morfológicas que compõem as operações de abertura e fechamento.	47
15	Algoritmo de esqueletização baseado em MAT aplicado a formas diversas.	47
16	Esquema dos coeficientes Wavelet em uma decomposição de 4 níveis.	50
17	Estrutura básica de uma rede neural artificial multicamadas.	51
18	Elementos básicos de uma rede CNN.	52
19	Arquitetura <i>encoding-decoding</i> da rede U-net.	53
20	Execução da revisão sistemática seguindo a diagramação sugerida em Page et al. (2021).	58
21	Métodos de aquisição de imagem nos trabalhos relacionados.	70
22	Métodos de segmentação e detecção de fraturas encontrados nos trabalhos relacionados.	71
23	Arquitetura da rede de segmentação semântica encoding/decoding Unet.	74
24	Arquitetura da rede de segmentação semântica encoding/decoding Segnet.	74
25	Ferramenta de segmentação assistida por Superpixels	78
26	Fluxo de trabalho proposto para: a avaliação da segmentação adaptativa: a aquisição de imagens do afloramento por VANT; e a caracterização da rede de fraturas.	79
27	Perfil de limiarização espaço-dependente Q e média local μ , em imagens de fundo escuro (a) e de fundo claro (b)	80

28	Exemplo de uso do algoritmo NLM para a estimativa do valor de um pixel p estimando valores de peso w em comparação as regiões dos pixels q_1 , q_2 e q_3 .	82
29	Mapa geológico de litologias da Bacia Potiguar no Rio Grande do Norte, Brasil. Sistema de Referência Geodésico: WGS84.	84
30	Localização da área de estudo e detalhe do afloramento fraturado carstificado do Lajedo Rosário.	86
31	VANTs utilizados para imageamento da área de estudo	87
32	Transformação do eixo medial usando a distância euclidiana. O tamanho dos círculos indica a medida da distância entre as bordas e o centro do círculo e a linha interna indicam o eixo medial.	87
33	Métodos de esqueletização baseados em afinamento (a,b) e em transformação do eixo medial (c) a partir de imagem binarizada (a).	88
34	Detalhe das vizinhanças de píxels indicando um nó de terminação e um nó de conexão usado para detecção de linha sobre os perfis de fratura esqueletizados.	89
35	Detecção de segmentos e rede topológica a partir da detecção de nodos e algoritmo de crescimento e pós processamento. Fonte autor.	90
36	Comparativo da curva de aprendizado para as duas redes de segmentação semântica selecionadas.	93
37	Segmentação semântica por Redes neurais convolucionais de codificação-decodificação.	93
38	Máscaras de segmentação de cada usuário usando iFG (b, c, d) e uma segmentação consolidada das máscaras criadas pelos três usuários usando ambos os métodos considerando 4 das 6 segmentações para cada imagem.	95
39	Testes iniciais de segmentação de limiarização adaptativa global e local.	96
40	Avaliação de tamanhos de janela arbitrários para o Sauvola. Em (b) usando uma janela pequena a detecção de fratura é ruidosa e com artefatos quando as áreas de fratura ultrapassam o tamanho da janela, enquanto foram detectados elementos de fratura com geometria mais próxima das áreas em preto (a) à medida que foi aumentada o tamanho de amostragem da janela.	97
41	Processamento fotogramétrico das imagens adquiridas por VANT no software Agisoft Metashape.	98
42	Ortofotos geras pelo processo de fotogrametria digital SfM/MVS.	99
43	Análise da segmentação em imagens adquiridas em voos múltiplos, onde: a, d, g são as imagens de afloramento obtidas a partir do processamento SfM-MVS de cada voo do UAV; b, e, h são a segmentação resultante de cada imagem; c, e, f são os diagramas de roseta ponderados das direções de descontinuidades com a direção do Sol marcada em amarelo.	100
44	Sobreposição das segmentações após a aplicação do método de segmentação proposto em cada imagem. Áreas em roxo indicam concordância de áreas	101
45	Descontinuidade detectadas de aquisição combinada de UAV (a) e estatísticas direcionais no diagrama de roseta ponderada (b).	102
46	Abertura das fraturas identificadas pela técnica de esqueletização baseada no <i>Medial Axis Transform</i>	103
47	Ajuste de distribuição dos comprimentos das descontinuidades em píxels para as distribuições de probabilidade exponencial, log-normal e lei de potência.	104

48	Ajuste de distribuição da abertura de fratura em pixels contra as distribuições de probabilidade exponencial, log-normal e lei de potência, usando uma amostra de um terço do tamanho dos dados da estimativa de abertura.	104
49	Intensidades de fratura por área (P21) para amostragens por área de 5m ² (a), e interpolação de dados de intensidade pelo algoritmo Lanczos.	104
50	Estimativa da abertura de fratura considerando uma abertura máxima de 30cm.	125
51	Identificação de nodos por algoritmo de Steger para a estimativa da conectividade entre as fraturas.	125
52	Estimativa da abertura por área obtida a partir da metodologia de decomposição em <i>wavelet</i> e Curvatura Gaussiana.	126
53	Segmentação de fraturas em escalas regionais em imagens de satélite de Thingvellir-Islândia.	126

LISTA DE TABELAS

1	Artigos considerados para a revisão em ordem cronológica.	59
2	Métodos de detecção e caracterização da rede de fratura encontrados nos trabalhos selecionados.	69
3	Parâmetros e estatísticas extraídas da rede de fraturas.	92
4	Média dos valores de F1 entre usuários para cada método.	94
5	Cliques para adicionar/remover regiões e tempo (em minutos) para concluir a segmentação para cada usuário e método.	95
6	Resultados de segmentação em comparação com o <i>ground truth</i> anotado. . .	97

LISTA DE SIGLAS

2D	<i>Two dimensions</i>
3D	<i>Three dimensions</i>
AFN	<i>Artificial Fracture Network</i>
CIE	<i>Commission Internationale d'Eclairage</i>
CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i>
CNN	<i>Convolutional Neural Networks</i>
DEM	<i>Digital Elevation Model</i>
DFM	<i>Discrete Fracture Model</i>
DFN	<i>Discrete Fracture Network</i>
DOM	<i>Digital Outcrop Model</i>
FCN	<i>Fully Connected Network</i>
GIS	<i>Geographic Information System</i>
GNSS	<i>Global Navigation Satellite System</i>
HSV	<i>Hue, Saturation, Value</i>
IFT	<i>Image Forest Transform</i>
ISF	<i>Iterative Spanning Forest</i>
JRC	<i>Joint Roughness Coefficient</i>
KNN	<i>K-Nearest Neighbors</i>
LiDAR	<i>Light Detection and Range</i>
MAT	<i>Medial Axis Transform</i>
MDA	Modelo Digital de Afloramento
MDE	Modelo Digital de Elevação
mIoU	<i>mean Intersection over Union</i>
MLP	<i>Multilayer Perceptron</i>
MVS	<i>Multi-View Stereo</i>
NLM	<i>Non-Local Means</i>
PDF	<i>Probability Density Function</i>
PRISMA	<i>Preferred Reporting Items for Systematic Review</i>
PSNR	<i>Peak Signal Noise Ratio</i>
QP	Questão Principal
QS	Questão Secundária
RGB	<i>Red, Green, Blue</i>
RNA	Redes Neurais Artificiais

RQD	<i>Rock Quality Index</i>
RTK	<i>Real Time Kinematic</i>
SfM	<i>Structure from Motion</i>
SIG	Sistema de Informação Geográfica
SLIC	<i>Simple Linear Iterative Clustering</i>
SSIM	<i>Structure Similarity Index Measure</i>
SVM	<i>Support Vector Machine</i>
UAV	<i>Unmanned Aerial Vehicle</i>
VANT	Veículo Aéreo Não Tripulado

SUMÁRIO

1	INTRODUÇÃO	21
2	REFERENCIAL TEÓRICO	27
2.1	Definição de fraturas	27
2.2	Estudo de afloramentos	28
2.3	Aquisição fotogramétrica por VANT e Fotogrametria Digital	29
2.4	Caracterização de fraturas e de rede de fraturas discretas DFN	30
2.4.1	Aquisição de dados de fraturas	31
2.4.2	Distribuições estatísticas	35
2.5	Processamento de Imagens e Visão Computacional	37
2.5.1	Discretização de imagens e espaço cor	37
2.5.2	Melhoramentos e filtros	38
2.6	Segmentação de imagens	39
2.6.1	Detecção de bordas	39
2.6.2	Segmentação baseada em região	44
2.6.3	Limiarização ou <i>Thresholding</i>	44
2.7	Operações morfológicas	46
2.7.1	Esqueletização	46
2.8	Transformadas	48
2.8.1	Transformada Hough	48
2.8.2	Transformadas de Fourier e Wavelet	49
2.9	Aprendizado de máquina	49
2.9.1	Técnicas de classificação supervisionadas	50
2.9.2	Técnicas de identificação de objetos e segmentação	52
2.9.3	Redes CNN <i>encoder/decoder</i> para segmentação semântica	53
3	TRABALHOS RELACIONADOS	55
3.1	Metodologia	55
3.2	Execução da Revisão de Literatura Sistemática e extração de dados	57
3.2.1	Estado da arte	60
3.3	Síntese qualitativa	64
3.3.1	Tipos de imagem e métodos de aquisição	64
3.3.2	Metodologias de detecção e segmentação de fraturas	65
3.3.3	Métricas e avaliações empregadas	68
3.3.4	Estatísticas de fraturas	68
3.4	Síntese quantitativa	68
3.4.1	Aquisição de imagens e tipos de dados de entrada	68
3.4.2	Artigos organizados por técnicas de segmentação	70
3.4.3	Áreas de estudo e geologia	71
3.5	Considerações	71
4	SEGMENTAÇÃO SEMÂNTICA DE FRATURAS POR <i>DEEP LEARNING</i>	73
4.1	Redes CNN deep learnin para segmentação semântica	73
4.1.1	Avaliação do método proposto e experimento	74

5	SEGMENTAÇÃO ASSISTIDA POR SUPERPIXELS E ESTRUTURAS DE GRAFO.	75
5.1	Metodologia proposta	75
5.1.1	Avaliação do método	77
6	DETECÇÃO DE FRATURAS EM IMAGENS POR SEGMENTAÇÃO ADAPTATIVA	79
6.1	Segmentação por limiarização adaptativa	79
6.1.1	Técnicas de redução de ruídos em dados binários	81
6.2	Avaliação do método proposto	82
6.3	Estudo de caso da análise do viés de iluminação e geração do modelo DFN	84
6.3.1	Área de estudo	84
6.3.2	Aquisição de imagens	85
6.3.3	Esqueletização e obtenção dos perfis centrais das fraturas	86
6.3.4	Deteção de linhas e extração de dados topológicos	88
6.4	Rede Discreta de Fraturas e estatísticas	91
7	RESULTADOS E DISCUSSÃO	93
7.1	Avaliação de métodos de segmentação semântica por deep learning	93
7.2	Avaliação dos métodos de segmentação assistida por superpixels	94
7.3	Avaliação dos métodos de segmentação por limiarização adaptativa	96
7.4	Estudo de caso: Caracterização DFN por múltiplos levantamentos aéreos	98
8	CONCLUSÃO	105
8.1	Contribuições	106
8.2	Artigos publicados	106
8.2.1	Artigos diretamente relacionados à tese desenvolvida	106
8.2.2	Levantamento fotogramétrico por VANT e acurácia cartográfica	107
8.2.3	Estudo de dados espectrais em afloramentos de carbonatos e melhoramento de resolução espacial	108
8.2.4	Estudos de modelos digitais de afloramentos e modelagem 3d fotogramétrica	108
8.2.5	Participação em eventos	108
8.3	Trabalhos Futuros	109
	REFERÊNCIAS	111
	APÊNDICE A – TRABALHOS ADICIONAIS DESENVOLVIDOS	125
A.1	Extração de fraturas como vales/curvas e estimativa de abertura	125

1 INTRODUÇÃO

Muitos dos equipamentos eletrônicos, utensílios domésticos, roupas e produtos alimentícios possuem derivados de petróleo na sua composição ou este se fez necessário em uma das etapas de sua produção. Embora haja uma tendência por parte da indústria automotiva, seguindo regulamentações governamentais ou interesse do mercado de reduzir o consumo de combustíveis fósseis, estes são atualmente a principal fonte de energia dos veículos automotores (BJORLYKKE, 2010). Esta demanda, aliada à diminuição de produção dos reservatórios existentes e à dificuldade de se encontrar novos reservatórios e perfurar novos poços, tem, desde o último século, aumentado o interesse da indústria petrolífera nas pesquisas envolvendo a composição geológica e o comportamento do fluido na forma de óleo ou gás (hidrocarbonetos) nas rochas que compõem estes reservatórios, permitindo um melhor planejamento e eficiência na extração de petróleo.

Os reservatórios de petróleo são geralmente compostos de rochas sedimentares como arenitos e carbonatos, também identificados como rochas reservatório devido as suas características de porosidade e permeabilidade. Enquanto a primeira define a capacidade de armazenar fluídos, a segunda define a capacidade da rocha de permitir o escoamento de fluídos.

A passagem do fluido pode ser influenciada pela direção em que o fluxo passa pela rocha, por exemplo, no caso das rochas sedimentares, o fluxo é facilitado na direção paralela ao plano sedimentar (BJORLYKKE, 2010). Além disso, a existência de fraturas, pode modificar a porosidade e permeabilidade das rochas, sendo um elemento de grande importância quando ocorre em rochas de baixa permeabilidade, permitindo a formação de grandes reservatórios (agindo como meio de transporte). Rochas de baixa porosidade também podem reter mais fluídos com a ocorrência de fraturas (BJORLYKKE, 2010).

As fraturas podem ser definidas em termos geológicos e mecânicos como sendo uma ruptura ou divisão do meio, que variam quanto à escala (milímetros à quilômetros), e quanto a sua origem ou diagênese, sendo também identificadas como diaclases, diques, veios, falhas e descontinuidades (PEACOCK et al., 2016). Elas ainda podem ser caracterizadas em termos geométricos (formatos, tamanho, orientação etc.), topológicos (arranjo, nós e bifurcações) e cinemáticos (deslocamento e tensão). Essas características podem ser relativas à fraturas individuais, pares de fraturas e à redes de fraturas, também conhecidas como DFM - *Discrete Fracture Model* (ZUO et al., 2019) e DFN - *Discrete Fracture Network*, sendo o último o termo preferido neste trabalho. As DFNs são elementos importantes na modelagem de reservatórios, sendo necessárias para a simulação de fluidos e caracterização de reservatórios.

Reservatórios carbonáticos concentram importantes reservas de hidrocarbonetos localizadas em grandes profundidades, como é o caso do pré-sal no *offshore* brasileiro. Esses reservatórios são afetados principalmente pela diagênese e dissolução pós-deposição causada pela carstificação (DE WAELE et al., 2011), que leva a rochas altamente fraturadas contribuindo para a heterogeneidade dos reservatórios carbonáticos (LARSSEN; SENGER; GRUNDVÅG, 2020).

O processo de carstificação causa fragilidade e fraturamento das rochas do reservatório alterando as propriedades inerentes de porosidade e permeabilidade, aumentando a importância da caracterização de fratura (e descontinuidades gerais) em reservatórios para estimar o fluxo de fluido, e esse mesmo comportamento pode ser visto em termos de afloramento (LA BRUNA et al., 2021).

Devido à baixa resolução espacial de dados sísmicos, e da esparsa coleta de dados de poços perfurados nos reservatórios de alto custo e riscos associados, as informações necessárias à criação de modelos DFN provém, geralmente, do estudo e análise de afloramentos análogos (MARQUES et al., 2020). Os afloramentos são formações rochosas expostas pela movimentação de placas tectônicas, pela erosão e intemperismos e pela ação do homem (BUCKLEY et al., 2006). Em escalas de afloramento, as informações para caracterização de fraturas e da modelagem DFN (LEI; LATHAM; TSANG, 2017) são obtidas a partir de técnicas de amostragem baseadas em dados obtidos em campo (LANEN et al., 2009; WATKINS et al., 2015) ou por meio de modelos digitais como imagens e modelos 3D (SEERS; HODGETTS, 2014; CASINI et al., 2016).

Técnicas de amostragem em campo incluem a obtenção do perfil geométrico de fraturas principais e amostragem por *scanline*, onde fraturas que interceptam ou cruzam uma linha (geralmente uma fita métrica estirada no afloramento), têm informações de comprimento, abertura, ângulo e direção de mergulho extraídas (WATKINS et al., 2015; ZEEB et al., 2013). Entretanto, por ser um processo que exige muito tempo por parte do analista, é acompanhado ou substituído pela caracterização de fraturas em modelos digitais (SEERS; HODGETTS, 2014; CASINI et al., 2016), como ortofotos e modelos 3D texturizados ou MDAs (Modelos Digitais de Afloramento) gerados a partir de escaneamento por LiDAR (*Light Detection and Range*) e Fotogrametria Digital utilizando algoritmos de SfM/MVS (*Structure from Motion/Multi-view Stereo*) (WESTOBY et al., 2012; FURUKAWA; HERNÁNDEZ, 2015), com imagens obtidas por câmeras fotográficas em solo ou embarcadas em veículos aéreos não tripulados (VANT), em inglês, Unmanned Aerial Vehicles (UAV).

Exemplos de métodos de caracterização de fraturas por interpretação visual em modelos digitais incluem o delineamento de forma manual de fraturas em ortofotos a partir de programas de SIG (Sistemas de Informação Geográfica) como ArcGIS e QGIS (HARDEBOL; BERTOTTI, 2013; HEALY et al., 2017; NYBERG; NIXON; SANDERSON, 2018; THIELE et al., 2017), e o delineamento de fraturas em modelos 3D, em programas como o CloudCompare (THIELE et al., 2017), Lime (BUCKLEY et al., 2019), VRGS (HODGETTS et al., 2007) e Mosis XP (GONZAGA et al., 2018).

A identificação manual de fraturas em meio digital, embora mais confortável que a identificação em campo, demanda tempo considerável do operador (LEMY; HADJIGEORGIOU, 2003; WANG; LIANG, 2015), o que pode ser impraticável em afloramentos com milhares de fraturas, sendo ainda uma tarefa que também pode sofrer com o viés de interpretação inerente a cada analista o que pode ocorrer também na interpretação em campo (THIELE et al., 2017;

VASUKI et al., 2014; ANDREWS et al., 2019). Os métodos automáticos têm a finalidade de solucionar esses problemas ao criar uma referência objetiva na detecção, porém, é comum a presença de falsos positivos (elementos incorretamente identificados como fraturas) e falsos negativos (falha na identificação de fraturas) nos resultados (LEMY; HADJIGEORGIOU, 2003; WEIXING; HAIJUN; YING, 2007; VASUKI et al., 2014). Isso resulta da dificuldade de adaptação dos métodos de segmentação considerando os diversos tipos de afloramentos e suas peculiaridades.

A detecção de fraturas em imagens é um campo ativo de pesquisa, levando avanços em técnicas de visão computacional e processamento de imagens também aplicadas a outras áreas de campo, como aplicações médicas, identificação de estradas e engenharia civil. Para isso, métodos de análise de sinal como Congruência de Fase (VASUKI et al., 2014), Wavelet (HE-ALY et al., 2017; RIZZO et al., 2017; Nelson Kennedy Babu, 2017), Shearlet (ZUO et al., 2019; PRABHAKARAN et al., 2019), detecção de linha com transformada de Hough (KEMENY et al., 2002; LEMY; HADJIGEORGIOU, 2003), filtros de detecção de cume e borda com Canny (LEMY; HADJIGEORGIOU, 2003; KEMENY et al., 2002; WEIXING; HAIJUN; YING, 2007; MOHEBBI et al., 2017; VASUKI et al., 2014; WANG; LIANG, 2015) e algoritmo Steger (LEMY; HADJIGEORGIOU, 2003; WANG; LIANG, 2015) também têm sido aplicados na detecção de fraturas. Grande parte dos métodos apresentados podem sofrer com ruídos ao detectar descontinuidades em afloramentos altamente fraturados ou com áreas sombreadas irregulares devido à presença de vegetação. Métodos de aprendizado profundo CNNs para segmentação semântica foram desenvolvidos recentemente para resolver com sucesso alguns desses problemas ao detectar fraturas em imagens de afloramentos e rochas (SANTOSO; HE; HOTEIT, 2019; LU et al., 2020; CHEN et al., 2021; BYUN et al., 2021; MARQUES et al., 2021), no entanto, conjuntos de dados de treinamento extensos e especializados são necessários para obter os melhores resultados. Outra ressalva é o viés de interpretação na detecção automatizada de fraturas causadas pela direção da luz solar ao detectar áreas de sombra como fraturas, um problema também apontado por Lemy e Hadjigeorgiou (2003), porém não foram encontrados outros trabalhos que levaram isso em consideração ao gerar o modelo DFN.

Em complemento aos métodos inteligentes de segmentação, a aplicação dos métodos automáticos possui limitações quanto a detecção correta das fraturas e a adaptação à diferentes cenários (presença de sombras ou conexões de fraturas contínuas). Em particular o mapeamento de afloramentos de rochas carbonáticas carstificados aumenta a complexidade devido ao alto fraturamento do corpo rochoso e a heterogeneidade da rede de fraturas.

Aliada a complexidade da rede de fraturas no ambiente cárstico, a presença de vegetação e a presença de áreas pouco uniformes quanto a áreas de sombra, temos um cenário pouco favorável à aplicação dos métodos presentes na literatura até então, principalmente para as técnicas que usam parâmetros globais estáticos.

Neste contexto, os métodos de aquisição de imagens e posterior segmentação de imagens não apresentam os resultados esperados devido à presença de falsos positivos e falsos negativos,

a hipótese investigada nesse trabalho é que o aperfeiçoamento de técnicas de segmentação e identificação de fraturas podem contribuir para uma melhor extração da rede de fraturas em relação à interpretação manual e à interpretação automática tradicional, aumentando a fidelidade dos modelos DFN.

Dada essa hipótese, este trabalho tem como objetivo principal:

- Gerar modelos DFN mais fiéis à verdade de campo obtidos a partir de segmentação de imagens por técnicas de visão computacional e processamento de imagens.

E como objetivos específicos:

- Implementar e aperfeiçoar algoritmos de visão computacional automáticos e semiautomáticos existentes voltados a identificação de fraturas;
- Criar algoritmos e ferramentas que auxiliem a interpretação e análise de fraturas;
- Validar as técnicas propostas utilizando dados de referência e comparação com os métodos existentes;
- Aplicar estatísticas de fraturas para a composição dos modelos DFNs geológicos.

Para atender esses objetivos, propomos o uso de um método de limiarização adaptativa juntamente com a técnica de remoção de ruído *Non-Local means* (BUADES; COLL; MOREL, 2011). São avaliadas e combinadas três aquisições de VANTs sobre o Lajedo do Rosário, um afloramento carbonático cárstico no município de Felipe Guerra, no Estado do Rio Grande do Norte, Brasil. Estas aquisições, combinadas à detecção de fraturas subsequente, são então usadas para estimar a intensidade de fraturas, as distribuições do comprimento e abertura, e informações relacionadas à rede topológica. Com esta estratégia, pretendemos capturar uma representação mais precisa e mais consistente da complexa rede de fraturas do ambiente cárstico em relação às técnicas automáticas observadas. Em relação ao estado da arte, apresentamos um método de segmentação adaptativo não utilizado até então nesse escopo e a combinação de várias aquisições de imagens sobre uma mesma área para melhorar a caracterização da rede de fraturas, além de apresentar algoritmos adicionais baseados em aprendizado de máquina (*deep learning*) e de segmentação assistida.

Este trabalho está organizado como segue: no Capítulo 2 são levantados os conceitos básicos para o entendimento desta pesquisa, incluindo as definições relacionadas às fraturas e como elas afetam a modelagem de reservatórios e a aquisição desse dado em afloramento, as técnicas de visão computacional e processamento de imagem, e as técnicas de aprendizado de máquina para a detecção e agrupamento de dados de fratura; No Capítulo 3 é apresentado uma revisão sistemática de trabalhos que segmentaram fraturas a partir de imagens RGB; nos Capítulos 4 e 5 são apresentadas metodologias de segmentação de fraturas baseadas em redes deep learning de segmentação semântica e de segmentação assistida baseada em superpixels; no Capítulo

6 é apresentada a metodologia de aquisição de imagens de múltiplos levantamentos aéreos, a técnica principal de segmentação adaptativa baseada em limiarização local, e as técnicas de detecção de linhas e caracterização da rede de fraturas e estatísticas relacionadas; no Capítulo 7 são apresentadas a validação das técnicas propostas, resultados da segmentação e caracterização de fratura na área de estudo escolhida, e a discussão dos resultados; por fim, no Capítulo 8 são apresentadas as considerações e contribuições deste trabalho de pesquisa.

2 REFERENCIAL TEÓRICO

Este capítulo tem o objetivo de fazer uma síntese dos termos e tecnologias que fazem parte do escopo deste trabalho, principalmente quanto às informações relacionadas às fraturas em ambiente rochoso de interesse à extração de petróleo e quanto as técnicas de segmentação de imagem baseadas processamento de imagem e visão computacional necessárias à identificação de fraturas e outras feições.

2.1 Definição de fraturas

As fraturas e descontinuidades são definidas como quebras, divisões, fendas ou brechas, caracterizadas dessa forma quando não há indícios do esforço estrutural ou mecânico que a ocasionou, ou este ainda não foi identificado (PEACOCK et al., 2016). Fraturas geológicas identificadas, podem ser referidas como falhas, juntas e veios dependendo de suas características de tamanho e preenchimento (Figura 1).

As falhas são definidas como fraturas formadas a partir de tensão mecânica ou torção entre blocos (esforço tectônico). As juntas são fendas não preenchidas por depósito mineral geralmente em posição normal ao plano fraturado. Veios são fraturas mineralizadas (preenchidas com material deposicional) (ADLER; THOVERT; MOURZENKO, 2013).

Lineamentos são definidos como estruturas geológicas visíveis a partir de sensoriamento remoto, principalmente a partir de dados de imagens de satélites, representando principalmente falhas (fraturas em grandes áreas) (KOIKE; NAGANO; OHMI, 1995; MASOUD; KOIKE, 2017; MIDDLETON et al., 2015).

Segundo Pollard e Aydin (1988), em termos geológicos, o termo fratura deve ser utilizado somente quando o tipo de fratura é desconhecido. Entretanto o termos "fratura" ou "descontinuidades" são os termos preferidos neste trabalho, assim como em Adler, Thovert e Mourzenko (2013) e Peacock et al. (2016), quando nenhuma outra definição for dada.

Figura 1: Exemplos de fraturas em diferentes escalas e tipos: a) falhas, b) juntas; c) veios.




Figura 2: Exemplos de afloramentos rochosos.



Fonte: Laboratório Vizlab ¹.

2.2 Estudo de afloramentos

As fraturas alteram substancialmente as propriedades mecânicas das rochas, influenciando a porosidade e a permeabilidade aos fluidos. Sua quantificação e modelagem são bem estudadas em disciplinas relacionadas às geociências do petróleo, como geofísica e geomecânica. Devido às suas propriedades, as fraturas podem influenciar o modo como os fluidos (hidrocarbonetos ou água) são retidos em uma matriz porosa, tornando o estudo das fraturas importante para o planejamento e extração petrolífera (BJORLYKKE, 2010).

A identificação de fraturas em reservatório de petróleo é geralmente feita por levantamento sísmico ou a partir do estudo de perfis de poços perfurados, onde o primeiro sofre com baixa resolução espacial e o segundo, embora com melhor resolução, sofre com a escassez dos dados coletados devido à geralmente a menor quantidade de poços extraídos. Uma alternativa é a modelagem de reservatórios a partir da análise de afloramentos com as mesmas propriedades (análogos) (BISDOM; NICK; BERTOTTI, 2017), permitindo uma melhor caracterização estrutural do reservatórios dado a grande quantidade de dados que podem ser extraídos.

Os afloramentos (Figura 2) são corpos rochosos expostos geralmente por processos erosivos, esforços tectônicos (falhas) ou pela ação do homem (construção de rodovias, mineração). Eles permitem o estudo de estruturas geológicas e topográficas, como informações geométricas e de composição de porções mais inferiores da Terra, que podem ser inviáveis do ponto de vista prático ou econômico (PRINGLE et al., 2006; BUCKLEY et al., 2006).

Os estudos de afloramentos podem ser conduzidos *in situ* por trabalhos de campo com o uso de clinômetros, aparelhos de GNSS (Global Navigation Satellite Systems) portáteis, cadernos de campo etc. (LANEN et al., 2009), ou podem ser conduzidos a partir da obtenção de dados de equipamentos de sensoriamento remoto.


A técnicas de sensoriamento empregadas incluem imageamento por satélite (orbital) (BERNAL et al., 2002) e aeronaves (suborbital) para levantamento topológico (radares) (HOLDEN et al., 2016) e espectral (retorno de luz nos espectros visível, infravermelho e termal). Adicionalmente, escaneamento LiDAR aéreo ou terrestre (BUCKLEY et al., 2010; TELLING et al., 2017), e levantamentos fotogramétricos digitais a partir de VANT e terrestres são empregados na obtenção de modelos MDAs, mapas de elevação (DEM - *Digital Elevation Model*) e ortofotos (imagens ortorretificadas) (WESTOBY et al., 2012; VOLLGGER et al., 2019; BILMES et al., 2019).

Embora utilizados em alguns trabalhos (ver Capítulo 3) os levantamentos orbitais e suborbitais no estudo de afloramentos são mais indicados para a identificação de fraturas em escalas de lineamentos e falhas em grandes áreas (MIDDLETON et al., 2015). Sendo o foco deste trabalho a identificação de fraturas em imagens (espaço 2D) uma maior atenção é dada aos trabalhos que utilizaram processamento de imagens obtidas por câmeras acopladas em VANTs ou por levantamento terrestre com câmeras portáteis.

2.3 Aquisição fotogramétrica por VANT e Fotogrametria Digital

A Fotogrametria Digital por VANT se baseia na triangulação de pares de pontos comuns utilizando o algoritmo SfM (*Structure from Motion*) (WESTOBY et al., 2012) combinado com o algoritmo MVS (Multi-View Stereo) (FURUKAWA; HERNÁNDEZ, 2015), a partir de fotos obtidas por câmeras digitais em solo ou acopladas em VANTs (VOLLGGER et al., 2019). Desse método, é possível reconstruir os afloramentos em ambiente digital, possibilitando o posterior estudo em laboratório. Essa alternativa vem sendo bastante explorada nos últimos anos em aplicações geológicas, como exemplo, os afloramentos de rochas, devido ao avanço computacional e a facilidade na aquisição das cenas (MARQUES et al., 2020). O processamento fotogramétrico digital é exemplificado na Figura 3.

Figura 3: Fluxo mais comum do processamento fotogramétrico digital SfM/MVS para a geração de modelos 3D.



Fonte: Adaptado de Racolte et al. (2022).

No SfM as posições das câmeras são estimadas combinando características semelhantes em pares de imagens que requerem 60% a 80% de sobreposição de cena e menos de 30° de ângulo

entre as imagens. Após esta primeira correspondência de imagem, temos uma nuvem de pontos esparsa que é processada no algoritmo MVS juntamente com as posições da câmera para gerar uma nuvem de pontos densa. Os produtos da fotogrametria digital são o modelo 3D texturizado, modelos de elevação e ortofotos enquanto as nuvens esparsas e densas também são utilizadas como produtos finais (MARQUES JUNIOR et al., 2020).

A utilização de pontos de controle (*Ground Control Points - GCPs*) permite a geração de modelos georreferenciados como o Digital Surface Model (DSM), ou seja, um modelo topográfico com todas as estruturas como vegetação e construções. O DSM combinado com as posições da câmera e os parâmetros de orientação interior permitem a geração do ortomosaico/ortofoto, onde os objetos podem ser posicionados com precisão (MARQUES JUNIOR et al., 2020; FURUKAWA; HERNÁNDEZ, 2015; VERHOEVEN, 2011).

Para validar esses modelos como produtos cartográficos a avaliação estatística é comumente feita com a comparação de GCPs coletados usando GNSS em modo RTK e o uso do RMSE como métrica de qualidade em um espaço 2D, com pontos utilizados para a verificação variando de cinco a cem (MARQUES JUNIOR et al., 2020; LALIBERTE et al., 2010; JAUD et al., 2016; TURNER; LUCIEER; WATSON, 2012).

2.4 Caracterização de fraturas e de rede de fraturas discretas DFN

Fraturas em rochas são formadas principalmente por estresse mecânico ou tensão, ou outras forças tectônicas relativas. Essas forças tendem a criar em diferentes escalas, falhas, lineamentos e descontinuidades de rochas. Importante no estudo de reservatórios, as fraturas modificam as características do meio rochoso como a porosidade e permeabilidade, alterando capacidade das rochas de reterem ou permitirem a passagem de fluxo, tanto de carbonatos como óleo cru e gases quanto de água (BJORLYKKE, 2010). Segundo Lepillier et al. (2020), a permeabilidade de reservatórios pode ser relacionada à escala da matriz rochosa e porosidade, e à ocorrência de fraturas no meio rochoso.

As fraturas são geralmente organizadas em redes de fraturas interconectadas (HEALY et al., 2017; LEPILLIER et al., 2020) definidas por suas características geométricas e topológicas (PEACOCK et al., 2016). As características principais observadas na caracterização de fraturas são propostas por Barton et al. (1978) onde são listadas a orientação (incluindo mergulho e direção), comprimento, conectividade (topologia de nós), abertura, preenchimento e forma, comumente estabelecida em termos do coeficiente de rugosidade JRC (*Joint roughness coefficient*) (BEER; STEAD; COGGAN, 2002). A aquisição e levantamento dessas características compõem os modelos DFN.

De acordo com Lei, Latham e Tsang (2017), os modelos DFN são modelos computacionais matemáticos que representam características geométricas e topológicas de redes de fraturas, podendo estes serem modelos geológicos obtidos através de mapeamento de fraturas em afloramentos, estocásticos gerados a partir de aproximações estatísticas de atributos geométricos

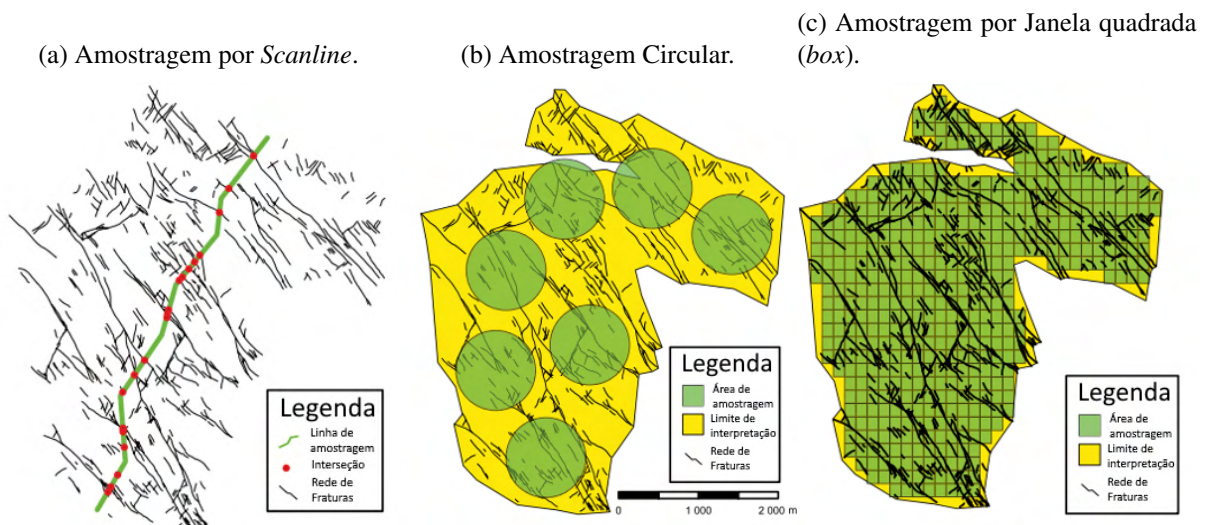
(Zeeb et al. (2013) usa o termo AFN - Artificial Fracture Network para modelos estocásticos), e geomecânicos, compostos de propriedades mecânicas das fraturas. Este trabalho dará mais atenção à obtenção de DFNs geológicos e à amostragem de dados estatísticos necessários à criação de DFNs estocásticos.

2.4.1 Aquisição de dados de fraturas

A caracterização dos dados de fraturas para a geração dos modelos DFN geológicos é realizada tanto a partir da obtenção *in situ* (afloramentos) quanto a partir de modelos digitais. A técnica de obtenção de dados de fratura em campo mais comum é a *scanline* ou escaneamento linear (WATKINS et al., 2015; LEPILLIER et al., 2020), realizado a partir da disposição de uma fita métrica em uma certa área onde as fraturas que cruzam a fita são avaliadas quanto ao mergulho e orientação da fratura, comprimento, abertura, preenchimento e forma. Alternativamente, essas informações também podem ser extraídas em perfis de imagens de poços (ZEEB et al., 2013).


Outros métodos de obtenção de dados de fratura incluem amostragens retangular ou circular. No método de amostragem retangular, um retângulo é disposto no afloramento e as medidas de comprimento das fraturas dentro da área determinada são obtidas permitindo a estimativa de comprimento médio de fraturas. No método de amostragem circular, um círculo é delimitado no afloramento onde as intersecções e terminações de fraturas que atravessam o perímetro do círculo são contadas (WATKINS et al., 2015). O uso de modelos digitais obtidos por técnicas de sensoriamento remoto permite a amostragem de todo o afloramento para a criação do DFN geológico. A Figura 4 ilustra os tipos de amostragem de fratura em um modelo digital.

Figura 4: Métodos de amostragem e obtenção de dados de fraturas.



Fonte: Adaptado de Nyberg, Nixon e Sanderson (2018).

Figura 5: Modelo DFN com informação espacial (à esquerda), modelo DFN com informações de juntas estacadas (centro), e modelo DFN com intensidade variável ao longo do modelo (à direita).



Fonte: Adaptado de Rogers et al. (2017).

Alternativamente, os modelos DFN podem incorporar informações espaciais 3D da rede de fraturamento, variando em apresentação e propósito. Rogers et al. (2017) ilustra alguns dos tipos de modelo DFN estocásticos gerados a partir de modelos de simulação estatísticos apresentados na Figura 5.

A obtenção de dados de fraturas em afloramento ainda pode ser realizada a partir de sensoriamento remoto, seja por imageamento por fotografias aéreas (WATKINS et al., 2015) ou por processamento fotogramétrico SfM de imagens obtidas por VANT e posterior interpretação manual ou automática (veja Capítulo 3) de fraturas em ortofotos ou modelos digitais de afloramentos (MDAs) (BISDOM; NICK; BERTOTTI, 2017; ANDREWS et al., 2019). O método de amostragem retangular ou por janelas é o mais comum em dados de levantamento aéreo (HEALY et al., 2017; SALVINI et al., 2017).

Mapeada e digitalizada a rede de fraturas, as propriedades de frequência, densidade, intensidade, distribuição de comprimento e orientação e estrutura topológica que definem o modelo DFN podem ser estimadas. Essas propriedades se relacionam diretamente com as dimensões do dado observado e a quantidade de dimensões consideradas para a sua estimativa, dadas pela notação P_{xy} onde x é a dimensão da área de amostragem e y é a quantidade de dimensões utilizadas na análise (DERSHOWITZ, 1984)(Figura 6).

A frequência de fraturas (também referida como intensidade I), dada em termos de amostragem por *scanline* é referida como

$$P_{10} = I_{scanline} = \frac{N}{L} \quad (2.1)$$

onde a quantidade de fraturas N é dividida pelo comprimento L . De forma semelhante a densidade D é dada por

Figura 6: Sistema de índices P_{xy} dado os espaços amostrais e dados de fratura observados.

		Dimensão de característica			
		0 Quantidade	1 comprimento	2 área	3 volume
Dimensão de região amostral	1 linha	P_{10} Frequência 1D = Intensidade	P_{11} Intensidade adimensional		
	2 área	P_{20} Frequência 2D	P_{21} Intensidade de fraturas	P_{22} Intensidade adimensional	
	3 Volume	P_{30} Frequência 3D		P_{32} Intensidade de fraturas	P_{33} Intensidade adimensional

Fonte: Adaptado de Sanderson e Nixon (2015)

$$P_{20} = D_{\text{área}} = \frac{N}{A} \quad (2.2)$$

dividindo-se a quantidade de fraturas pela área A de amostragem em m^2 . A mesma analogia pode ser aplicada quando observamos o volume em P_{30} .

A intensidade de fraturas $I_{\text{área}}$ por área é dada pelo índice

$$P_{21} = I_{\text{área}} = \frac{\sum_{i=1}^N L_i}{A} \quad (2.3)$$

onde $\sum_{i=1}^N L_i$ é a soma dos comprimentos de todas as fraturas em uma janela de amostragem. Enquanto a estimativa de área de fraturas por área amostral é dada pelo índice

$$P_{22} = \frac{\sum_{i=1}^N A_i}{A}. \quad (2.4)$$

Intensidade de fraturas em volumes, obtida a partir de dados de tomografia e sísmica por exemplo, tem relação direta com os índices de fraturamento por *scanline* e por área quando a variação média dos ângulos θ é nula e as normais do conjunto observado é paralelo à *scanline* e.g. $P_{10} = P_{21} = P_{32}$ (ZEEB et al., 2013).

Quanto a informação de espaçamento, conforme apontado por Stephen Mak BAsC (2014) a sua definição não é consistente, entretanto, é geralmente referida à distância média entre fraturas adjacentes, podendo ser tanto aplicada à amostragem por *scanline* quanto à amostragem por área (janela). Em relação à *scanline*, o espaçamento S_{scanline} é o inverso da intensidade, dado por

$$S_{\text{scanline}} = \frac{1}{P_{10}}, \quad (2.5)$$

enquanto o espaçamento para uma área de amostragem $S_{\text{área}}$ é dado por

$$S_{\text{área}} = \frac{A}{L_0 + \sum_{i=1}^N L_i} \quad (2.6)$$


onde L_0 é comprimento de um dos lados da área de amostragem.

Quanto ao comprimento das fraturas, estatísticas relacionadas à distribuição dos comprimentos são realizadas para toda a rede de fraturas ou para subconjuntos, dependendo da orientação de fraturas principais previamente identificadas ou a partir da análise multimodal do histograma de rosetas. Os comprimentos de fraturas naturais geralmente seguem a distribuição da lei de potência (BONNET et al., 2001; ZEEB et al., 2013; M. Tóth, 2018), embora distribuições log-normal, exponencial negativa, e gama também possam ser encontradas (MIRANDA et al., 2018; NYBERG; NIXON; SANDERSON, 2018; LEI; LATHAM; TSANG, 2017; ZEEB et al., 2013).

Quanto à orientação as fraturas em uma rede DFN são investigadas com o uso de histogramas circulares ou diagrama de rosetas. Os diagramas de roseta auxiliam na identificação de subconjuntos de fraturas de acordo com as direções predominantes, possibilitando a modelagem e análise separadamente (XU; DOWD, 2010). Tal procedimento pode ser aplicado também aos diagramas de projeções hemisféricas ou *stereonets*, onde, além das informações de orientação, a informação de mergulho das fraturas também pode ser levada em consideração (HEALY et al., 2017). Os dados de orientação podem apresentar distribuições uniformes, normais e de Fisher (EINSTEIN; BAECHER, 1983; LEI; LATHAM; TSANG, 2017).

A topologia de fraturas refere-se ao arranjo espacial e como fraturas e falhas se interconectam (SANDERSON; NIXON, 2015; PEACOCK et al., 2016). A topologia pode ser definida a partir da relação entre fraturas descrita a partir de definições de grafos (galhos e nodos). Observando a Figura 7, podemos identificar os diferentes tipos de nodos e em que situações eles ocorrem. Os nodos de terminação "I" ocorrem em fraturas isoladas, os nodos "Y" ocorrem em fraturas que se tocam e os nodos "X" ocorrem em fraturas que se cruzam.


Figura 7: Interações entre fraturas e tipos de nodos: nodos I em fraturas isoladas (a) e em aproximação (b); nodos Y em fraturas adjacentes (c) e em fraturas em deslocamento (d); nodos X em fraturas que se cruzam (e).



Fonte: Adaptado de Sanderson e Nixon (2015).

A topologia é fundamental para criar DFNs geológicos, pois, a depender da resolução adotada, podem ser obtidos valores para Y coerentes com meios geológicos, que respeitam a propagação de fraturas no processo de seu desenvolvimento.

Figura 8: Fluxo de levantamentos de dados geológicos desde o levantamento de campo e digital até a criação dos modelos DFN e reamostragem à escala de reservatórios.



Fonte: Elaborado pelo autor.

A caracterização de fraturas no DFN pela sua topologia pode ser feita tanto pela quantidade de elementos conectados em um subgrafo (conexões por linha ou por galho) (SANDERSON; NIXON, 2015; NYBERG; NIXON; SANDERSON, 2018), quanto pela porcentagem de nodos conectados (ANDREWS et al., 2019), em amostragem circular ou por área. O índice de porcentagem de nodos conectados de Andrews et al. (2019) é dado por

$$Pc = \frac{3N_y + 4N_x}{N_i + N_y + N_x} \quad (2.7)$$

onde N é a quantidade de nodos dos tipos "I", "Y" e "X".

A conectividade de fraturas também é fator importante no estudo da percolação, que define a propriedade do fluxo de fluido percorrer de um lado no corpo rochoso fraturado (importante na disposição de poços de extração de petróleo) (ADLER; THOVERT; MOURZENKO, 2013).

Nesse sentido o trabalho de Sævik e Nixon (2017), faz uma extensiva análise dos índices baseados em quantidade de nodos conectados e sugere um ajuste linear do índice Pc para a obtenção do índice de conectividade hidráulica f dado por

$$f = \max \left(0, \frac{2,94 * (4N_x + 2N_y)}{4N_x + 2N_y + N_i} - 2,13 \right) \quad (2.8)$$

para valores de f acima de 0, caso contrário a conectividade hidráulica é nula.

Uma vez obtidas as informações para a criação do modelo DFN a partir de informações geométricas, topológicas, mecânicas etc., o objetivo final do modelo DFN é integrar os modelos de simulação de fluxo de reservatório. Esse fluxo baseado no esquema proposto por Casini et al. (2016) é apresentado na Figura 8.

2.4.2 Distribuições estatísticas

A partir da rede de fraturas discretas, os atributos como distribuição de comprimento podem ser amostrados para toda a rede de fraturas ou subconjuntos, dependendo da orientação das principais fraturas previamente identificadas ou da análise multimodal do histograma da roseta

e estatísticas circulares adicionais (NYBERG; NIXON; SANDERSON, 2018).

As distribuições dos comprimentos das fraturas naturais geralmente seguem a distribuição da lei de potência (ZEEB et al., 2013; M. Tóth, 2018; BONNET et al., 2001), embora as distribuições log-normal, exponencial negativa e gama também possam ser encontradas (MIRANDA et al., 2018; NYBERG; NIXON; SANDERSON, 2018; LEI; LATHAM; TSANG, 2017; ZEEB et al., 2013). Além disso, a abertura da fratura também é avaliada pela distribuição das medições da amostra seguindo as distribuições log-normal, lei de potência e exponencial como no trabalho de (MIRANDA et al., 2018).

Neste trabalho, consideramos as distribuições lei de potência, exponencial e log-normal em sua forma de função de densidade de probabilidade (*Probability Density Function* - PDF) utilizando um gráfico log-log como base para a avaliação do melhor ajuste. Essas distribuições em termos do PDF são apresentadas na sequência.

A PDF da distribuição exponencial é dada por

$$p(x|\lambda) = \lambda \exp^{-\lambda x} \quad (2.9)$$

onde λ é um valor estimado por $\hat{\lambda} = 1/\bar{x}$, com $x \in X$, enquanto X é o conjunto de atributos medido.

A PDF da distribuição log-normal é dada por

$$p(x|\mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} \exp^{-\frac{(\ln x - \mu)^2}{2\sigma^2}} \quad (2.10)$$

onde μ é o valor médio da distribuição, e σ é o desvio padrão.

A PDF da distribuição de lei de potência é dada por

$$p(x|\alpha) = \frac{\alpha - 1}{x_{min}} \left(\frac{x}{x_{min}} \right)^{-\alpha} \quad (2.11)$$

onde α é o coeficiente de lei de potência l (RIZZO et al., 2017) que pode ser estimada por

$$\hat{\alpha} = 1 + n \left[\sum_{i=1}^n \ln \frac{x_i}{x_{min}} \right]^{-1}. \quad (2.12)$$

Para avaliar a distribuição dos comprimentos e dados de abertura, um método comum é traçar os dados de fratura no gráfico log-log como um eixo y inverso contra o PDF cumulativo no eixo x da distribuição da qual queremos medir a semelhança. As posições x e y neste gráfico são usadas para determinar o melhor ajuste dos dados aplicando o algoritmo de regressão linear de mínimos quadrados. O melhor ajuste é avaliado usando o coeficiente de determinação R^2 dado por

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y})^2} \quad (2.13)$$

onde \bar{y} é o valor médio de referência e \hat{y} são os valores estimados ou preditos.


2.5 Processamento de Imagens e Visão Computacional

Esta seção apresentará os conceitos básicos relacionados a visão computacional e processamento de imagens, necessários ao entendimento de técnicas de segmentação e identificação de características em imagens.

2.5.1 Discretização de imagens e espaço cor

Imagens digitais são representações discretizadas na forma de uma matriz $M \times N$ (imagem rasterizada) com valores de intensidade de luz (0 (preto) a 255 (branco) em imagens 8 bits em escala de cinza), ou com valores combinados representando cores no espectro visível (espaço de cores RGB, XYZ, HSV, CIELab), onde um píxel é dado por $I(u, v)$ ou $I(x, y)$, onde u ou x é a posição na coluna e v ou y é a posição na linha (BURGER; BURGE, 2016)(Figura 9).

Figura 9: Sistema de coordenadas em uma imagem digital



Fonte: Adaptado de Burger e Burge (2016).

Imagens RGB representam em cada camada (banda) os valores de retorno espectral das cores primárias vermelho (700nm), verde (546,1nm) e azul (435,8nm), definidos pela CIE (*Commission Internationale d'Eclairage*). O padrão de cores CIE XYZ é um reajuste (normalização) da representação RGB onde para representar certas cores a banda vermelha deveria ter valores negativos. Já o padrão CIELab ou $L * a * b$ é baseado em como os seres humanos percebem diferenças em luminosidade e cores (croma), de modo que essa diferença é calculada de maneira uniforme. L representa luminância, e a e b representam diferentes posições no espaço croma, onde a varia da cor vermelho a verde e b varia da cor azul a amarelo. Já o espaço de cor HSV é uma reprojeção do espaço de cor RGB, que separa a representação de cor em tonalidade (em inglês H - *hue*) dada pela posição angular, saturação (S) definindo a intensidade de cores, e valor (V) onde menores valores estão mais próximos do preto e valores mais altos estão mais

perto do branco (SZELISKI, 2011; BURGER; BURGE, 2016).

2.5.2 Melhoramentos e filtros

Melhoramentos de imagens incluem operações pixel-a-pixel ou a partir de informação de vizinhança com a aplicação de filtros convolutivos. A operação pixel-a-pixel mais comum é a equalização de histograma onde a distribuição dos valores de pixels é computada e os valores pixel são então redistribuídos considerando os valores máximo e mínimo de modo que o histograma tenha quantidades de valores de pixel semelhantes (equalizadas), aumentando o contraste da imagem.

O processo de suavização de ruídos em imagens assim como na detecção de bordas (Seção 2.6.1) consideram a vizinhança dos píxeis. Considerando $f(x, y)$, dependendo do tipo de suavização, diferentes filtros $h(x, y)$ e equações são aplicados para a obtenção do novo valor de pixel na imagem processada $g(x, y)$ (Figura 10).

Figura 10: Aplicação de filtro de vizinhança $h(x, y)$ a uma imagem $f(x, y)$, gerando uma imagem $g(x, y)$.

45	60	98	127	132	133	137	133	*	=	69	95	116	125	129	132					
46	65	98	123	126	128	131	133			68	92	110	120	126	132					
47	65	96	115	119	123	135	137			66	86	104	114	124	132					
47	63	91	107	113	122	138	134			62	78	94	108	120	129					
50	59	80	97	110	123	133	134			57	69	83	98	112	124					
49	53	68	83	97	113	128	133			53	60	71	85	100	114					
50	50	58	70	84	102	116	126													
50	50	52	58	69	86	101	120													
$f(x,y)$													$h(x,y)$				$g(x,y)$			

Fonte: Adaptado de Szeliski (2011).

Os filtros lineares são filtros onde os novos valores de píxel na imagem filtrada são dados pela soma ponderada dos píxeis em uma vizinhança. O filtro de média considera todos os valores do filtro como peso 1 enquanto o filtro Gaussiano é uma discretização da equação dada por

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}, \quad (2.14)$$

onde os elementos centrais têm um peso maior, conforme o filtro ilustrado na Figura 10.

Filtros não lineares incluem entre outros os filtros de mediana e bilateral. O filtro de mediana é semelhante ao filtro de média, entretanto, utiliza o valor de posição central em uma lista ordenada de valores de vizinhança, sendo útil na remoção de ruídos (*outliers*), também conhecidos como "sal e pimenta" (*salt and pepper*). O filtro bilateral (calculado para cada posição $I(u, v)$) é uma evolução do filtro de média ponderada e de mediana, onde é dado um maior peso

para os píxeis centrais e os píxeis que tem valores muito distantes do valor central são excluídos, contribuindo para a preservação de bordas (SZELISKI, 2011; TOMASI; MANDUCHI, 1998).

2.6 Segmentação de imagens

A segmentação de imagens tem o objetivo de auxiliar a identificação de objetos tanto utilizando a similaridade entre píxeis (segmentação por região) quanto a descontinuidade entre eles (detecção de bordas e identificação de curvas).

2.6.1 Detecção de bordas

A detecção de bordas é baseada na identificação de mudança de intensidade em uma direção (gradiente). Quanto mais forte for essa mudança, maior é a probabilidade de um píxel ou região pertencer a uma borda (BURGER; BURGE, 2016). O objetivo dos detectores de borda é destacar os gradientes na imagem, o que pode ser feito na forma de filtros convolutivos (KRIG, 2014), importantes na identificação semântica de objetos (SZELISKI, 2011).

As mudanças de gradiente podem ser identificadas ao observar os valores máximos e mínimos de funções derivativas de primeira ordem e em valores nulos (*zero crossing*), em derivadas de segunda ordem (Laplaciano) (Figura 11). Considerando um perfil (uma dimensão), a primeira derivada de uma função $f(x)$ é dada por

$$f'(x) = \frac{df}{dx}(x). \quad (2.15)$$

Considerando uma função discreta $f(u)$ (perfil em uma imagem) a primeira derivada é indefinida, sendo geralmente dada pela aproximação (aproximação de Taylor) da tangente de uma função $f(u)$ considerando a posição u e os valores de vizinhança $f(u-1)$ e $f(u+1)$ (BURGER; BURGE, 2016),

$$\frac{df}{dx}(u) \approx \frac{f(u+1) - f(u-1)}{(u+1) - (u-1)} = \frac{f(u+1) - f(u-1)}{2} \quad (2.16)$$

onde o método pode ser tanto aplicado na horizontal quanto na vertical.


Considerando um dado multidimensional (duas dimensões no caso de imagens em escala de cinza) a derivada da função multidimensional $I(u, v)$ é dada pelas derivadas parciais em cada uma das dimensões,

$$I_x = \frac{\partial I}{\partial x}(u, v) \quad , \quad I_y = \frac{\partial I}{\partial y}(u, v). \quad (2.17)$$

O gradiente da função $I(u, v)$ é dado pelo vetor

$$\nabla I(u, v) = \begin{pmatrix} I_x(u, v) \\ I_y(u, v) \end{pmatrix} = \begin{pmatrix} \frac{\partial I}{\partial x}(u, v) \\ \frac{\partial I}{\partial y}(u, v) \end{pmatrix}, \quad (2.18)$$

Figura 11: Exemplos de aplicações de filtros convolutivos baseados derivadas de primeira (b) e segunda ordem (c) em um perfil unidimensional (a)



Fonte: Adaptado de (BURGER; BURGE, 2016).

e a magnitude ou intensidade do gradiente é dado pelo módulo

$$|\nabla I| = \sqrt{I_x^2 + I_y^2}, \quad (2.19)$$

independente de rotação de objetos ou orientação da imagem.

Assim como na equação Gaussiana, as funções derivativas são discretizadas na forma de filtros derivativos convolutivos. Estes filtros, em uma dimensão, têm a forma $[-0,5 \ 0 \ 0,5]$ ou $[-1 \ 0 \ 1]$, onde o valor central é ignorado. Filtros multidimensionais de detecção de borda como Roberts, Sobel, Kirsch e Prewitt (ARGIALAS; MAVRANTZA, 2004) são baseados em filtros derivativos de dimensão 3×3 com pelo menos dois filtros para a computação da intensidade e direção do gradiente.

O filtro Prewitt se utiliza de dois filtros derivativos, um para a identificação de bordas verti-

cais e outro para a identificação de bordas horizontais:

$$H_x^P = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, \text{ e } H_y^P = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.20)$$

similarmente os filtros Sobel são dados como

$$H_x^S = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \text{ e } H_y^S = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}. \quad (2.21)$$

Os gradientes locais de Prewitt são dados por

$$\nabla I(u, v) \approx \frac{1}{6} \begin{pmatrix} (I * H_x^P)(u, v) \\ (I * H_y^P)(u, v) \end{pmatrix}, \quad (2.22)$$

enquanto os gradientes locais de Sobel são dados por

$$\nabla I(u, v) \approx \frac{1}{8} \begin{pmatrix} (I * H_x^S)(u, v) \\ (I * H_y^S)(u, v) \end{pmatrix}. \quad (2.23)$$

Tanto para Prewitt quanto para Sobel os resultados da aplicação dos filtros são dados por

$$I_x = I * H_x, \text{ e } I_y = I * H_y. \quad (2.24)$$

Assim podemos obter o gradiente de magnitude $E(u, v)$ e a orientação do angulo do gradiente $\Phi(u, v)$, respectivamente

$$E(u, v) = \sqrt{I_x^2(u, v) + I_y^2(u, v)} \quad (2.25)$$

e

$$\Phi(u, v) = \tan^{-1} \left(\frac{I_y(u, v)}{I_x(u, v)} \right) = \arctan(I_x(u, v), I_y(u, v)). \quad (2.26)$$

Outros filtros derivativos de primeira ordem incluem os filtros Robert (ROBERTS, 1963) com filtros de dimensões 2x2 e filtros "compass" Kirsch e Robinson (ROBINSON, 1977), que incluem filtros em mais direções, além da vertical e horizontal.

O detector de bordas Laplaciano é baseado na derivada de segunda ordem de uma função I e é dado por

$$\nabla^2 I = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2}, \quad (2.27)$$

onde devido a sua alta sensibilidade a ruídos, requer a aplicação de um filtro Gaussiano e a segunda derivada da função Gaussiana na forma de Laplaciano da Gaussiana dado por

$$\nabla^2 G_\sigma(\chi) = \frac{1}{\sigma^3} \left(2 - \frac{x^2 + y^2}{2\sigma^2} \right) \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right), \quad (2.28)$$

resultando em uma borda dupla como na Figura 11c. O elemento de borda desejado é obtido no retorno zero, podendo ser calculado ao observar os píxeis vizinhos na posição (i, j) . Dada uma função sinal $S(\chi)$, χ_z é a posição subpíxel da posição "zero crossing" na direção do gradiente, dado por (SZELISKI, 2011)

$$\chi_z = \frac{\chi_i S(\chi_j) - \chi_j S(\chi_i)}{S(\chi_j) - S(\chi_i)}. \quad (2.29)$$


Os filtros derivativos Laplacianos são dados por (KRIG, 2014)

$$H^L = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \begin{bmatrix} 0,5 & 1 & 0,5 \\ 1 & -6 & 1 \\ 0,5 & 1 & 0,5 \end{bmatrix}, \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}. \quad (2.30)$$

2.6.1.1 Detector de bordas Canny

O detector de bordas Canny (1986) é um detector de bordas composto de múltiplos estágios, tendo como objetivo final a geração de uma imagem binarizada com elementos de borda com 1 píxel de largura. É uma das técnicas mais utilizadas na detecção de bordas em imagens (SZELISKI, 2011; BURGER; BURGE, 2016). Primeiro um filtro Gaussiano é aplicado onde é possível variar o valor σ de suavização. O filtro Sobel é então aplicado a imagem suavizada onde são obtidos a intensidade e direção dos gradientes. Para melhor localização das bordas (Figura 12), apenas o valor máximo na direção do gradiente é mantido (*non-maximum suppression*). A limiarização por "histerese" utiliza dois valores de limiar, um alto e um baixo. Todos os píxeis com intensidade maior que o limiar mais alto são mantidos, enquanto píxeis conectados a esses são mantidos se eles se mantiverem acima do limiar mais baixo.

Figura 12: *Non-maximum suppression* dada uma posição (u, v) . A direção do gradiente é discretizada em quatro direções (a), dado o perfil na direção do gradiente (b), somente o píxel central de maior magnitude é mantido.




2.6.1.2 Algoritmo de Steger e matriz diferencial Hessiana

Esta seção apresenta a detecção de cume do algoritmo de Steger para obter linhas de centro, onde, para entender o método de detecção, podemos primeiro avaliar o perfil de fratura 1D de largura 2ω e altura h , que pode ser considerado como uma forma parabólica (Figura 13) expresso como

$$f(x) = \begin{cases} h(1 - (\frac{x}{\omega})^2), & \text{se } |x| \leq \omega \\ 0, & \text{se } |x| > \omega \end{cases} \quad (2.31)$$

Figura 13: Perfil de fratura em uma dimensão e perfil aproximado pelo algoritmo de Steger.



Fonte: Adaptado de Steger (1996).

Para a detecção de linhas e segmentos em uma imagem $z(x)$, onde elementos a serem identificados têm maior intensidade, as regiões de pico (ou vale) são identificadas onde $z'(x)$ se anula e $z''(x) > 0$ (STEGGER, 1996). Essa ideia é a mesma de se encontrar o máximo na parábola ilustrada na Figura 13, onde $f'(x) = 0$ e $f''(x) < 0$. No entanto, avaliar apenas a primeira e a segunda derivada não é suficiente, devido ao ruído inerente às imagens reais. Assim, a imagem precisa ser convolvida com o *kernel* de suavização gaussiana

$$g_{\sigma}(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp -\frac{x^2}{2\sigma^2}, \quad (2.32)$$

e suas derivadas $g'_{\sigma}(x)$ e $g''_{\sigma}(x)$, dando uma descrição completa do espaço de escala do perfil de linha ideal f . Em imagens reais, muitas abordagens para detecção de linhas consideram as linhas como forma de barra ($f(x) = h$ se $|x| < \omega$ e 0, caso contrário) e dificilmente o contraste em ambos os lados da linha é simétrico. Assim, considerando as linhas em forma de barra e incluindo um parâmetro a para levar em conta essa assimetria, a descrição do espaço de escala do perfil da linha pode ser dada por (STEGGER, 1998)

$$r(x, \sigma, \omega, a) = \phi_{\sigma}(x - \omega) + (a - 1)\phi_{\sigma}(x + \omega), \quad (2.33)$$

$$r'(x, \sigma, \omega, a) = g_\sigma(x - \omega) + (a - 1)g_\sigma(x + \omega), \quad (2.34)$$

$$r''(x, \sigma, \omega, a) = g'_\sigma(x - \omega) + (a - 1)g'_\sigma(x + \omega), \quad (2.35)$$

onde $\phi(x)$ é a integral do kernel gaussiano. Então, a posição da linha é dada por

$$l = -\frac{\sigma^2}{2\omega} \ln(1 - a), \quad (2.36)$$

que é obtido pelos mínimos de $r(x, \sigma, \omega, a)$ ou pelos pontos onde $r'(x, \sigma, \omega, a) = 0$. Em Steger (1998) foi mostrado que para σ pequenos, a detecção de linhas se tornará difícil, mas possível se

$$\sigma \geq \omega/\sqrt{3}. \quad (2.37)$$

Além disso, podemos ver na Equação 2.36 que a posição da linha será enviesada se $a \neq 0$, mas pode ser corrigida usando a definição da posição da linha por $r'(x, \sigma, \omega, a) = 0$ e da posição de borda por $r''(x, \sigma, \omega, a) = 0$ como foi mostrado em Steger (1998).

2.6.2 Segmentação baseada em região

A segmentação baseada em região divide as imagens em classes (*clusters*) que agrupam píxeis com características semelhantes, utilizando técnicas baseadas em clusterização (aprendizado não supervisionado) e Superpíxeis, crescimento de região, limiarização e técnicas baseadas em aprendizado supervisionado como redes neurais convolucionais.

2.6.3 Limiarização ou *Thresholding*

Limiarização também conhecida como binarização ou *thresholding* é uma técnica de segmentação baseada em região, que tem o objetivo de separar elementos de interesse (em primeiro plano) de elementos de fundo (ou de segundo plano). A imagem binarizada é obtida com a aplicação da função

$$b(x, y) = \begin{cases} 0, & \text{se } I(x, y) \leq T \\ 1, & \text{caso contrário} \end{cases} \quad (2.38)$$

onde b é a imagem binarizada, I é a imagem original em escala de cinza, (x, y) é a posição de um píxel da imagem e T é o valor de limiarização. Variando o valor T podemos separar os elementos da imagem, sendo que esse valor pode ser definido globalmente ou localmente em uma janela de vizinhança em uma posição $I(x, y)$.

O algoritmo de limiarização Otsu (1979) é originalmente um algoritmo de limiarização

global, onde o valor T é estimado baseado na distribuição de histograma.

Entretanto, a limiarização global é limitada a imagens com pouco ruído e contraste uniforme. Imagens degradadas, ou com variação de iluminação podem ser melhor segmentadas utilizando técnicas de limiarização locais. Técnicas de limiarização locais ou adaptativas como os algoritmos de Niblack, Bernsen (1986), Yanowitz e Bruckstein (1989), Phansalkar et al. (2011), Singh et al. (2011) e Sauvola e Pietikak (2000), originalmente criados para a segmentação de caracteres, geralmente estimam um valor $T(x, y)$ observando a vizinhança e uma janela de tamanho w^2 .

2.6.3.1 Superpíxel

A segmentação por superpíxeis agrupa pequenas regiões na imagem, dada a similaridade dos píxeis em cada região, geralmente com base em algoritmos de grafos e clusterização. O objetivo do uso de Superpíxeis é a otimização de desempenho computacional, onde píxeis maiores (superpíxeis) representam conjuntos de píxeis diminuindo o tamanho do espaço N .

O método SLIC (ACHANTA et al., 2012) (*Simple Linear Iterative Clustering*) é o método mais comum, tendo seu algoritmo baseado em clusterização. No algoritmo SLIC os centros dos *clusters* (sementes) S são iniciados em uma grade uniforme de tamanho $2S \times 2S$ onde S é dado por

$$S = \sqrt{N/K}, \quad (2.39)$$

onde N é a quantidade de píxeis na imagem e K é a quantidade de Superpíxeis desejados. Os *clusters* são iterativamente agregados seguindo a métrica dada por

$$d = \sqrt{\left(\frac{d_c}{m}\right)^2 + \left(\frac{d_S}{S}\right)^2}, \quad (2.40)$$

onde $d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2}$ é a diferença de cor no espaço CIElab e $d_S = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2}$ é distância espacial de um cluster C_k e um píxel vizinho i . Com todos os píxeis associados aos seus respectivos clusters e observada a distância d , a posição central de cada cluster é recalculada, reiniciando o processo de agrupamento utilizando as novas posições de *clusters*. O processo termina quando as posições dos novos *clusters* não tiverem diferença significativa em comparação à iteração anterior.

Já a segmentação de superpíxel ISF (VARGAS-MUNOZ et al., 2019) (*Iterative Spanning Forest*) é um algoritmo baseado em operações de grafo. O algoritmo ISF se baseia na técnica IFT (FALCÃO; STOLFI; ALENCAR LOTUFO, 2004) (*Image Foresting Transform*) para transformação de uma imagem I para um grafo $G = (I, A)$, onde I são os nodos (píxeis) da imagem, A é a matriz de adjacência, e $f(\pi t)$ é a função custo, onde πt é uma sequência de píxeis adjacentes utilizada para definir um caminho ótimo πt para cada píxel t , gerando uma

árvore de caminhos ótimos P .

As sementes (*seeds*) na técnica ISF serão raízes de uma subárvore S representando cada superpíxel na árvore P . Diferentemente do algoritmo SLIC o posicionamento das sementes é feito de maneira não uniforme, de modo que regiões com mais detalhes tenham sementes mais próximas dado um quadrante Q . O reposicionamento das sementes é dado seja pelo píxel com a cor mais próxima à cor média do superpíxel ou pelo píxel mais central no superpíxel.

2.6.3.2 Crescimento por região

O crescimento por região (*region growing*, em inglês) realiza segmentação por região por similaridade baseada em crescimento iterativo de regiões com características semelhantes. A partir de uma posição como semente, a integração de novos píxeis à região é realizada avaliando a similaridade do píxel original com os píxeis da vizinhança, sendo estes 4 píxeis (vizinhos na vertical e horizontal), ou 8 píxeis (considerando também os píxeis na diagonal). A similaridade d pode ser dada pela similaridade de luminosidade (em imagens de escala de cinza), similaridade de cor, intensidade e direção do gradiente ou uma combinação destes fatores. O crescimento por região é um processo iterativo que termina quando não há mais píxeis que atendam os requisitos de crescimento, sendo mais indicado para seleção de algumas regiões como opção à seleção manual (RUSS, 2007), além de ser computacionalmente custoso.

2.7 Operações morfológicas

As operações morfológicas são operações que alteram a forma de objetos na imagem, geralmente aplicadas quando se quer reforçar uma característica ou reduzir ruídos (KRIG, 2014).

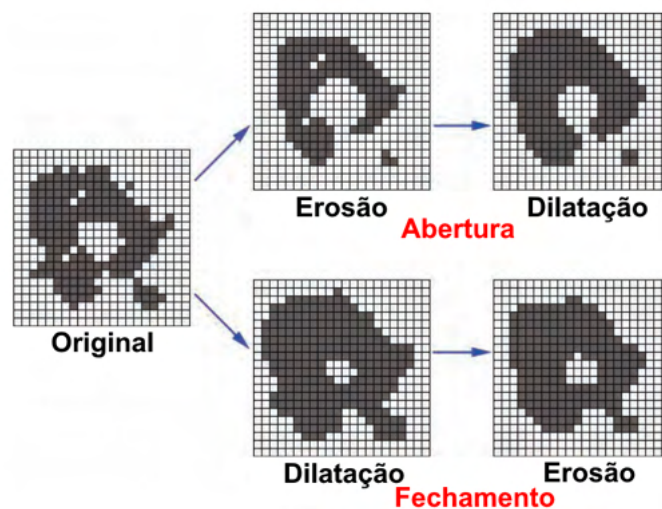
Os operações mais comuns envolvem a modificação de imagens binárias (com píxeis variando de 0 a 1), sendo elas a erosão e a dilatação. A erosão remove um píxel no perímetro do objeto, conseqüentemente, elementos com 1 píxel são eliminados. A dilatação adiciona um píxel no perímetro do objeto, sendo bastante útil quando se quer reforçar objetos ou reconectar bordas. Ambas operações podem ser realizadas com a aplicação de filtros.

Diferentes combinações dessas duas operações geram as operações de abertura (erosão seguida de dilatação) e fechamento (dilatação seguida de erosão) (Figura 14).

2.7.1 Esqueletização

A esqueletização é o processo de reduzir elementos/objetos à sua linha central (*medial axis*). O esqueleto de um objeto pode reter a sua forma topológica ou forma geométrica ou ambas, dependendo da técnica utilizada. Ao contrário da erosão, a esqueletização garante que os elementos se mantenham conectados ao final do processo. As principais técnicas de esqueletização são baseadas em transformação de distância (*distance transform*), diagrama de Voronoi e afina-

Figura 14: Operações morfológicas que compõem as operações de abertura e fechamento.




Fonte: Adaptado de Russ (2007).

mento (ABU-AIN et al., 2013).

Os algoritmos desenvolvidos por Zhang e Suen (1984) e Lee, Kashyap e Chu (1994a) são populares algoritmos de esqueletização iterativos baseados em afinamento, entretanto algoritmos baseados em Medial Axis Transform (MAT) também são bastante empregados. A Figura 15 mostra a aplicação dessa técnica para a obtenção das linhas centrais (na cor branca).

Figura 15: Algoritmo de esqueletização baseado em MAT aplicado a formas diversas.



Fonte: Montero e Lang (2012).

2.8 Transformadas

Nesta seção são apresentadas as transformadas baseadas na representação de imagens como função discreta de um sinal bidimensional para as transformadas de Fourier e *Wavelet*, bem como as transformadas baseadas em detecção de objetos como a transformada Hough.

2.8.1 Transformada Hough

A transformada Hough foi patenteada por Hough (1962) e modificada por Duda e Hart (1972), criando a variação hoje chamada de "transformada Hough generalizada" (*generalized Hough transform*). A transformada Hough foi criada originalmente para identificar retas em imagens, mas há variações que permitem identificar círculos e elipses, bem como formas arbitrárias.

A transformada Hough é uma transformação linear de bordas de píxeis contíguos em segmentos ou retas. A implementação mais básica da transformação Hough se utiliza da transformação da identificação de linhas para o espaço de parâmetros que representam a reta, dado por

$$y = mx + b, \quad (2.41)$$

onde x e y são coordenadas ou posições de píxel, m é o parâmetro de inclinação da reta e b é o parâmetro de interceptação. Uma matriz denominada acumulador armazena os votos para cada combinação de parâmetros (m e b), que definem as retas. A partir de um píxel de borda na imagem, a vizinhança é verificada em uma varredura circular em intervalos definidos de ângulos, se um outro píxel de borda é encontrada na vizinhança o acumulador incrementa o "voto" para aquele parâmetro de reta até esse novo píxel. Um limiar definido aplicado ao acumulador filtrará os segmentos identificados na imagem.

A modificação de Duda e Hart (1972) resolve o caso em que o parâmetro m tende ao infinito propondo o uso de coordenadas polares para a definição de reta, utilizando ρ ou r como a distância da reta até a origem e θ para o ângulo da linha para a definição de uma reta dada por

$$y = \left(-\frac{\cos\theta}{\sin\theta} \right) x + \left(\frac{\rho}{\sin\theta} \right), \quad (2.42)$$

que é usualmente modificada para

$$\rho = x\cos\theta + y\sin\theta. \quad (2.43)$$

Devido às equações de reta, seja em coordenadas polares ou cartesianas, não indicarem tamanhos de segmentos, técnicas adicionais são necessárias para determinar segmentos. Além disso, implementações mais recentes da transformada Hough trazem modificações no método de votação no espaço parâmetro para melhorar o desempenho, com destaque para a implemen-

tação probabilística e a probabilística progressiva (MATAS; GALAMBOS; KITTLER, 2000) implementada no OpenCV. Outras implementação da transformada Hough estão presentes no trabalho de revisão de Hassanein et al. (2015).

2.8.2 Transformadas de Fourier e Wavelet

A análise de Fourier é muito utilizada em análise de sinais em uma dimensão para ressaltar ou decompor um sinal com a aplicação de um determinado filtro de onda. Entretanto o sinal tem sua variação observada somente na amplitude enquanto o filtro de onda é uma janela fixa que percorre o sinal. A transformada de Fourier em sua forma discreta pode ser aplicada em imagens 2D para a identificação de bordas e objetos em imagens.

A análise Wavelet se diferencia da análise Fourier por variar o seu comportamento na escala do tempo (translação), além de variar seu comportamento na escala de amplitude (dilatação) em uma função ψ denominada Wavelet-mãe dada por

$$\psi_{a,b}(x) = |a|^{-1/2} \psi \left(\frac{x-b}{a} \right) \quad a, b \in \mathbb{R}, a \neq 0, \quad (2.44)$$

onde a é o fator de dilatação e b é o fator de translação.

A análise multirresolução a partir de *Wavelets* é baseada na decomposição em pirâmide desenvolvida por Mallat (1989). Esta técnica é utilizada tanto para suavização (*downsampling*) quanto para decomposição e reconstrução de detalhes em imagem. Cada nível j na pirâmide tem metade dos coeficientes no nível $j + 1$, onde sua extensão para o caso bidimensional para uma função imagem $f(x, y)$ é dado por


$$\begin{aligned} \phi_{j_0,k}(x, y) &= 2^{j_0/2} \phi(2^{j_0}x - k_1) \phi(2^{j_0}x - k_2) \\ \psi_{j,k}^{(Horizontal)}(x, y) &= 2^{j/2} \phi(2^jx - k_1) \psi(2^jx - k_2) \\ \psi_{j,k}^{(Vertical)}(x, y) &= 2^{j/2} \psi(2^jx - k_1) \phi(2^jx - k_2) \\ \psi_{j,k}^{(Diagonal)}(x, y) &= 2^{j/2} \psi(2^jx - k_1) \psi(2^jx - k_2) \end{aligned}$$

onde k são os parâmetros de posição e ϕ é a Wavelet- dada um nível j . A Figura 16 ilustra a dimensão dos coeficientes para uma decomposição de 4 níveis. A decomposição obtém menos detalhes à medida que observamos níveis mais baixos na pirâmide dada as três direções horizontal, vertical e diagonal.

2.9 Aprendizado de máquina

Adicional à segmentação de imagens por métodos de processamento de imagens e visão computacional, os dados de segmentação podem também ser agrupados, classificados ou preditos (regressão) por técnicas de aprendizado de máquina supervisionadas e não supervisionadas.

Figura 16: Esquema dos coeficientes Wavelet em uma decomposição de 4 níveis.



Fonte: Adaptado de Nason e Silverman (1995).

Além disso, as técnicas de aprendizado de máquina baseado em *deep learning* também têm sido utilizadas nas tarefas de identificação de objetos nas imagens e identificação/classificação de objetos em cada píxel, geralmente referenciada como técnica de segmentação semântica.

2.9.1 Técnicas de classificação supervisionadas

As técnicas de classificação supervisionada, em oposição às técnicas de agrupamento ou não supervisionadas, aprendem ou replicam o comportamento dos dados de entrada (X) e anotações esperadas para cada dado (Y). Algumas dessas técnicas incluem as árvores de decisão, KNN (*K-Nearest-Neighbor*), Regressores logísticos, redes neurais artificiais etc. As seções abaixo apresentam algumas destas técnicas, brevemente.

Árvores de Decisão (MURPHY, 2012; KUBAT, 2017) são modelos de regressor e classificador baseados em árvores binárias onde cada nó avalia um valor de atributo para inferir uma decisão. Cada nó é ainda dividido até as folhas que indicam o objeto de classe. Nesta técnica, algoritmos como C4.5 e CART (SINGH; GUPTA, 2014) são usados para decidir se um nó é dividido ou não. Outro ponto a ser considerado é a métrica para avaliar cada nó de decisão, que podem ser por entropia e índice de Gini (pureza de decisão), por exemplo.

O classificador Random Forest expande a técnica de árvore de decisão gerando múltiplas árvores de decisão fornecidas com subconjuntos aleatórios dos dados, enquanto a decisão do classificador é feita por votação.

O algoritmo KNN (MURPHY, 2012; KUBAT, 2017), usado tanto para regressão quanto para classificação, é baseado na distância de classes de objetos em um espaço de classe/atributos. Cada objeto ou amostra neste espaço será utilizado para classificar novos objetos apresentados em um procedimento de votação de classe dos K vizinhos mais próximos.


O classificador Naive Bayes (MURPHY, 2012; KUBAT, 2017) é um classificador probabilístico baseado no teorema de Bayes com alta independência entre os pares de características comparados.

A regressão logística (MURPHY, 2012; KUBAT, 2017) é um classificador probabilístico que utiliza uma abordagem discriminativa ajustando um modelo de probabilidade baseado na função sigmóide (função logística) aplicada ao produto de probabilidades de atributos ponderados, em uma estrutura semelhante aos perceptrons.

O classificador *Support Vector Machine* (Máquinas de vetor de suporte) (NOBLE, 2006) é baseado na margem máxima entre objetos. Ele usa hiperplanos em um espaço N-dimensional na margem de cada conjunto usando os vetores de suporte enquanto define o hiperplano maximizado (limite de decisão). Nesta técnica, o hiperplano ótimo é obtido ajustando os pesos aplicados aos vetores de suporte usando uma perda de função e um otimizador como o *Stochastic Gradient Descent* - SGD. O classificador SVM depende de funções de kernel para mapear espaços de recursos de alta dimensão.

As Redes Neurais Artificiais (RNA) (MURPHY, 2012; KUBAT, 2017), usadas tanto para regressão quanto para classificação, são estruturas baseadas em perceptrons conectados que imitam neurônios, pois são uma soma ponderada de entradas de sinal que posteriormente passam em uma função de ativação como o Sigmoid, Tangente hiperbólica (Tanh) e Unidade linear retificada (ReLU). Sendo a estrutura Multilayer Perceptron (MLP) com camadas ocultas uma estrutura comum para as redes RNA (Figura 17). Nesta estrutura, o *backpropagation* é a etapa de aprendizado, que faz uso de otimizadores (HAJI; ABDULAZEEZ, 2021) para atualizar o peso dos perceptrons e reduzir o custo dos erros.

Figura 17: Estrutura básica de uma rede neural artificial multicamadas.



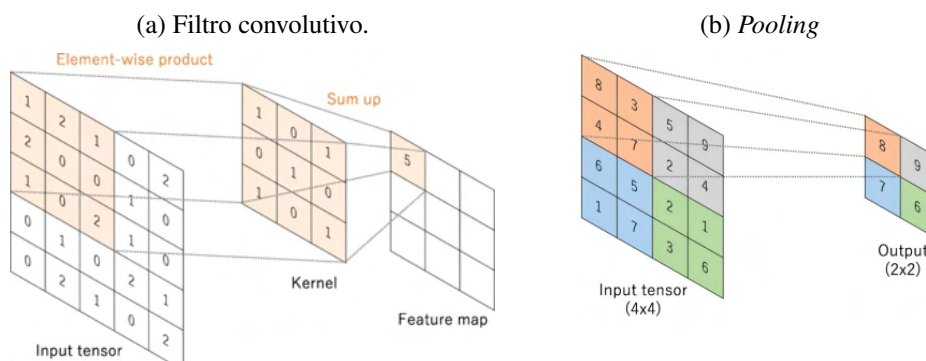
Fonte: Adaptado de Bishop e Nasrabadi (2006).

2.9.2 Técnicas de identificação de objetos e segmentação

Técnicas de aprendizado de máquina para segmentação de imagens, em geral, fazem uso de Redes Neurais Convolucionais (CNNs), que evoluíram das RNAs clássicas. Nesses modelos de rede, os perceptrons são organizados em camadas de filtros de aprendizado que envolvem as entradas da imagem para aprender padrões espaciais.

Os filtros de convoluções em CNN são semelhantes aos filtros convolutivos apresentados na Figura 10, porém os filtros são aprendidos pela rede em vez de previamente definidos. As imagens ou dados resultantes da passagem do filtro são os mapas de características ou *feature maps* (Figura 18a), que geralmente passam por uma convolução de *pooling* para a redução espacial do dado. A camada *pooling* reduz a *feature map* espacialmente, selecionando o maior valor em uma região ou computando a média dos valores (Figura 18b). Outros tipos de camada, como camadas *dropout* e *pooling*, complementam esse modelo (SKANSI, 2018).

Figura 18: Elementos básicos de uma rede CNN.



Fonte: Adaptado de Yamashita et al. (2018).

O primeiro uso das CNNs em visão computacional foi detectar e classificar objetos dentro de imagens, evoluindo posteriormente para incorporar a localização de objetos. À medida que os recursos computacionais evoluíram, principalmente no processamento de tensores em placas de processamento gráfico ou em placas de processamento dedicado, novas arquiteturas como as redes *deep learning* de segmentação semântica, de instância e panópticas surgiram.

As CNNs de segmentação semântica diferem dessas implementações anteriores, fornecendo rotulagem para cada píxel dentro de uma imagem, separando classes de objetos ou objetos individuais (instâncias) (SKANSI, 2018). As redes de segmentação panópticas combinam as propriedades das redes de segmentação semântica e por instância para segmentar e identificar objetos individuais e partes de objetos. Por limitação de escopo e por ser o modelo mais comum na detecção de fraturas (ver Capítulo 3), uma breve apresentação das redes de segmentação semântica é realizada.

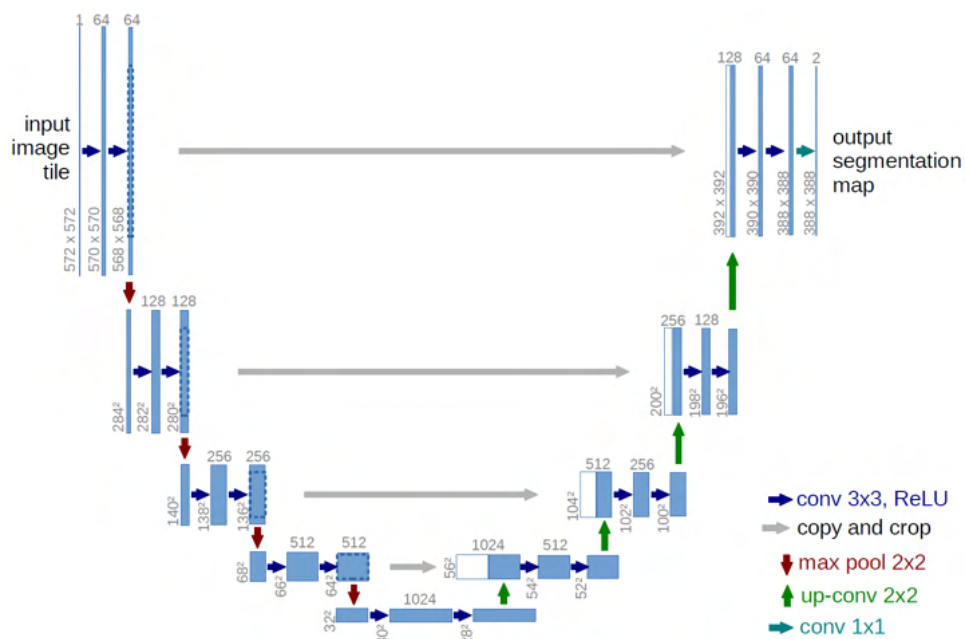
2.9.3 Redes CNN *encoder/decoder* para segmentação semântica

As FCNs (*Fully Connected Network*), Segnets (BADRINARAYANAN; KENDALL; CIPOLLA, 2017) e U-nets (RONNEBERGER; FISCHER; BROX, 2015) são modelos populares de arquitetura CNN para segmentação semântica com base em estruturas de codificação/decodificação (*encoder/decoder*), que foram aplicadas com sucesso em engenharia civil, medicina/biologia, sensoriamento e transporte (ABDOLLAHI; PRADHAN; ALAMRI, 2020).

As CNNs para segmentação semântica usam a estratégia de codificação e decodificação, aumentando a profundidade e reduzindo a resolução dos mapas de recursos na primeira parte e, em seguida, revertendo para o tamanho original da imagem na saída.

A U-net (RONNEBERGER; FISCHER; BROX, 2015) CNN é moldada em um formato U de camadas interconectadas, com camadas de codificação injetando dados nas camadas de decodificação, conforme mostrado na Figura 19.

Figura 19: Arquitetura *encoding-decoding* da rede U-net.



Fonte: Ronneberger, Fischer e Brox (2015)

Uma característica comum dessas redes é uso de filtro *convolutional up-sampling* para restaurar os mapas de características para a resolução da imagem de entrada na fase de *decoding*. Ainda, em relação as U-nets, possuem como característica a concatenação de camadas na fase de *encoding* com camadas na fase de *decoding* com mesma resolução.

3 TRABALHOS RELACIONADOS

Este capítulo reúne os principais trabalhos que apresentam como objetivo a caracterização de fraturas ou redes de fraturas a partir de imagens obtidas por câmeras digitais RGB e/ou acompanhado de fotogrametria digital, capturando feições de afloramentos e rochas expostas de forma automática ou semiautomática (supervisionada) utilizando processamento de imagens, visão computacional e *deep learning*. São considerados trabalhos desenvolvidos nos últimos 20 anos.

3.1 Metodologia

A metodologia de busca, síntese e análise dos artigos selecionados se dará pelas definições do protocolo de revisão sistemática, de modo a garantir a reprodutibilidade da pesquisa e diminuir o viés inerente da pesquisa exploratória tradicional, de modo a preencher lacunas e conceitos ausentes em artigos principais selecionados arbitrariamente.

A criação ou planejamento do protocolo de execução é o primeiro passo na execução e divulgação da revisão sistemática e serve como guia ou apresentação do que o processo como um todo traz como requisitos e definições (KITCHENHAM, 2004; KITCHENHAM; BUDGEN; BRERETON, 2006). As três etapas principais de planejamento, execução e divulgação de uma revisão sistemática podem ser divididas em dez sub-etapas ou definições detalhadas apresentadas a seguir baseadas nos trabalhos de Khan et al. (2001); Boland, Cherry e Dickson (2017).

A primeira das sub-etapas é a definição de recursos, tanto de pessoal em caso de times quanto do uso de softwares e sistemas de gerenciamento das atividades e das referências coletadas durante todo o processo, além da definição de prazos para a condução da Revisão de Literatura Sistemática. Neste trabalho a condução da revisão é feita de forma individual pelo pesquisador, utilizando software de gerenciamento de referências Mendeley, planilhas em Excel, scripts para mineração de texto em linguagem R e ferramentas visuais como a aplicação em Java VOSViewer¹.

A segunda sub-etapa se refere a definições do protocolo de condução da revisão e envolve a definição do tema e escopo levantados por meio de pesquisa inicial sobre o tema, que são sumarizados aqui como questões de pesquisa principal e secundárias.

As questões listadas aqui como QP (questão principal) e QS (questões secundárias), visam atender os objetivos específicos de estudo das técnicas disponíveis na detecção de fraturas em imagens e geração dos modelos DFN de modo a identificar tendências e oportunidades de pesquisa:

- QP - Quais são as principais técnicas e algoritmos utilizados na detecção de fraturas em imagens

¹<https://www.vosviewer.com/>

- QS - Quais propostas de melhorias e vantagens apresentados para cada técnica
- QS - Quais fontes de dados são utilizadas e suas particularidades
- QS - Quais estatísticas e características são extraídas para a geração dos modelos DFN

Adicionalmente ao levantamento das questões de pesquisa, os critérios de inclusão e exclusão dos artigos também são estabelecidos nesta etapa. Neste trabalho de pesquisa eles incluem a escolha por artigos publicados em conferências e revistas indexadas nas bases de dados escolhidas no período de 2001 a 2021, excluindo capítulos de livros, comunicações de pesquisa e outras publicações como editoriais que não tenham passado por crivo científico.

A terceira sub-etapa na construção da revisão sistemática é uma continuação do planejamento do protocolo de pesquisa, que na prática é o começo da execução da revisão, onde são definidas as palavras (ou frases) de busca. Nesta etapa, a frase de busca é testada e modificada de modo a obter os trabalhos que mais se adequam ao tema, e é comum a criação de variações dependendo da base de dados utilizada.

Este trabalho considera como base de pesquisa principais as bases de dados Elsevier Scopus e Science Direct, e IEEE Xplore Digital Library, sendo não consideradas as bases Springerlink (pela predominância de livros e capítulos de livro), Google Acadêmico (pelo não uso de operadores booleanos no sistema de pesquisa principal), e Web of Science pela grande abrangência de trabalhos já cobertos pela base de dados Scopus (HARZING; ALAKANGAS, 2016; POWELL; PETERSON, 2017).

Foram identificadas na pesquisa inicial de levantamento dos trabalhos mais relevantes para este trabalho de tese, definições e palavras chaves que se alternam temporalmente, mas que têm a mesma equivalência no escopo observado. Estas palavras são apresentadas na frase de busca a seguir entre parênteses acompanhadas pelo operador *booleano OR*:

- (fracture OR discontinuity OR lineament OR trace) AND (detection OR recognition OR segmentation) AND image AND (outcrop OR rock)

Quando possível, a frase de busca é modificada para:

- (fracture OR discontinuity OR lineament OR trace) AND (detection OR recognition OR segmentation) AND image AND (outcrop OR rock) AND NOT (log OR ct OR 3d)

para limitar os trabalhos que não usem os tipos de imagem esperados como dados de entrada.

Obtidas as listas de artigos de cada base de dados, estas são carregadas para o software de gerenciamento de referências Mendeley, onde um primeiro filtro de entradas repetidas é realizado.

Esta tarefa é seguida pelo filtro de leitura dos resumos e títulos ou *screening* (quarta etapa), para a verificação do escopo de cada trabalho, que é acompanhada logo em seguida pela recuperação dos artigos completos e avaliações de seus conteúdos (como quinta e sexta sub-etapa).

Os achados relevantes em cada artigo são tabulados na sétima sub-etapa da condução da revisão sistemática, de modo a facilitar a posterior avaliação qualitativa e quantitativa dos trabalhos selecionados.

A oitava sub-etapa é descrita por Boland, Cherry e Dickson (2017) como a etapa de avaliação de qualidade dos artigos, verificando por exemplo, quantidade de citações e outros índices referentes ao artigo ou à revista, além de pontuar requisitos em cada trabalho como a descrição do *dataset* e a avaliação e comparação com outros trabalhos relevantes. Pela quantidade reduzida de trabalhos, esta avaliação de qualidade não foi conduzida.

A filtragem dos artigos conduzida nas sub-etapas 4 à 8, e a quantidade de artigos excluídos, alimentam o diagrama sugerido pelo conjunto de regras e definições estabelecidos pelo *Preferred Reporting Items for Systematic reviews and Meta-Analyses (PRISMA)* em Moher et al. (2009), mais tarde atualizado por Page et al. (2021).

A sub-etapa 9, descrita por Boland, Cherry e Dickson (2017), é a síntese qualitativa e quantitativa dos trabalhos, usualmente acompanhada da última etapa que fará uma discussão e conclusão do que foi encontrado de relevante nessa etapa da pesquisa.

3.2 Execução da Revisão de Literatura Sistemática e extração de dados

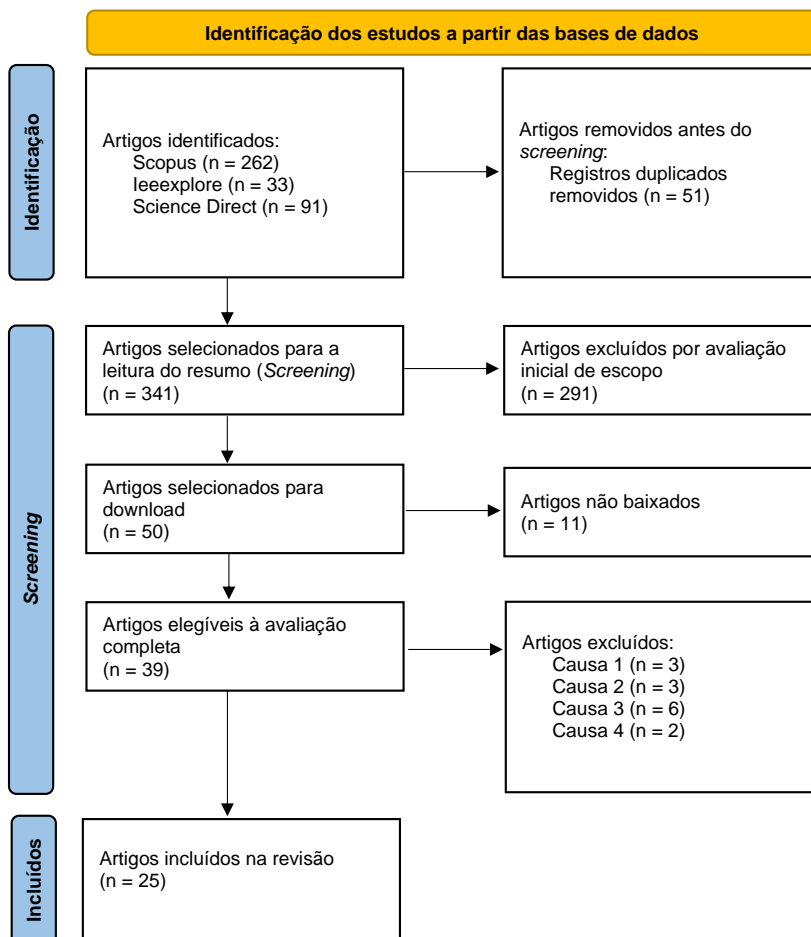
Esta seção é detalhada, principalmente pelo diagrama Prisma (Figura 20) a execução da revisão sistemática, onde é demonstrado que houve uma predominância de trabalhos oriundos da base de dados Scopus.

Após a inserção dos arquivos ".bib" das três bases de dados no gerenciador de referências Mendeley, as entradas repetidas são automaticamente identificadas. Entretanto, 7 das 51 entradas repetidas foram identificadas manualmente, deixando 341 resumos a serem lidos na fase de *screening*. Na leitura dos resumos foram eliminados 291 artigos, restando 50 artigos para uma avaliação mais aprofundada onde 11 artigos não puderam ter o arquivo pdf baixado ou não se enquadraram no formato de trabalhos propostos na definição dos critérios de inclusão e exclusão.

Dos 39 artigos selecionados para a leitura completa, 11 foram excluídos por não se encaixarem nos critérios definidos quanto aos tipos de produtos avaliados, ou ao tipo de metodologia empregada. As causas para a exclusão desses artigos são listadas a seguir:

- Causa 1: Artigos onde não há processamento de imagens automático;
- Causa 2: Utilizam imagens ou modelos volumétricos de tomógrafos ou microscópios digitais;
- Causa 3: Utilizam fotos de rochas que foram alteradas fisicamente ou preenchidas;
- Causa 4: Não apresentam imagens RGB ou em escala de cinza.

Figura 20: Execução da revisão sistemática seguindo a diagramação sugerida em Page et al. (2021).



Fonte: Elaborado pelo autor.

Ao final desta etapa de *screening* e avaliação completa dos trabalhos foram considerados 25 destes (Tabela 1) para as etapas posteriores de síntese, e análise qualitativa e qualitativa

Tabela 1: Artigos considerados para a revisão em ordem cronológica.

Autor	Título	Ano
(BARDUCCI; MECOCCI; PAPERINI, 2002)	Detection of linear geological features (jointing) by Hough transform of multispectral remotely sensed images	2002
(LEMY; HADJIGEORGIOU, 2003)	Discontinuity trace map construction using photographs of rock exposures	2003
(LEMY; HADJIGEORGIOU, 2004)	A digital face mapping case study in an underground hard rock mine	2004
(WANG; HAKAMI, 2005)	A segmentation algorithm for rock fracture detection	2005
(WANG, 2005)	An edge based segmentation algorithm for rock fracture tracing	2005
(YAO; WANG, 2006)	Color image segmentation of rock fracture stuffing base on image fusion	2006
(ANTONY; DOVE, 2006)	Semiautomatic rock mass discontinuity detection using digital images	2006
(WEIXING; HAIJUN; YING, 2007)	Rock fracture tracing based on image processing and SVM	2007
(LIU; JIN; WANG, 2009)	Detection of rock fractures junction in gray-level images	2009
(WANG; WAN; YANG, 2010)	Rock fracture extracting on fractional differential	2010
(GUO et al., 2012)	A semi-automated methodology for rock mass discontinuity trace map construction	2012
(LIU et al., 2013)	Automatic quantification of crack patterns by image processing	2013
(WANG; LIANG, 2015)	Rock fracture centerline extraction based on hessian matriz and steger algorithm	2015
(WANG et al., 2017)	Rock fissure pattern characterization by combining 1-D fractal dimension and statistical analysis	2017
(TIAN; DAIGLE, 2018)	Machine-learning-based object detection in images for reservoir characterization: A case study of fracture detection in shales	2018
(PRABHAKARAN et al., 2019)	An automated fracture trace detection technique using the complex shearlet transform	2019
(SANTOSO; HE; HOTEIT, 2019)	Application of machine-learning to construct simulation models from high-resolution fractured formation	2019
(BASIRAT; GOSHTASBI; AHMADI, 2019)	Determination of the Fractal Dimension of the Fracture Network System Using Image Processing Technique	2019
(LIU; REN, 2019)	Research on Coal-Rock Fracture Image Edge Detection Based on Tikhonov Regularization and Fractional Order Differential Operator	2019
(ZENG et al., 2020)	Automatic Extraction of Fractures in Digital Geological Outcrop of Carbonate Rocks and Its Application	2020
(LU et al., 2020)	Convolution neural network based on fusion parallel multiscale features for segmenting fractures in coal-rock images	2020
(WANG et al., 2020)	Crack and Fracture central line delineation on Steger and Hydrodynamics with improved Fractional differential	2020
(WEISMÜLLER et al., 2020)	Mapping the fracture network in the Lilstock pavement, Bristol Channel, UK: manual versus automatic	2020
(BYUN et al., 2021)	A deep convolutional neural network for rock fracture image segmentation	2021
(CHEN et al., 2021)	Automated extraction and evaluation of fracture trace maps from rock tunnel face images via deep learning	2021
(MARQUES et al., 2021)	Deep learning application for fracture segmentation over outcrop images from UAV-based digital photogrammetry	2021
(PI et al., 2021)	Digital image processing method for characterization of fractures, fragments, and particles of soil/rock-like materials	2021
(HU, 2021)	Integrated Machine Learning and Numerical Modeling for Multiscale Analyses of Coupled Processes in Geosystems	2021
(LENG et al., 2021)	Rock mass trace line identification incorporated with grouping algorithm at tunnel faces	2021

Fonte: Elaborado pelo autor.

3.2.1 Estado da arte

Observados os artigos selecionados (Tabela 1) após a leitura completa dos textos, foi possível estabelecer o estado da arte dos trabalhos que detectam e caracterizam fraturas em imagens. Estes trabalhos são brevemente apresentados a seguir, em ordem cronológica.

Como um dos primeiros trabalhos, Barducci, Mecocci e Paperini (2002) é um dos poucos que utilizam imagens espectrais (bandas termais) como base à detecção de fraturas, classificando previamente possíveis áreas que podem ser confundidas com feições geológicas, que é o caso de rios e estradas. Este processo de classificação, baseado em Bayes, é seguido pela extração de bordas (não detalhada no trabalho) e pelo uso da transformada Hough para o reconhecimento de linhas de fraturas (técnica muito comum no começo da década). Devido à alta dimensionalidade das imagens de sensoriamento remoto para a área estudada, a detecção de linhas pela transformada Hough foi conduzida separando a imagem de entrada em "tiles" (mosaico). Após a detecção de linhas, somente são gerados o diagrama de roseta e o mapa de delineamentos.

Lemy e Hadjigeorgiou (2003) utilizam redes neurais para classificar segmentos de fratura utilizando parâmetros fotométricos (gradientes, valores de intensidade, curvatura) e geométricos (comprimento, curvatura local), utilizados para descrever os segmentos de bordas e linhas centrais, como dados de entrada. Os segmentos são então ligados (*segment linking*) usando como base a proximidade e ângulo entre segmentos. Como operação final, uma interpretação manual de traços faltantes é permitida ao usuário. Estatísticas de espaçamento/frequência e comprimento de fraturas são obtidas. Um índice chamado *Rock Quality Designation*, que quantifica a porcentagem de rocha maiores que 10cm intactas ao longo de uma linha também é considerado. A mesma estrutura de trabalho é rerepresentada em Lemy e Hadjigeorgiou (2004).

Wang e Hakami (2005) fazem uma pequena revisão dos métodos de detecção de bordas e vales aplicados à detecção de fraturas, considerando ainda as diferenças no desempenho dessas aplicações quando consideradas diferentes escalas da imagem. Já o trabalho de Wang (2005), estende o trabalho anterior trazendo uma proposta de identificação de vales que avalia a vizinhança de cada píxel considerando quatro direções variando a distância de observação. Etapas de pós-processamento incluem a esqueletização, conexão entre segmentos próximos e remoção de *outliers* (segmentos menores desconectados).

Antony e Dove (2006) desenvolveram uma aplicação de delineamento automático chamada VTrace, que combina diversas etapas de processamento de imagens e visão computacional como: suavização por filtro passa baixa e de mediana; *Thresholding* global definido manualmente e automático por Otsu; e esqueletonização pelo algoritmo de Naccache e Shinghal (1984) e por Zhang e Suen (1984). As fraturas são identificadas analisando a imagem esqueletizada e identificando-se os nós e terminações para a definição de feições lineares que são usadas como base para a extração das características de fratura como comprimento e orientação. As feições lineares ainda são usadas para a identificação da largura, identificando-se a quantidade de píxels

observados na direção perpendicular ao traço da fratura e para a estimativa de rugosidade média, observando-se a variação do traço da fratura em relação à feição linear extraída. O trabalho de Antony e Dove (2006) utiliza imagens naturais de formações rochosas e imagens sintéticas para os testes de extração de atributos de fraturas.

Weixing, Haijun e Ying (2007) destacam a extração manual em campo como não confiável na obtenção de características, tediosa e potencialmente perigosa em áreas menos acessíveis, destacando a importância das metodologias de processamento de imagens na detecção de rede de fraturas e suas aberturas. Em sua metodologia de detecção automática, o filtro de mediana é utilizado para a redução de ruídos das imagens. Os autores destacam ainda a dificuldade de segmentação em imagens de corpos rochosos devido ao comportamento de sua superfície, o que estimula as pesquisas na área. É utilizado o algoritmo Canny acompanhado de operações morfológicas de fechamento (dilatação seguida por erosão). Informações dos gradientes na imagem em conjunto com parâmetros que descrevem os segmentos são utilizadas para a classificação de segmentos utilizando Máquinas de Vetores de Suporte (*Support Vector Machine - SVM*) para a identificação de falsos positivos, assim como no trabalho de Lemy e Hadjigeorgiou (2003). Uma diferença adicional ao trabalho anterior é o uso de câmeras digitais em vez de fotos analógicas.

Liu, Jin e Wang (2009) enfatizam no seu trabalho a topologia da rede de fraturas de forma a detectar conexões e nodos. Esta detecção se dá a partir da imagem binarizada e esqueletonizada, onde filtros 3x3 identificam as junções que são pontos de partida para a identificação dos píxels pertencentes a um segmento e à outras junções e terminações. Elementos X , Y e I de topologia de fratura são identificados pelo método proposto.

Wang, Wan e Yang (2010) utiliza uma matriz de Tiansi de coeficientes fracionais diferenciais para quatro direções para a segmentação de vales na imagem. O trabalho seguinte do mesmo grupo (WANG; LI; YU, 2012) estende este trabalho, combinando três algoritmos para classificar a informação obtida pela matriz de Tiansi, de modo a destacar diferentes estruturas na segmentação de bordas e vales. Entretanto, essa implementação apesar de aumentar a detecção das áreas desejadas, também aumentou o ruído, segundo os autores.

Guo et al. (2012) é um dos primeiros nesta revisão a empregar o algoritmo de Steger (baseado na matriz Hessiana de derivadas de segunda ordem) para a detecção de descontinuidades em imagens de afloramentos. Esta abordagem é complementada por uma etapa de ligação entre segmentos próximos, dados ângulos de referência e distância entre eles como requisitos, como nos trabalhos de Lemy e Hadjigeorgiou (2003, 2004); Weixing, Haijun e Ying (2007).

Liu et al. (2013), assim como no trabalho anterior (LIU; JIN; WANG, 2009), dão mais atenção à topologia da rede de fraturas de forma a detectar conexões e nodos. Esta detecção se dá a partir da imagem binarizada e esqueletonizada, onde filtros 3x3 identificam as junções que são pontos de partida para a identificação dos píxels pertencentes a um segmento e à outras junções e terminações. Elementos X , Y e I de topologia de fratura são identificados pelo método proposto.

Wang e Liang (2015) emprega algoritmos baseados na matriz Hessiana como o filtro de Frangi e o algoritmo de Steger para obter linhas centrais (detecção de vales) de fratura. Este processo é complementado pela ligação (*segment linking*) entre os segmentos considerando ângulos e distância entre segmentos. Imagens de rochas fraturadas e de fraturas em concreto foram utilizadas para a avaliação do método. Este trabalho é revisitado em (WANG et al., 2020) trazendo uma otimização na matriz de coeficientes fracionais Tiansi e no algoritmo de Steger.

Wang et al. (2017) focam na identificação das características de fraturas a partir da imagem segmentada, principalmente na esqueletonização e no pós-processamento (eliminação de “rebarbas” e correção de falhas entre segmentos). As características de fraturas observadas são baseadas na análise fractal, no qual são apresentados dois algoritmos: um baseado no *stick-measuring* também utilizado na estimativa de rugosidade de fraturas, mas aqui aplicado para um conjunto de fraturas; e outro baseado em *box-counting* de modo que a imagem é particionada em *patches* (caixas) e os píxels de fratura são contados para a estimativa de dimensão fractal. A topologia também é observada, mas identificada como “análise de pontos”, identificando terminações e cruzamentos entre fraturas.

Prabhakaran et al. (2019) implementa Shearlets para a detecção de linhas centrais (vales) de fraturas. As Shearlets desenvolvida por Labate et al. (2005) são variações de *Wavelets*, que além de serem escaladas e transladadas, também são “torcidas” (*shear*) em várias direções, isso torna as Shearlets naturalmente anisotrópicas (dependente da direção). A análise multidirecional das Shearlets é usada para estimar a distribuição de orientação das fraturas, enquanto a detecção de bordas e vales é inspirada pela técnica de congruência de fase. Complementam a metodologia de Prabhakaran et al. (2019), a segmentação por limiarização (Otsu), esqueletonização, *polyline fitting* (vetorização) e simplificação de polilinhas. Nesse trabalho, Prabhakaran et al. (2019) considera o alto fraturamento de afloramentos carstificados. A mesma solução proposta é aplicada no trabalho de Weismüller et al. (2020), sendo esse o trabalho mais recente do mesmo grupo de autores, com a diferença que este, além de trazer a intensidade de fraturas e estatísticas de comprimento, traz também a rede topológica.

Basirat, Goshtasbi e Ahmadi (2019) utilizam imagens (fotos digitalizadas) de faces rochosas para a estimativa do índice fractal da rede de fraturas. O fluxo proposto propõe a aquisição perpendicular à face a ser observada, o uso de imagens em escala de cinza e o pré-processamento por equalização de histograma. A detecção de bordas é feita a partir de algoritmo Canny e a identificação de traços de fratura é feita por transformada Hough. Complementarmente, operações morfológicas de imagem como *opening/closing* são aplicadas para a eliminação de ruídos e conexão de objetos próximos. A estimativa da dimensão fractal é feita subdividindo a imagem em vários níveis, em árvore como na subdivisão por *quad-tree* mas utilizando 9 divisões/caixas por nível. As fraturas são identificadas pela quantidade de caixas utilizadas para descrever o objeto e a estimativa do índice fractal é feita a partir da inclinação encontrada utilizando um gráfico log-log.

Santoso, He e Hoteit (2019) é um dos primeiros a considerar CNNs *deep learning* para a

segmentação de fraturas em rochas, apesar da técnica ser utilizada por trabalhos que foram considerados como fora de escopo por empregarem outros tipos de imagens e materiais (imagens de microscópio eletrônico) (TIAN; DAIGLE, 2018). Este trabalho implementa uma rede U-net para a segmentação de fraturas. A estrutura apresentada utiliza *image splitting* de modo a alimentar a rede com imagens 64x64 e acelerar o processo de segmentação. O pós-processamento inclui a dilatação e a esqueletonização para obter os delineamentos de fratura de modo que são identificadas as intersecções *XY*, além da recomposição da imagem a partir das imagens menores preditas.

Zeng et al. (2020) utiliza transformadas Beamlets para a extração de linhas e curvas em imagens de fratura. As Beamlets são compostas por dicionários multiescala de elementos binarizados de linhas e curvas e as transformadas são realizadas aplicando este dicionário em porções (*patches*) da imagem seccionada. Após a segmentação de traços de fratura, a conexão de segmentos também é realizada. Estatísticas de fraturas observadas incluem a densidade de fraturas e o comprimento médio.

Leng et al. (2021) utiliza o algoritmo de segmentação de borda Canny como o principal método de detecção de fraturas, mas aplica operações de pós-processamento para eliminar as possíveis linhas duplas em volta de uma abertura e para separar delineamentos de fratura que não seguem uma mesma direção. A eliminação de linhas duplas utiliza um crescimento iterativo em direção à área de gradiente, fazendo com que as linhas duplas se anulem e mantenham a linha central. A conexão de linhas é semelhante ao já apresentado *segment linking* utilizando o ângulo entre linhas como base.

No trabalho de Byun et al. (2021) foram utilizadas 91 imagens capturadas levando em conta a posição solar na detecção das fraturas e considerando somente feições lineares com visíveis aberturas nas rochas para a criação do *ground truth*. Este conjunto de imagens é então utilizado para a avaliação de várias modificações à rede de segmentação semântica U-net com o uso de convoluções Atrous, convoluções *Depthwise Separable* e diversas configurações de *skip connections*. O pré-processamento das imagens se dá por equalização de histograma adaptativo (CLAHE). A saída da melhor arquitetura de rede obtida ainda é combinada com a aplicação da técnica CRF (*fully connected conditional random field*).

Ainda utilizando *deep learning*, Chen et al. (2021) utilizam 600 imagens de faces rochosas de cavernas/tuneis que por *data augmentation* geram um *dataset* de 3000 imagens. Este trabalho cria a ferramenta FraSegNet, que integra um modelo *deep-learning* baseado no VGG16 e VGG19 como *encoding* (a fase *decoding* é baseada em *skip connections* redimensionadas para a resolução final) e adicional modificação incorporando convoluções Atrous. Além da segmentação o FraSegNet, estima a rede de fraturas a partir da esqueletonização e correção do mapa topológico da imagem (mosaico) composta de *patches* preditos pela rede. Estatísticas de fraturas incluem a identificação de nodos, distribuição de comprimentos, direção, intensidade e densidade de fraturas.

Em trabalho desenvolvido pelo proponente desta tese (MARQUES et al., 2021), foram ava-

liadas a aplicação de redes de segmentação *encoder-decoder* como a U-net e a Segnet. São utilizadas 100 imagens/*patches* para validação e treinamento e 20 imagens para teste, geradas a partir da anotação de ortofotos de afloramentos da formação Jandaíra, pertencente à bacia Potiguar, no nordeste brasileiro. Trabalhos futuros desta abordagem irão avaliar diferentes abordagens de redes U-net que são estado da arte para a segmentação semântica, além de ampliar a caracterização da rede de fraturas e estatísticas extraídas (ver Capítulo 4).

Em outro trabalho de segmentação semântica *deep learning*, Hu (2021) utiliza 60 imagens para treino e 15 imagens, com padrões de descontinuidade diversos, para a validação de uma rede de segmentação U-net para a segmentação de fraturas. O trabalho de Hu (2021) ainda emprega *machine learning* para a geração da *mesh* de modelagem numérica para a estimativa de *stress* mecânico.

Ainda utilizando um método mais tradicional de visão computacional, Pi et al. (2021) utiliza a estimativa de gradiente baseado na composição RGB para extrair bordas como fraturas em imagens. Processos posteriores de redução de ruído e binarização são aplicados para a posterior estimativa das dimensões fractais da rede de fraturas e distribuições de comprimento e curvatura.

3.3 Síntese qualitativa

Observados os 28 artigos selecionados (Tabela 1) após a leitura completa dos textos, foram observados os principais pontos de preocupação ou destaques entre os artigos selecionados. Estes pontos incluem a metodologia empregada, métodos de aquisição de imagem, tipos de métricas utilizadas para avaliar a segmentação, estatísticas de fraturas extraídas das imagens e principais destaques, apresentados a seguir.

3.3.1 Tipos de imagem e métodos de aquisição

Os tipos de imagem dos trabalhos selecionados foram limitados à imagens digitais RGB e em escala de cinza. A diferença entre os trabalhos nesse sentido se limita ao tipo de aquisição e origem das imagens, ao passo que algumas observações e restrições são feitas quanto à uma aquisição com mais qualidade ou de maneira a destacar as características desejadas.

Os tipos de aquisição de imagens incluem a aquisição por imageamento aéreo aliado à sensores termais (BARDUCCI; MECOCCI; PAPERINI, 2002), por câmeras profissionais e semiprofissionais analógicas (LEMY; HADJIGEORGIOU, 2003, 2004) e digitais (ANTONY; DOVE, 2006; WEIXING; HAIJUN; YING, 2007; LIU et al., 2013; WANG; LIANG, 2015; WANG et al., 2017; BASIRAT; GOSHTASBI; AHMADI, 2019; ZENG et al., 2020; WANG et al., 2020; BYUN et al., 2021; CHEN et al., 2021; PI et al., 2021; HU, 2021; LENG et al., 2021) para a aquisição de afloramentos verticais ou subverticais, e fotogrametria digital aérea UAV-SfM (THIELE et al., 2017; PRABHAKARAN et al., 2019; SANTOSO; HE; HOTEIT,

2019; WEISMÜLLER et al., 2020; MARQUES et al., 2021).

Quanto à posição de tomada é recomendada a posição perpendicular à face rochosa (LEMY; HADJIGEORGIOU, 2003, 2004; BASIRAT; GOSHTASBI; AHMADI, 2019; LIU et al., 2013; GUO et al., 2012). Os trabalhos de Lemy e Hadjigeorgiou (2003) e Lemy e Hadjigeorgiou (2004) fazem algumas considerações quanto à influência da posição da iluminação em relação ao corpo rochoso, onde a iluminação oblíqua é a mais indicada para a identificação das bordas, utilizando o algoritmo Canny (CANNY, 1986), e com a iluminação direta sendo melhor indicada para a identificação de vales (ou linhas centrais) utilizando o algoritmo de Steger (STEGGER, 1998). Uma análise inicial conduzida por estes trabalhos também destaca as mudanças em resultado dada as direções onde a iluminação é aplicada. Essas peculiaridades quanto à posição do imageamento e posição da iluminação são atacados nesta pesquisa. Ainda, o trabalho de Weismüller et al. (2020) destaca as condições climáticas ideais para a aquisição de imagens para a detecção de fraturas. Eles recomendam a aquisição de imagens em dias de bastante luz solar e céu limpo para favorecer a presença de sombras no imageamento, requisito para a detecção de fraturas por algoritmos de visão computacional.

3.3.2 Metodologias de detecção e segmentação de fraturas

Os trabalhos observados nessa revisão têm, em geral, propostas de metodologia que podem ser divididas em três grandes tarefas, sendo a primeira, o pré-processamento, a segunda, a própria segmentação e a última, o pós-processamento.

3.3.2.1 Pré-processamento

O pré-processamento na grande maioria dos trabalhos envolve: a transformação de imagens coloridas em tons de cinza; a aplicação de filtros de suavização de imagem como os filtros Gaussianos e de média (LEMY; HADJIGEORGIOU, 2003, 2004; ANTONY; DOVE, 2006; WEIXING; HAIJUN; YING, 2007); e a correção de contraste por equalização de histograma (LEMY; HADJIGEORGIOU, 2003, 2004; LIU; JIN; WANG, 2009; BASIRAT; GOSHTASBI; AHMADI, 2019) e por equalização de histograma adaptativo (CLAHE) (ZENG et al., 2020; BYUN et al., 2021). Os trabalhos que empregam CNN *deep learning* ainda complementam essa etapa com a geração de *patches* ou recortes da imagem original, de forma a terem a resolução adequada à entrada da arquitetura construída (SANTOSO; HE; HOTEIT, 2019). Adicionalmente, é conduzido o processo de *data augmentation* (CHEN et al., 2021).

3.3.2.2 Segmentação e detecção de fraturas

A segmentação de fraturas se dá por várias técnicas e abordagens como por detecção de bordas e vales, limiarização ou binarização, decomposição Fourier, Wavelets, Beamlets e con-

gruência de fase e *deep learning* por detecção de objetos e de segmentação semântica.

Trabalhos que usaram a detecção de bordas e vales como técnica principal empregaram técnicas baseadas nos gradientes da imagem e derivações de primeira e segunda ordem. Essas técnicas incluem o uso de filtros detectores de borda e vales como Canny (LEMY; HADJIGEORGIOU, 2003, 2004; WEIXING; HAIJUN; YING, 2007; BASIRAT; GOSHTASBI; AHMADI, 2019; LENG et al., 2021), filtros baseados na matriz Hessiana de derivadas de segunda ordem como o algoritmo de Steger (LEMY; HADJIGEORGIOU, 2003, 2004; WANG; LIANG, 2015; WANG et al., 2020), filtros de Frangi (WANG; LIANG, 2015) e filtros Tiansi e derivados (WANG, 2005; WANG; HAKAMI, 2005; WANG; WAN; YANG, 2010; WANG et al., 2020).

Trabalhos que detectaram fraturas por análise de sinal na imagem (PRABHAKARAN et al., 2019; WEISMÜLLER et al., 2020) utilizaram técnicas semelhantes às de transformadas Wavelet denominadas Shearlets, que são Wavelets bidimensionais distorcidas (ou achatadas) em direções diagonais. Ainda utilizando as Wavelets como comparação, outros trabalhos aplicaram decomposição multiescala para a posterior aplicação de filtros (WANG, 2005; WANG; HAKAMI, 2005) e dicionários Beamlet (ZENG et al., 2020).

Uma boa parcela dos trabalhos (BARDUCCI; MECOCCI; PAPERINI, 2002; ANTONY; DOVE, 2006; LIU; JIN; WANG, 2009; LIU et al., 2013; WANG et al., 2017; PRABHAKARAN et al., 2019) utilizou alguma forma de binarização geralmente seguida de alguma técnica para a extração das linhas de fraturas. Sendo que a técnica de binarização é baseada em um limiar global definido manualmente ou pelo algoritmo Otsu. Lemy e Hadjigeorgiou (2003) enfatizam a necessidade de se remover ruídos após a aplicação da binarização e a inconveniência de se estimar um limiar para cada imagem quando se criar uma ferramenta de mapeamento automático, pontos atacados na presente pesquisa.

Trabalhos que utilizaram *deep learning* (SANTOSO; HE; HOTEIT, 2019; BYUN et al., 2021; MARQUES et al., 2021; HU, 2021) focaram na aplicação ou criação de redes CNN de segmentação semântica baseadas em *encoding* e *decoding* como as U-nets. Assim como na binarização, um processo posterior de detecção de linhas de fratura é necessário. Diferentes tipos de imagens de afloramentos horizontais e faces rochosas são empregados para treinamentos destas redes *deep-learning*, entretanto os modelos treinados e imagens utilizadas não estão ao todo disponíveis.

3.3.2.3 Pós-processamento

O pós-processamento nos trabalhos apresentados pode ser separado em processos de detecção de linhas e de melhoramento ou filtragem do dado (ligação de segmentos e eliminação de ruídos).

Os métodos de detecção de linha se aplicam à imagens previamente segmentadas por algum método que naturalmente não fornece esse tipo de dado, como a segmentação por binarização e por *deep learning*. A detecção de linhas também pode acompanhar os métodos de detecção

de bordas e vales por Canny e Steger, respectivamente, com o objetivo de vetorizar o dado e facilitar a extração das estatísticas de fratura.

Esses métodos incluem a esqueletonização para a identificação dos perfis centrais, geralmente conduzida por algoritmos de transformada do eixo medial (WANG et al., 2017; LIU et al., 2013), por afinamento (PRABHAKARAN et al., 2019; WANG et al., 2017; ANTONY; DOVE, 2006), ou por método próprio ou não especificado (CHEN et al., 2021; LIU; JIN; WANG, 2009; SANTOSO; HE; HOTEIT, 2019; WEISMÜLLER et al., 2020).

A esqueletonização, independente da técnica utilizada pode gerar elementos espúrios como galhos ou terminações que não representam a topologia do objeto esqueletizado. Para atacar essa questão, alguns trabalhos também realizaram a remoção de galhos ou poda (*prunning*) como no trabalho de Liu et al. (2013). A estratégia em Liu et al. (2013) é remover galhos menores que a abertura das fraturas.

O processo de esqueletonização e remoção de galhos espúrios é geralmente seguido pela vetorização ou identificação das polilinhas, que é a identificação os traços em termos de terminações e conexões que identificam as redes de fraturas. Esta tarefa é descrita nos trabalhos de Liu, Jin e Wang (2009); Liu et al. (2013); Santoso, He e Hoteit (2019); Chen et al. (2021); Leng et al. (2021), onde a estratégia mais comum é convolucionar uma janela de observação pela imagem e observar a disposição dos píxeis identificando terminações e junções.

Alternativas de obtenção das linhas ou segmentos de fratura são incorporadas nos próprios algoritmos de segmentação e detecção de bordas e vales como no algoritmo de Steger (LEMY; HADJIGEORGIOU, 2003, 2004; GUO et al., 2012; WANG; LIANG, 2015). Ainda, os traços de fraturas podem ser vetorizados pela transformada Hough, processo geralmente realizado após a detecção de bordas com o algoritmo de Canny (BASIRAT; GOSHTASBI; AHMADI, 2019) ou após a binarização de traços (BARDUCCI; MECOCCI; PAPERINI, 2002). Por outro lado, Weixing, Haijun e Ying (2007) utilizam uma estratégia baseada na descrição de objetos ou fotometria para descrever elementos curvos ou retas nas imagens, estratégia explorada em maior amplitude pelos trabalhos de Prabhakaran et al. (2019); Weismüller et al. (2020); Leng et al. (2021) ao aplicarem o ajustamento de curvas e polilinhas (*polyline fitting*) utilizando o algoritmo de Douglas e Peucker (1973).

A última das etapas de pós processamento dos segmentos é a ligação de segmentos ou *segment linking*. Esta tarefa tem o objetivo de conectar segmentos ou linhas que deveriam ser contíguos por representarem uma única falha ou fratura, de modo que a posterior descrição dos comprimentos seja mais fiel à observação do especialista. A ligação dos segmentos, conduzida nos trabalhos de Lemy e Hadjigeorgiou (2003, 2004); Guo et al. (2012); Wang e Liang (2015); Leng et al. (2021), parte da identificação das terminações dos segmentos como pontos de busca de outras terminações de segmentos que estão à uma distância máxima predefinida. Os segmentos candidatos são avaliados quanto ao ângulo em comparação ao segmento base e ao ângulo do possível novo segmento de ligação.

3.3.3 Métricas e avaliações empregadas

Os trabalhos observados, em sua maioria, não fazem avaliações quantitativas sobre a segmentação ou detecção de fraturas obtidas, relegando a avaliação da qualidade dos produtos gerados à observação visual. Os trabalhos que fizeram avaliação das imagens obtidas em relação a um *ground truth* anotado utilizaram as métricas de: SNR (Signal Noise Ratio) (WANG; WAN; YANG, 2010), Intersection over Union (BYUN et al., 2021; MARQUES et al., 2021; HU, 2021), métrica F1 (MARQUES et al., 2021), e Precisão/Recall, NPV (Negative Predictive Value) e Especificidade (BYUN et al., 2021).

3.3.4 Estatísticas de fraturas

Quanto as estatísticas de fratura obtidas os trabalhos extraíram estatísticas de orientação, estatísticas de comprimento (LEMY; HADJIGEORGIOU, 2003, 2004; ANTONY; DOVE, 2006; LIU et al., 2013; PRABHAKARAN et al., 2019; ZENG et al., 2020; WEISMÜLLER et al., 2020; CHEN et al., 2021; LENG et al., 2021) e abertura (ANTONY; DOVE, 2006; LENG et al., 2021) utilizando histogramas ou estimando a distribuição do conjunto, estimativas de rugosidade (ANTONY; DOVE, 2006), intensidade (PRABHAKARAN et al., 2019; ZENG et al., 2020; WEISMÜLLER et al., 2020; CHEN et al., 2021), densidade (LENG et al., 2021), espaçamento (LEMY; HADJIGEORGIOU, 2003, 2004; ZENG et al., 2020) e topologia (WEISMÜLLER et al., 2020; CHEN et al., 2021), estimativa de dimensão fractal por contagem de caixa e por estatísticas de tamanho dos segmentos (WANG et al., 2017; BASIRAT; GOSHTASBI; AHMADI, 2019; PI et al., 2021), RQD (Rock Quality Index) (LEMY; HADJIGEORGIOU, 2003, 2004) e por fim, a estimativa de *stress* na malha de elementos finitos (HU, 2021).

3.4 Síntese quantitativa

Esta seção fornece uma visão geral dos artigos selecionados para esta revisão. A análise inclui um resumo temporal e espacial das principais características e tecnologias consideradas nos artigos.

3.4.1 Aquisição de imagens e tipos de dados de entrada

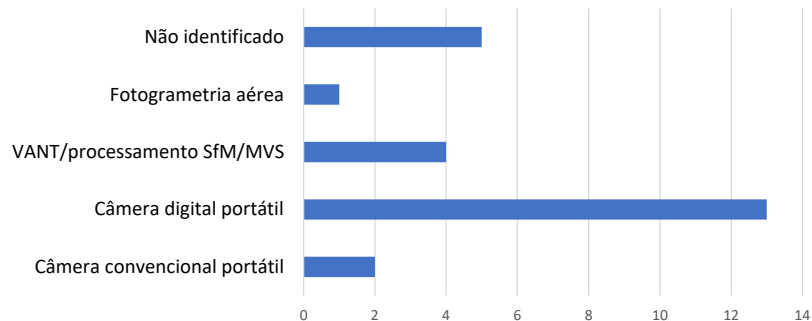
Nos 26 artigos selecionados há a predominância de métodos de aquisição que se utilizam de câmeras digitais portáteis, com 13 artigos utilizando este recurso, enquanto 2 artigos utilizaram câmeras analógicas convencionais (rolo de filme). Outros trabalhos utilizaram imagens de satélite (1 trabalho), ortofotos adquiridas por fotogrametria digital SfM/MVS (4 trabalhos) e 1 trabalho utilizou fotogrametria aérea tradicional (criação de ortomosaicos). Em 6 trabalhos não foi possível identificar a procedência das imagens como destacado no gráfico da Figura 21.

Tabela 2: Métodos de detecção e caracterização da rede de fratura encontrados nos trabalhos selecionados.

Autor	Pré-processamento	Algoritmo de segmentação	Deteção de linhas	Pós-processamento
(BARDUCCI; ME-COCCI; PAPERINI, 2002)	Clasificação de áreas de interesse	Binarização global	Hough transform	-
(LEMY; HADJIGEORGIOU, 2003)	Equalização de histograma / filtro de mediana	Canny / Steger	-	Segment linking / classificação de segmentos por ANN / manual
(LEMY; HADJIGEORGIOU, 2004)	Equalização de histograma / filtro de mediana	Canny / Steger	-	Segment linking / classificação de segmentos por ANN / Correção manual
(WANG; HAKAMI, 2005)	Separação multiescala / Piramide	Template/Filtro de deteção de vales	-	-
(WANG, 2005)	Separação multiescala / Piramide	Template/Filtro de deteção de vales	-	-
(ANTONY; DOVE, 2006)	Filtro de mediana	Binarização global	esqueletonização	Correção manual
(WEIXING; HAIJUN; YING, 2007)	Filtro de mediana	Canny	-	Classificação de segmentos por SVM
(LIU; JIN; WANG, 2009)	Equalização de histograma / filtro não especificado	Binarização global	esqueletonização / Deteção de nodos	-
(WANG; WAN; YANG, 2010)	-	Template/Filtro de deteção de vales de Tiansi	-	-
(GUO et al., 2012)	Escala de cinza	Steger	-	Segment linking/Correção manual
(LIU et al., 2013)	-	Binarização global	esqueletonização / Deteção de nodos	Prunning
(WANG; LIANG, 2015)	-	Steger/Frangi Filter	-	Segment linking
(WANG et al., 2017)	-	Binarização global	esqueletonização	-
(PRABHAKARAN et al., 2019)	-	Shearlet / binarização global	esqueletonização / Polyline fitting	-
(SANTOSO; HE; HOTEIT, 2019)	Image splitting	U-net	esqueletonização / Deteção de nodos	-
(BASIRAT; GOSH-TASBI; AHMADI, 2019)	Equalização de histograma / filtro não especificado	Canny	Hough transform	-
(ZENG et al., 2020)	CLAHE / Bilinear resampling	Beamlet dictionary/Binarização	-	-
(WANG et al., 2020)	Gaussian filter	Filtro de deteção de vales/Steger	-	-
(WEISMÜLLER et al., 2020)	-	Shearlet / binarização global	esqueletonização / Polyline fitting	Simplificação de curvas
(BYUN et al., 2021)	CLAHE	U-net	-	CRF
(CHEN et al., 2021)	Não especificado / Data augmentation	Custom encoding/decoding /method	esqueletonização / Deteção de nodos	-
(MARQUES et al., 2021)	-	U-net/Segnet	-	-
(PI et al., 2021)	-	Color gradient filter	-	Binarização/Noise reduction
(HU, 2021)	-	U-net	-	Mesh generation
(LENG et al., 2021)	-	Canny	-	Eliminação de segmentos duplos / Segment linking / Polyline fitting

Fonte: Elaborado pelo autor.

Figura 21: Métodos de aquisição de imagem nos trabalhos relacionados.



Fonte: Elaborado pelo autor.

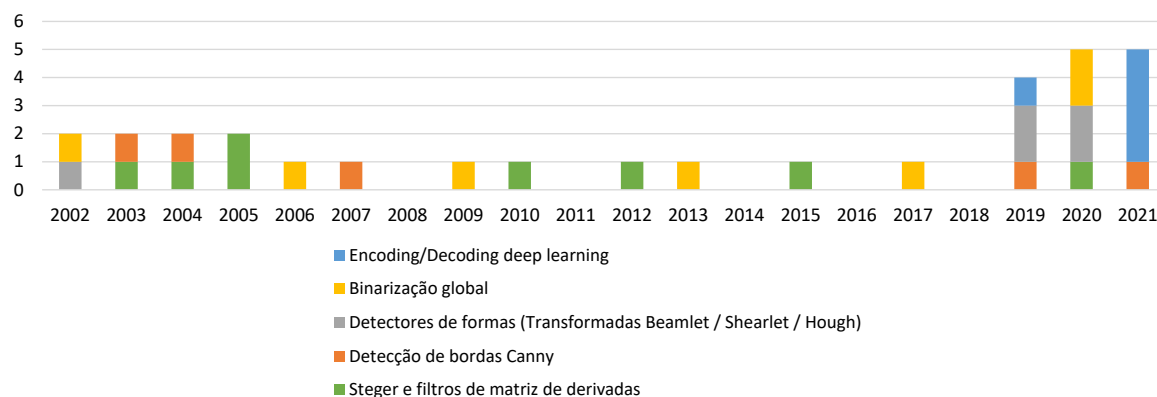
O número elevado de trabalhos que utilizaram câmeras portáteis se dá pela grande maioria de trabalhos que tem foco na detecção de fraturas em faces verticais e faces de cavernas.

3.4.2 Artigos organizados por técnicas de segmentação

Quanto às técnicas de segmentação e detecção de fraturas, há um grande equilíbrio entre as técnicas, principalmente entre as técnicas de detecção de fraturas por filtros de matriz de derivadas como o algoritmo de Steger (7 trabalhos) (LEMY; HADJIGEORGIOU, 2003, 2004; WANG, 2005; WANG; HAKAMI, 2005; WANG; WAN; YANG, 2010; GUO et al., 2012; WANG; LIANG, 2015; WANG et al., 2020) e as técnicas de binarização global (8 trabalhos) (BARDUCCI; MECOCCI; PAPERINI, 2002; ANTONY; DOVE, 2006; LIU; JIN; WANG, 2009; LIU et al., 2013; WANG et al., 2017; PRABHAKARAN et al., 2019; ZENG et al., 2020; WEISMÜLLER et al., 2020). As outras técnicas empregadas se dividem em: técnicas de detecção de bordas pelo algoritmo de Canny (5 trabalhos) (LEMY; HADJIGEORGIOU, 2003, 2004; WEIXING; HAIJUN; YING, 2007; BASIRAT; GOSHTASBI; AHMADI, 2019; LENG et al., 2021); técnicas de aprendizado de máquinas *deep learning encoding/decoding* de segmentação semântica (5 trabalhos) (HU, 2021; SANTOSO; HE; HOTEIT, 2019; BYUN et al., 2021; MARQUES et al., 2021; CHEN et al., 2021); e técnicas baseadas em transformadas Beamlet, Hough e Shearlets (5 trabalhos) (PRABHAKARAN et al., 2019; BARDUCCI; MECOCCI; PAPERINI, 2002; WEISMÜLLER et al., 2020; ZENG et al., 2020; BASIRAT; GOSHTASBI; AHMADI, 2019).

É possível identificar na Figura 22, que há uma tendência de crescimento no número de artigos publicados a partir de 2019. Ainda, vale mencionar a grande quantidade de artigos empregando técnicas de segmentação semântica por *encoding/decoding* no período. Um detalhamento maior das técnicas encontradas pode ser visualizado na Tabela 2.

Figura 22: Métodos de segmentação e detecção de fraturas encontrados nos trabalhos relacionados.



Fonte: Elaborado pelo autor.

3.4.3 Áreas de estudo e geologia

As áreas de estudo dos trabalhos selecionados são em sua maioria faces verticais de afloramentos, cavernas ou minas (14 trabalhos) (LEMY; HADJIGEORGIOU, 2003, 2004; WANG, 2005; WANG; HAKAMI, 2005; ANTONY; DOVE, 2006; WEIXING; HAIJUN; YING, 2007; GUO et al., 2012; WANG et al., 2017; SANTOSO; HE; HOTEIT, 2019; BASIRAT; GOSH-TASBI; AHMADI, 2019; ZENG et al., 2020; BYUN et al., 2021; CHEN et al., 2021; LENG et al., 2021), contra 6 que usam afloramentos horizontais (BARDUCCI; MECOCCI; PAPE-RINI, 2002; LIU et al., 2013; WANG; LIANG, 2015; WEISMÜLLER et al., 2020; MARQUES et al., 2021; PI et al., 2021) e 2 que usam tanto áreas verticais quanto áreas horizontais (PRABHAKARAN et al., 2019; WANG et al., 2020). Entretanto, as informações geológicas de gênese, bacias e formações onde os estudos estão inseridos e informações de tipos de rocha (litologia) não estão presente em 16 trabalhos. Dos trabalhos que apresentaram informações litológicas das áreas de estudo, 7 detectaram fraturas em áreas de rochas carbonáticas (calcários, dolomitas) (LEMY; HADJIGEORGIOU, 2003, 2004; PRABHAKARAN et al., 2019; ZENG; ZHANG; LU, 2016; CHEN et al., 2021; MARQUES et al., 2021), com 4 desses trabalhos citando o processo de carstificação dos afloramentos (MARQUES et al., 2021; CHEN et al., 2021; PRABHAKARAN et al., 2019; ZENG; ZHANG; LU, 2016).

3.5 Considerações

A segmentação e detecção de fraturas é um campo de pesquisa em constante evolução, dado que os desafios inerentes ao comportamento da detecção e segmentação dependem do meio ob-

servado, e não há um consenso quanto a técnica mais adequada. Entretanto foi possível observar quatro vertentes principais de técnicas de segmentação (QP): a detecção de vales baseados em matrizes de derivadas; a detecção de bordas; a detecção de segmentos e retas por transformadas; a segmentação de regiões de fraturas por binarização e por *deep learning*.

O aperfeiçoamento das técnicas apresentadas (QS) envolve tanto o pré-processamento quanto o pós-processamento, e apresentam grandes diferenças de um trabalho a outro. Porém, é possível observar que as metodologias propostas são consistentes entre trabalhos que apresentam grupos de autores em comum.

A aquisição de imagens (QS) tem utilizado câmeras portáteis e VANTs para o imageamento de afloramentos verticais, entretanto o imageamento de afloramentos horizontais tem crescido recentemente. Isso pode ser decorrente dos avanços tecnológicos, tanto no melhoramento dos sensores quanto no aumento de capacidade computacional, que tem possibilitado o processamento por fotogrametria digital SfM de grandes áreas.

Quanto às estatísticas de fratura extraídas nos trabalhos (QS), é possível observar que há um grande interesse em se extrair uma maior quantidade de informações relacionadas à rede de fraturas, principalmente nos trabalhos mais recentes.

Este cenário leva essa pesquisa ao desenvolvimento de metodologias que procuram obter melhores segmentações em imagens de afloramentos carstificados que sofrem com ruídos e com alta complexidade da rede de fraturas. As técnicas desenvolvidas, apresentadas nos capítulos seguintes focam em técnicas que aprendem ou se adaptam ao complexo contexto. Ainda, uma solução assistida também é apresentada como alternativa às técnicas manuais e automáticas.

4 SEGMENTAÇÃO SEMÂNTICA DE FRATURAS POR *DEEP LEARNING*

Técnicas de aprendizado de máquina para segmentação de imagens, em geral, fazem uso de Redes Neurais Convolucionais (CNNs), que evoluíram das RNAs clássicas. Nesses modelos de rede, os perceptrons são organizados em camadas de filtros de aprendizado que envolvem as entradas da imagem para aprender padrões espaciais. Outros tipos de camada, como camadas *dropout* e *pooling*, complementam esse modelo (SKANSI, 2018). O primeiro uso das CNNs em visão computacional foi detectar e classificar objetos dentro de imagens, evoluindo posteriormente para incorporar a localização de objetos. As CNNs de segmentação semântica diferem dessas implementações anteriores, fornecendo rotulagem para cada pixel dentro de uma imagem, separando classes de objetos ou objetos individuais (instâncias)(SKANSI, 2018). FCN (Rede Totalmente Conectada), Segnets (BADRINARAYANAN; KENDALL; CIPOLLA, 2017) e U-net (RONNEBERGER; FISCHER; BROX, 2015) são modelos populares de arquitetura CNN para segmentação semântica com base em estruturas de codificação/decodificação, que foram aplicadas com sucesso em engenharia civil, medicina/biologia, sensoriamento e transporte (ABDOLLAHI; PRADHAN; ALAMRI, 2020).

O objetivo deste trabalho, publicado em (MARQUES et al., 2021), é avaliar a eficiência dos modelos U-net e Segnet para detecção de fraturas em imagens RGB adquiridas com um VANT em um contexto de fotogrametria digital com algoritmos SfM/MVS. Para tanto, tomamos como caso de estudo um afloramento carbonático cárstico análogo ao reservatório de petróleo do pré-sal brasileiro. Uma ortofoto anotada manualmente obtida a partir de fotogrametria digital serviu como um conjunto de dados de treinamento e validação para os modelos CNN. Métricas usuais de Precisão, Recall, F1 (interseção de dados) e Interseção média sobre União (mIoU) foram aplicadas para avaliar os resultados.

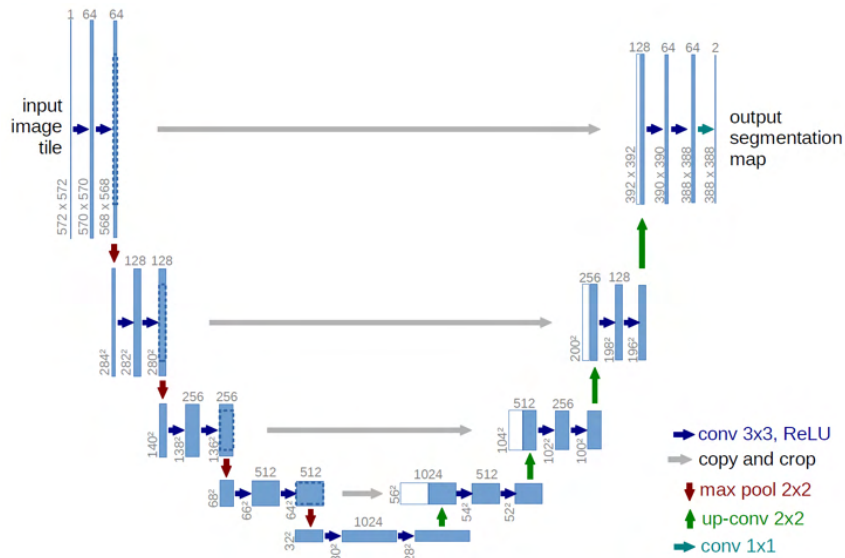
4.1 Redes CNN deep learnin para segmentação semântica

As CNNs para segmentação semântica usam a estratégia de codificação e decodificação, aumentando a profundidade e reduzindo a resolução dos mapas de recursos na primeira parte e, em seguida, revertendo para o tamanho original da imagem na saída.

A U-net (RONNEBERGER; FISCHER; BROX, 2015) CNN é moldada em um formato U de camadas interconectadas, com camadas de codificação injetando dados nas camadas de decodificação, enquanto a Segnet (BADRINARAYANAN; KENDALL; CIPOLLA, 2017) CNN usa uma arquitetura mais linear para codificação e decodificação, como duas CNN espelhadas ligadas entre si. Essas arquiteturas são apresentadas nas Figuras 23 e 24.

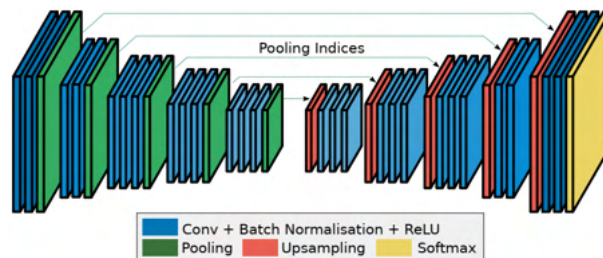
Ambas as CNNs usam a função de ativação da Unidade linear retificada (Relu) para as camadas intermediárias e a Função Sigmóide na camada de saída (SKANSI, 2018). Otimizador de retropropagação Adam e uma função de perda baseada em entropia cruzada binária, usando o mIoU como métrica de erro (PAL; GULLI, 2017).

Figura 23: Arquitetura da rede de segmentação semântica encoding/decoding Unet.



Fonte: Ronneberger, Fischer e Brox (2015).

Figura 24: Arquitetura da rede de segmentação semântica encoding/decoding Segnet.



Fonte: (BADRINARAYANAN; KENDALL; CIPOLLA, 2017)

4.1.1 Avaliação do método proposto e experimento

Para a criação dos conjuntos de treinamento e validação, uma porção de um ortofotomosaico com resolução de 1cm/px obtido a partir do processamento de UAV e SfM/MVS fornecido por (BERTOTTI et al., 2013), foi anotado por interpretação visual e utilizado como verdade. Tanto a imagem anotada quanto a ortofoto original foram cortadas em trechos iguais redimensionados para 384 por 384 pixels nos dando um total de 100 trechos de imagem divididos em conjunto de treinamento e validação na proporção de 80% a 20%, enquanto o conjunto de validação tem um total de 24 imagens.

O ambiente do experimento usa o serviço de nuvem GoogleTM Colab[®] com suporte ao Python 3.7.x. As bibliotecas TensorFlow 2.3, Keras 2.4, scikit-learn 0.22 e scikit-image 0.16 e NumPy 1.18 foram usadas em nossa implementação. As bibliotecas TensorFlow e Keras suportam a aceleração do tensor da placa gráfica com uma NVIDIATM Tesla T4[®] fornecida pelo ambiente de nuvem. A fase de treinamento de cada um dos modelos CNN aplicados considera no máximo 50 épocas.

5 SEGMENTAÇÃO ASSISTIDA POR SUPERPIXELS E ESTRUTURAS DE GRAFO.

Complementar à segmentação automática, a segmentação assistida oferece bons resultados e encontra-se em uma zona intermediária entre os processos manuais e os automáticos. Os Superpíxels são agrupamentos de pixels com propriedades semelhantes em uma imagem, reduzindo desta forma a quantidade de objetos a serem avaliados durante a segmentação assistida, otimizando o tempo de processamento.

5.1 Metodologia proposta

Esta seção apresenta o método *Interactive Forest Growing* (iFG) baseado na conectividade ótima entre superpixels para segmentar rapidamente fraturas de imagens aéreas de afloramentos em metodologia publicada em Marques Junior et al. (2022). Uma imagem de afloramento com cerca de 250 mil pixels é primeiro dividida em cerca de 3 mil superpixels que podem representar parte de uma fratura ou parte do fundo (Ver Figura 30). Tal simplificação na representação da imagem é primordial para fornecer tempo de resposta interativo durante a segmentação. Como uma etapa de pré-processamento automatizado, qualquer algoritmo de segmentação superpixel preciso pode ser usado para esse fim (YIN et al., 2021; QUAN et al., 2021; KORNILOV; SAFONOV; YAKIMCHUK, 2022; VARGAS-MUNOZ et al., 2019). Foi adotado o algoritmo *Iterative Spanning Forest* (ISF)(VARGAS-MUNOZ et al., 2019) na segmentação superpixel das imagens de afloramento. O ISF oferece vários métodos com delineamento preciso de limites com base em múltiplas execuções de um algoritmo Image Foresting Transform (IFT) (Lemes Galvão; FALCÃO; Shankar Chowdhury, 2019; GALVÃO; GUIMARÃES; FALCÃO, 2020; BELEM; GUIMARAES; FALCAO, 2020).

Nos métodos baseados em ISF, as sementes são estimadas e cada superpixel é definido como uma *árvore do caminho ótimo* enraizada em um pixel de semente - ou seja, um conjunto de pixels mais fortemente conectado à sua semente do que a qualquer outro pixel. Neste trabalho, propomos dois algoritmos IFT para segmentação interativa de fraturas em grafos superpixel. Em ambos os casos, as fraturas são definidas como conjuntos de superpixels fortemente conectados aos superpixels de sementes selecionados pelo usuário.

O usuário escolhe uma semente r na imagem por vez e nossos métodos podem definir um componente de fratura na imagem como:

- (i) uma árvore de caminhos ótimos \mathcal{T} com custos de caminho abaixo de um determinado limite T ou como
- (ii) um caminho ótimo de r para um superpixel terminal t definido pela posição atual do mouse sobre a imagem.

O usuário pode definir quantos componentes de fratura forem necessários para completar a segmentação. Em (i), o limite T pode ser configurado interativamente usando uma barra de

rolagem, à medida que o usuário visualiza os componentes do fragmento candidato. Em (ii), conforme o usuário move o mouse sobre a imagem, um componente candidato a fragmento é exibido e seu superpixel terminal t pode ser escolhido depositando o mouse.

O algoritmo 1 é utilizado para os métodos (i) e (ii), respectivamente. Em ambos os algoritmos, um mapa predecessor P é um mapa acíclico que atribui a cada vértice $t \in V$ seu predecessor $P(t) = s \in V$ no caminho atual de r , ou um marcador $P(t) = nil \notin V$, quando $t = r$ (a raiz do mapa). O algoritmo geral IFT é essencialmente o algoritmo de Dijkstra para funções de custo de caminho mais gerais f . Uma fila de prioridade Q é usada para armazenar vértices visitados durante o processo e toda vez que um vértice t é removido de Q , o caminho ótimo $\pi_{r \rightarrow t} = P^*(t)$ pode ser obtido de trás para frente a partir do mapa predecessor P . O componente de fragmento resultante \mathcal{T} no Algoritmo 1 pode ser obtido selecionando superpixels $t \in V$ cujo custo de caminho ótimo $f(P^*(t)) \leq T$ e, no Algoritmo 2, os superpixels em $P^*(t)$ definem o componente de fratura resultante. Um mapa de custo de caminho C pode ser usado para armazenar $f(\pi_{r \rightarrow t}) = C(t)$ para cada vértice visitado $t \in V$.

Algoritmo 1: Finding an optimum-path tree from r with path costs $f(P^*(t)) \leq T$.

Input: Superpixel graph (V, E) , path-cost function f , seed r , and threshold $T \in (0, +\infty)$.

Output: Superpixel set \mathcal{T} representing a fracture component.

Auxiliary: Predecessor map P , path-cost map C , priority queue Q , and variable tmp .

1. For every $t \in V$ do
 2. Set $C(t) \leftarrow +\infty$.
 3. If $t = r$ then
 4. Set $C(t) \leftarrow 0$ and $P(t) \leftarrow nil$.
 5. Insert t in Q .
 6. While $Q \neq \emptyset$ do,
 7. Remove a vertex s from Q such that $s = \operatorname{argmin}_{t \in Q} \{C(t)\}$.
 8. If $C(s) \leq T$ then
 9. Insert s in \mathcal{T} .
 10. For every $(s, t) \in E$ such that $t \in Q$ do
 11. Set $tmp \leftarrow f(P^*(s) \cdot \langle s, t \rangle)$.
 12. If $tmp < C(t)$ then
 13. Set $C(t) \leftarrow tmp$ and $P(t) \leftarrow s$.
 14. Else
 15. Return \mathcal{T} .
-

Pode-se implementar o Algoritmo 1 para diferentes tipos de funções de custo de caminho f sem comprometer sua otimalidade (CIESIELSKI; FALCÃO; MIRANDA, 2018). No entanto, também podemos considerar funções de conectividade baseadas em raiz (FALCÃO; BRAGANTINI, 2019) que não satisfaçam as propriedades em (CIESIELSKI; FALCÃO; MIRANDA, 2018).

Seja $\pi_{t \rightarrow t} = \langle t \rangle$ um caminho trivial e $\pi_{r \rightarrow s} \cdot \langle s, t \rangle$ o caminho que resulta da concatenação de caminho $\pi_{r \rightarrow s}$ e um segmento $\langle s, t \rangle$ – ou seja, aresta $(s, t) \in E$ – com as duas instâncias de junção de s mescladas dentro de um. A linha 11 do Algoritmo 1 usa esta notação para indicar

a extensão de um caminho ótimo $P^*(s)$ com terminal s por uma aresta $(s, t) \in E$. Todas as funções de conectividade devem definir os custos de caminhos triviais como (consulte as Linhas 1-4 no Algoritmo 1)

$$f_*(\langle t \rangle) = \begin{cases} 0 & \text{if } t = r, \\ +\infty & \text{caso contrário.} \end{cases} \quad (5.1)$$

Para o caso de caminhos não triviais, exemplos de funções de conectividade são dados por:

$$f_1(\pi_{r \rightarrow s} \cdot \langle s, t \rangle) = f_1(\pi_{r \rightarrow s}) + d(s, t), \quad (5.2)$$

$$f_2(\pi_{r \rightarrow s} \cdot \langle s, t \rangle) = \max\{f_2(\pi_{r \rightarrow s}), d(s, t)\}, \quad (5.3)$$

$$f_3(\pi_{r \rightarrow s} \cdot \langle s, t \rangle) = \max\{f_3(\pi_{r \rightarrow s}), d(r, t)\}, \quad (5.4)$$

$$(5.5)$$

onde $d(s, t)$ é a distância euclidiana entre as cores médias do CieLab dos superpixels s e t . Observe que $f(P^{ast}(s))$ na Linha 11 é igual a $C(s)$ nas funções acima.

5.1.1 Avaliação do método

Para avaliar a metodologia proposta este trabalho utiliza uma imagem ortofoto do afloramento do Rosário no município de Felipe Guerra no Rio Grande do Norte - Brasil (Figura 30), adquirida a partir de VANT e processamento de fotogrametria.

A ortofoto processada com resolução de 5cm/pixel foi dividida em 193 recortes com resolução igual de 500x500 pixels (cobrindo área de 25m²), onde aplicamos a segmentação em superpixel pelo método ISF para identificar 3000 superpixels em cada recorte. A partir dessas imagens, reservamos 15 recortes arbitrários com vários graus de fraturamento, vegetação e rocha exposta a serem segmentados por três especialistas que identificaram fraturas usando o método iFG e uma abordagem semelhante chamada *interactive Region Growing* (iRG) para referência. Os três especialistas, denominados O1, O2 e O3, possuem diferentes experiências na análise de fraturas. O1 e O3 são consideravelmente mais experientes do que O2.

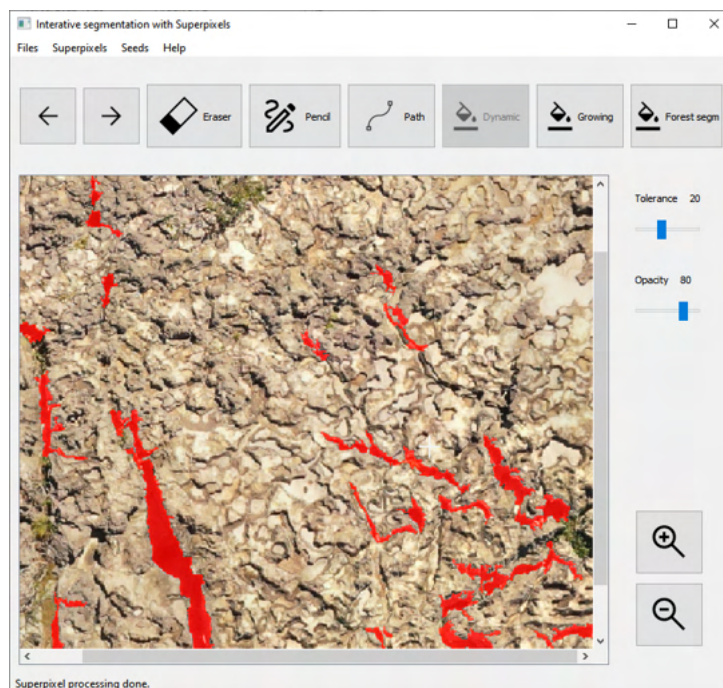
No iRG, o usuário também seleciona sementes de superpixels, um limite de similaridade de cores, e as fraturas são delineadas pelo crescimento de uma região de superpixels conectada a cada semente no gráfico. Assim como o iFG, os superpixels são representados por sua cor média de pixel no espaço de cores CieLAB. Um novo superpixel é incorporado como uma fratura quando a distância entre sua cor média e a cor média da região de crescimento está abaixo do limite determinado. Observe que a cor média da região em crescimento é atualizada para cada novo superpixel.

São observados os tempos de execução e qualidade de segmentação entre operadores e in-

interpretações feitas, bem como a quantidade de interações (clicks) durante a segmentação. Após a comparação das segmentações com a métrica F1, consolidamos a segmentação para cada uma das 15 imagens por votação de pixel, considerando apenas as áreas segmentadas em pelo menos quatro segmentações dado as 6 segmentações (três para cada método).

Em parceria com a Unicamp foi desenvolvida uma aplicação (Figura 25) (Disponível em https://github.com/ademirmarquesjunior/superpixel_segmentation) para segmentação assistida baseada no algoritmo ISF (Iterative Spanning Forest) de VARGAS-MUNOZ et al. (2019).

Figura 25: Ferramenta de segmentação assistida por Superpixels



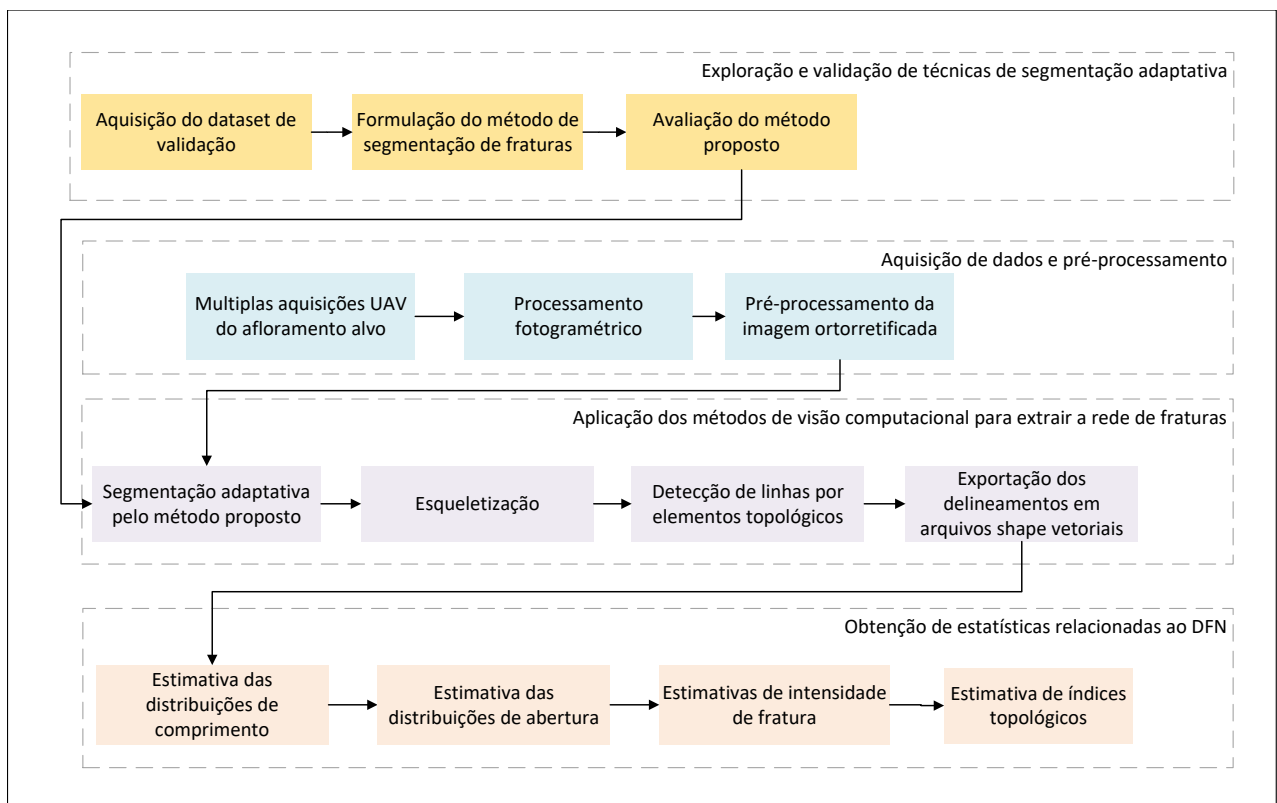
Fonte: Elaborado pelo autor.

Esta aplicação foi utilizada para avaliar o viés de interpretação entre geólogos, de modo a servir como estudo de caso do uso da aplicação e para a criação de um dataset consolidado das anotações.

6 DETECÇÃO DE FRATURAS EM IMAGENS POR SEGMENTAÇÃO ADAPTATIVA

A principal metodologia proposta nesta tese e o fluxo de trabalho para a segmentação adaptativa e caracterização da rede de fraturas são apresentados na Figura 26, fluxo este também apresentado em Marques et al. (2022). O respectivo fluxo, não apresentado até então na literatura, consiste em aquisições por VANT, processamento de fotogrametria, aquisição de dados e validação de métodos de segmentação adaptativa e o uso de um método de *denoising* binário, utilizando métodos de visão computacional e processamento de imagens tradicionais em alternativa à métodos baseados em aprendizado de máquina. Uma vez validado o método de segmentação, foi realizada a caracterização de fraturas e a geração de DFN usando várias aquisições por VANT para analisar o viés na detecção da fratura. Por fim, são combinadas as segmentações de fratura de cada aquisição VANT para caracterizar adequadamente o DFN, avaliando a distribuição ajustada das características das fraturas (abertura, comprimento) e computando os índices de fratura espacial (intensidade e conectividade).


Figura 26: Fluxo de trabalho proposto para: a avaliação da segmentação adaptativa: a aquisição de imagens do afloramento por VANT; e a caracterização da rede de fraturas.



Fonte: Elaborado pelo autor

6.1 Segmentação por limiarização adaptativa

As técnicas de limiarização, também conhecidas como binarização, são técnicas bem conhecidas no reconhecimento de caracteres e segmentação de imagens de Ressonância Magnética

Figura 27: Perfil de limiarização espaço-dependente Q e média local μ em imagens de fundo

Fonte: Burger e Burge (2016).

(RM), sendo métodos de segmentação baseados em regiões que visam separar as imagens em objetos de primeiro plano e segundo plano (SINGH et al., 2012; N; S, 2016; PHANSALKAR et al., 2011; SAUVOLA; PIETIKAK, 2000). A identificação de fraturas tem se beneficiado desses métodos devido a comum representação de fraturas em áreas mais escuras de imagens de rochas e afloramentos (BARDUCCI; MECOCCHI; PAPERINI, 2002; ANTONY; DOVE, 2006; LIU; JIN; WANG, 2009; LIU et al., 2013; WANG et al., 2017; PRABHAKARAN et al., 2019; ZENG et al., 2020; WEISMÜLLER et al., 2020).

Uma imagem binarizada (b) é dada por

$$b(x, y) = \begin{cases} 0, & \text{Se } I(x, y) \leq T \\ 1, & \text{Caso contrário} \end{cases} \quad (6.1)$$

onde (x, y) representa a posição do píxel, $I(x, y)$ é o valor da intensidade da escala de cinza e T é o valor limite determinado por um método escolhido. Para o limiar adaptativo, a estimativa de média e desvio padrão, bem como a estimativa de contraste, são calculadas sobre uma janela móvel que é convolucionada sobre a imagem. A Figura 27 exemplifica a aplicação dessa técnica considerando um perfil de uma dimensão no qual a escolha de um limiar global satisfatório pode ser impossível.

Neste trabalho, a estratégia adotada é a aplicação de limiares adaptativos locais para maximizar a segmentação de fraturas em imagens com alto nível de detalhe ou áreas sombreadas arbitrariamente, como imagens de afloramentos carbonáticos carstificados ou com vegetação rasteira e árvores. Para isso, são avaliadas várias técnicas de limiarização adaptativa usando as propostas por Niblack, Sauvola e Phansalkar que são técnicas comuns para segmentação de imagens biomédicas e reconhecimento de caracteres. Os filtros local gaussiano e global Otsu também são avaliados como comparação. Estas técnicas de limiarização são brevemente descritas a seguir.

A binarização local adaptativa por Niblack (NIBLACK, 1985) $T(x, y)$ é dada por

$$T(x, y) = m(x, y) + k\delta(x, y) \quad (6.2)$$

onde $m(x, y)$ é o valor médio e $\delta(x, y)$ é o desvio padrão de uma janela de valores de píxel sobre uma janela de convolução de tamanho w , enquanto k é um viés valor definido para 0,5.

A binarização local adaptativa por Sauvola (SAUVOLA; PIETIKAK, 2000) é dada por

$$T(x, y) = m(x, y) \left[1 + k \left(\frac{\delta(x, y)}{R} - 1 \right) \right] \quad (6.3)$$

onde R é um valor padrão representando um valor na posição central na escala de cores, normalmente definido como 128, e k é um valor de viés ou *bias* no intervalo de 0,2 a 0,5.

O limiar adaptativo de Phansalkar (PHANSALKAR et al., 2011) atualiza a técnica de Sauvola tentando estimar melhor o limiar em regiões escuras e com baixo contraste adicionando duas novas constantes e uma operação exponencial que adiciona mais impacto à média. Este limiar local é dado por

$$T(x, y) = m(x, y) \left[1 + p \exp^{-qm(x,y)} k \left(\frac{\delta(x, y)}{R} - 1 \right) \right] \quad (6.4)$$

onde a constante p é igual a 3, q é igual a 10, e k é igual a 0.25 seguindo o artigo original.

Para as técnicas de limiarização local adaptativa, o tamanho da janela convolutiva tem tamanho fixo de 91x91 píxels com o objetivo de obter o limiar para uma área grande o suficiente para cobrir a largura das fraturas observadas nessas imagens.

6.1.1 Técnicas de redução de ruídos em dados binários

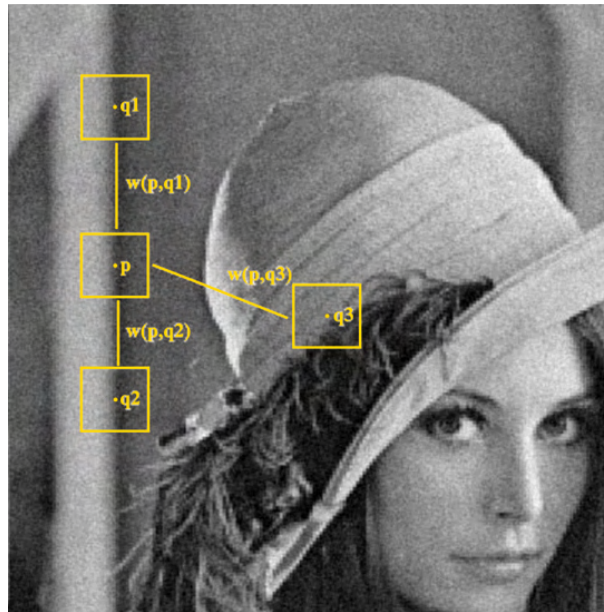
Após a segmentação das imagens de afloramento com os métodos de limiarização adaptativa, é esperado algum ruído relacionado a áreas de fratura detectadas incorretamente ou a outros artefatos. Nesta etapa, são aplicadas técnicas comuns para redução de ruído em imagens binárias onde o algoritmo Non-Local means (NLM) (BUADES; COLL; MOREL, 2004) foi escolhido devido ao seu desempenho e eficiência. O algoritmo NLM é um método de remoção de ruído que utiliza a similaridade dentro do espaço da imagem, inferindo o valor real de um píxel em uma região analisando outras regiões da imagem que possuem distribuição de intensidades semelhante. Sua equação considera a imagem ruidosa como um elemento v , enquanto x é o elemento na imagem que queremos determinar a média, com base em vizinhanças gaussianas semelhantes à vizinhança de x . Em sua forma básica o NLM é dado por

$$NLM(v)(x) = \frac{1}{C(\mathbf{x})} \int \exp^{-\frac{G_\alpha * |v(\mathbf{x}+) - v(\mathbf{y}+)|^2(0)}{h^2}} v(\mathbf{y}) dy \quad (6.5)$$

onde G_α é um kernel gaussiano com desvio padrão α , $C(x)$ é um fator de normalização e h é um parâmetro de filtragem. Em uma imagem discreta $v = \{v(i)|i \in I\}$ o NLM de um elemento i na imagem ruidosa v é dado por

$$NLM(v)(i) = \sum_{j \in I} w(i, j) v(j), \quad (6.6)$$

Figura 28: Exemplo de uso do algoritmo NLM para a estimativa do valor de um pixel p estimando valores de peso w em comparação as regiões dos pixels $q1$, $q2$ e $q3$.



Fonte: Buades, Coll e Morel (2004).

onde os pesos $\{w(i, j)\}_j$ dependem da similaridade de pixels entre as vizinhanças i e j . Na Figura 28 esses elementos são representados como pesos w para a similaridade entre a vizinhança de um pixel p e outros pixels $q1$, $q2$ e $q3$, onde o peso para $q3$ é menor na determinação do valor do pixel p devido à baixa similaridade dessas regiões.

A implementação de NLM utilizada nesse trabalho é baseada no trabalho de (BUADES; COLL; MOREL, 2011), que traz otimizações computacionais para melhorar o desempenho do algoritmo.

6.2 Avaliação do método proposto

Para avaliação do método de segmentação adaptativo proposto são utilizadas imagens ortoretificadas de afloramentos disponíveis em (BERTOTTI; BISDOM, 2013) que foram obtidas a partir de aquisição de VANTs (altura de 60 a 70m) e processamento de fotogrametria SfM gerando produtos com resolução de 1cm/píxel. Uma região desta imagem de afloramento foi anotada manualmente considerando as fraturas e descontinuidades mais proeminentes, segmentadas pixel-à-píxel e delineadas com ferramentas GIS, em um estudo primário realizado pelo Vizlab que teve como objetivo solucionar a falta de conjuntos de dados públicos de fraturas anotadas para comparação adequada entre os trabalhos. As imagens anotadas pixel-a-píxel e delineamentos de fraturas disponíveis no GitHub ¹ são usadas neste trabalho para comparação direta dos delineamentos e validação dos métodos de segmentação.

Para comparação entre as segmentações, é utilizado um conjunto de métricas de avaliação

¹<https://github.com/lucaskup/VizFracSet>

para verificar a proximidade das imagens segmentadas com a imagem segmentada manualmente identificada como *ground truth*. As métricas observadas são a *Structure Similarity Index Measure* (SSIM), a *Mean Intersection over Union* (mIoU), a métrica F1; e a relação sinal-ruído de pico (Peak Signal Noise Ratio - PSNR) descritas a seguir.

A SSIM é dada por (WANG et al., 2004).

$$SSIM_{(x,y)} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (6.7)$$

onde x e y são os valores de píxel em ambas as imagens, μ_x e μ_y são a média de x e y respectivamente, σ_x^2 e σ_y^2 são a variância de x e y respectivamente, σ_{xy} é a covariância de x e y , C_1 e C_2 são os estabilizadores de função dados por $(K_1L)^2$ e $(K_2L)^2$ respectivamente, onde K_1 e K_2 são constantes e L é o intervalo dinâmico da imagem.

O PSNR mede o quão perto duas imagens estão uma da outra, onde valores mais altos indicam maior similaridade. O PSNR é dado por

$$PSNR = 10 \log\left(\frac{C^2}{MSE}\right) \quad (6.8)$$

onde

$$MSE = \frac{\sum_{x=1}^M \sum_{y=1}^N (I(x,y) - I'(x,y))^2}{MN} \quad (6.9)$$

e M e N são as dimensões do tamanho do píxel nos eixos x e y , e I e I' são a primeira e a segunda imagens, respectivamente.

A métrica F1 e a mIoU são baseados nos elementos da matriz de confusão, onde: TP são os verdadeiros positivos, FP são os falsos positivos; TN são os verdadeiros negativos e; FN são os falsos negativos.

A mIoU, também conhecida como índice de similaridade de *Jaccard*, é dada por

$$mIoU = \frac{TP}{TP + FP + FN} / \text{classes}. \quad (6.10)$$

A métrica F1 também conhecida como coeficiente Dice é dada por

$$F1 = \frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (6.11)$$

onde

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (6.12)$$

e

$$\text{Precisão} = \frac{TP}{TP + FP}. \quad (6.13)$$

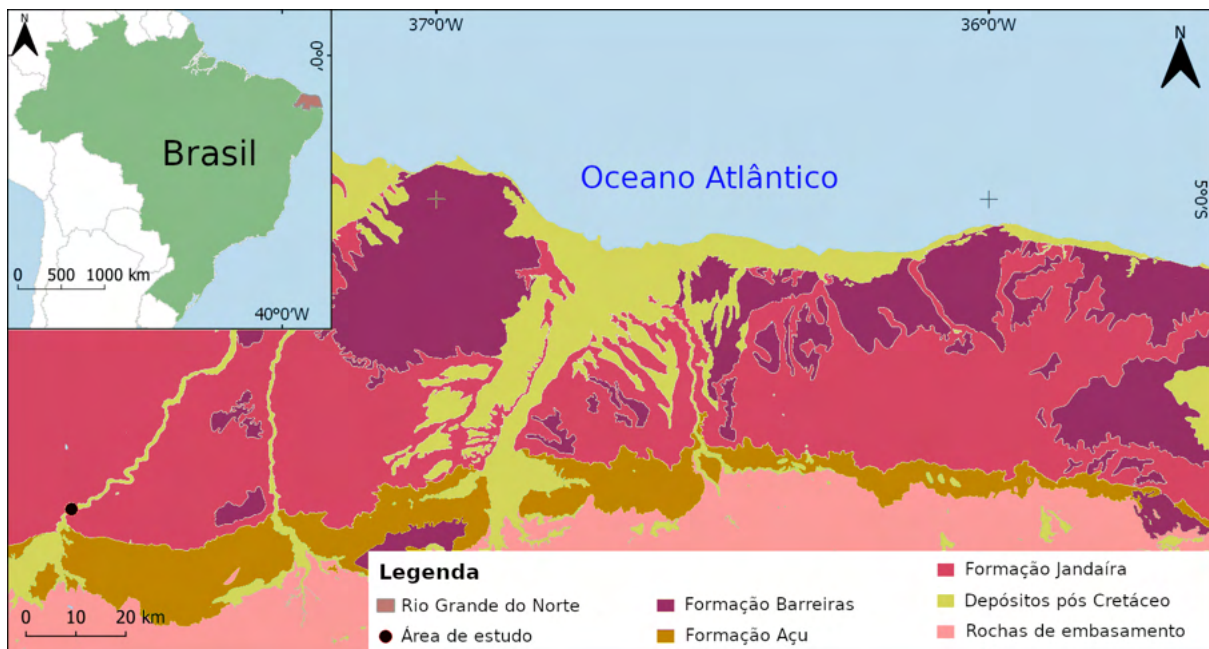
6.3 Estudo de caso da análise do viés de iluminação e geração do modelo DFN

Para analisar um possível viés da aquisição e detecção de fratura, considerando diferentes condições ou tempos de aquisição, são analisados cada produto de segmentação de fratura relacionado a cada voo. Após essa análise, com o objetivo de obter uma representação mais precisa da rede de fraturas das imagens do afloramento essas segmentações são posteriormente combinadas. Isso é feito acumulando as segmentações de fratura após o processo de eliminação de ruídos gerando uma nova imagem binarizada. Esta imagem binarizada seguirá então o processo de esqueletização/detecção de descontinuidade para obter o modelo DFN resultante com estatísticas de comprimento e abertura, e mapa topológico.

6.3.1 Área de estudo

O estudo foi realizado no município de Felipe Guerra no Estado do Rio Grande do Norte, situado na região nordeste do Brasil (Figura 29). A área de interesse consiste em um extenso afloramento, o *Lajedo Rosário*, onde afloram rochas da Formação Jandaíra (Bacia Potiguar) (PESSOA NETO et al., 2007; MEDEIROS; CórDOBA, 2020).

Figura 29: Mapa geológico de litologias da Bacia Potiguar no Rio Grande do Norte, Brasil. Sistema de Referência Geodésico: WGS84.



Fonte: Adaptado de Cassab (2003).

A Formação Jandaíra consiste em uma extensa sucessão de rochas carbonáticas, principalmente calcárias, como *grainstones*, *packstones* e secundariamente argilitos, com graus variáveis de dolomitização (GRAAF et al., 2017; MENEZES et al., 2020). Os estratos apresentam conteúdo bioclástico variável de moluscos bivalves e algas (CASSAB, 2003; GRAAF et al., 2017).

Os sedimentos correspondentes depositados do Turoniano ($\pm 93,9$ a 89 Ma) ao Campaniano ($\pm 83,6$ Ma) (MENEZES, 2002) como sedimentos carbonáticos marinhos em ambientes de águas turbulentas a rasas (TIBANA; TERRA, 1981). Os estratos apresentam um mergulho suave ($2-5^\circ$) para NNE e afloram como platôs NE-SW prolongados em nível regional (MENEZES et al., 2020). Esses bancos carbonáticos ocorrem com espessuras distintas ao longo da bacia, de 30m na região de Upanema e acima de 600m na região de Apodi (PESSOA NETO et al., 2007). As partes basais da formação apresentam uma transição dos sedimentos calcários para os arenitos da Formação Açú subjacente, o que indica uma transgressão marinha na bacia. Assim, a formação Jandaíra relaciona-se ao estágio de *rift* transicional que encerra a fase continental (GOMES et al., 2019).

O afloramento da Formação Jandaíra apresenta extensa deformação por fraturas (RABELO et al., 2020; LOPES; CASTRO; BERTOTTI, 2018; MENEZES et al., 2020). A literatura relata as principais famílias de fraturas nas direções N-S e E-W, com famílias subsidiárias NE-SW e NW-SE, em ambos os casos apresentando mergulho sub-vertical e, por último, um conjunto de fraturas sub-horizontais, estratificação-paralelas (RABELO et al., 2020; LOPES; CASTRO; BERTOTTI, 2018). Veias de calcita e fraturas expostas com direções N-S, NNE-SSW e E-W foram observadas (RABELO et al., 2020), e estilólitos direcionados E-W e WNW-ESE (MENEZES et al., 2020). Essas estruturas relacionam-se a diversos estágios de subsidência e movimento lateral regional relacionados ao contexto da abertura da margem atlântica (MENEZES et al., 2020).

6.3.2 Aquisição de imagens

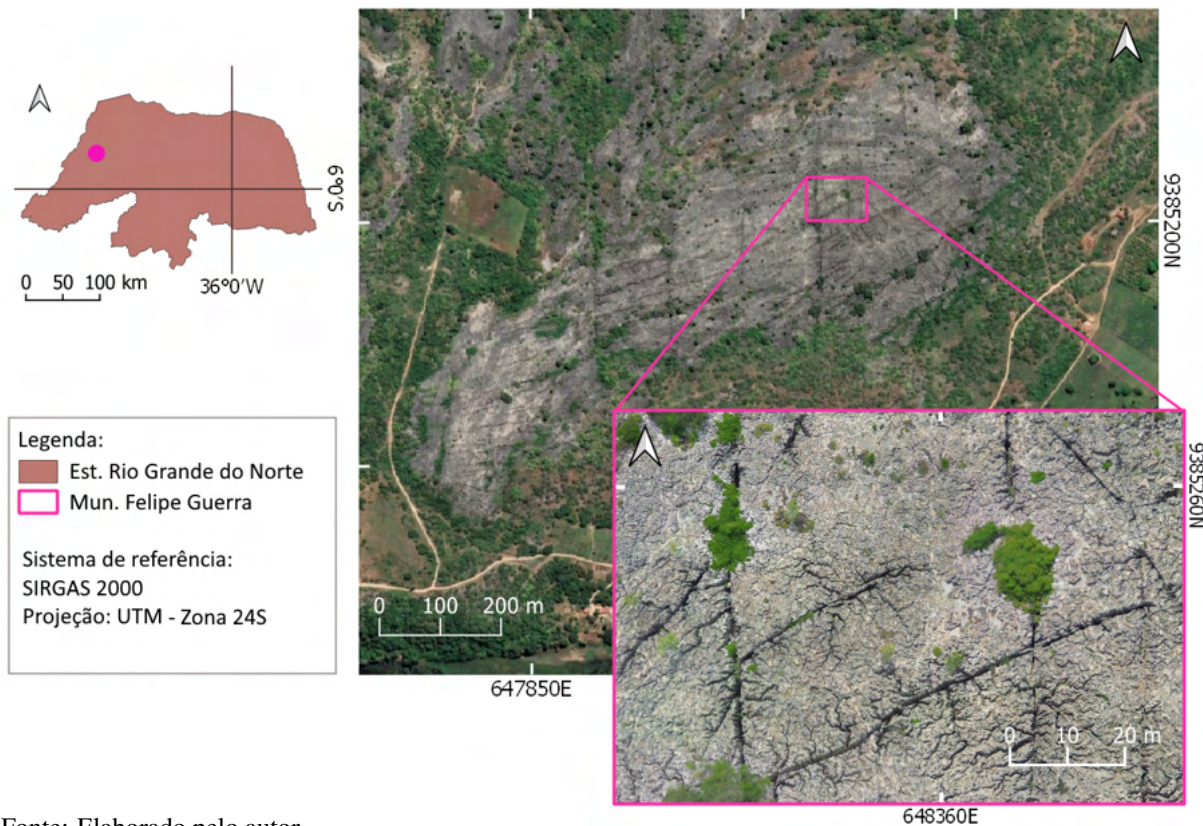
A aquisição de imagens foi realizada utilizando os VANTs DJI Mavic Pro 2 e DJI P4 multi-espectral em vários voos sobre a área de estudo mostrada na Figura 30 para possibilitar a análise do impacto da hora do dia na aquisição e detecção de fraturas usando o método proposto neste trabalho.

O DJI Mavic Pro 2 (Figura 31a) é um VANT com um sensor RGB embutido de pixel efetivo de 20M, tempo máximo de voo de 29 minutos e 907g (2lbs), enquanto o multiespectral DJI P4 (Figura 31b) é um VANT com 6 câmeras embutidas, 1 sensor RGB e 5 sensores monocromáticos capturando cinco comprimentos de onda distintos com 2M de pixels efetivos em cada sensor, pesando 1,47kg (3,2lbs). O DJI P4 também inclui um Sistema Global de Navegação por Satélite (GNSS) cinemático em tempo real (RTK).

A aquisição de imagens do VANT é realizada em três horários diferentes do dia respeitando a sobreposição de 60% a 80% entre as aquisições de imagens. O processamento SfM-MVS é realizado usando o software de fotogrametria Agisoft Metashape versão 1.6 considerando configurações médias de qualidade para alinhamento de fotos e densificação de nuvens.

Os principais produtos utilizados neste trabalho são os dados RGB de imagens ortorretificadas georreferenciadas na região mostrada em detalhe na Figura 30. Esses produtos são alinhados

Figura 30: Localização da área de estudo e detalhe do afloramento fraturado carstificado do Lajedo Rosário.



Fonte: Elaborado pelo autor.

e redimensionados para a mesma resolução usando pontos de controles artificiais para permitir a comparação e integração das imagens. A posição do Sol durante cada voo é registrada usando uma ferramenta online² que calcula a posição do sol dada a data-hora e a posição global.

6.3.3 Esqueletização e obtenção dos perfis centrais das fraturas


Para identificar traços de descontinuidade é preciso extrair a linha central ou esqueleto das áreas fraturadas segmentadas usando um processo chamado esqueletização. O esqueleto de um objeto pode reter sua forma topológica, geométrica ou ambas as formas do objeto original, dependendo da técnica utilizada que é geralmente baseada na transformação de distância, diagrama de Voronoi ou afinamento.

Algoritmos como o desenvolvido por (ZHANG; SUEN, 1984) e (LEE; KASHYAP; CHU, 1994b) são algoritmos tradicionais de esqueletização baseados em afinamento iterativo, removendo iterativamente os píxels ao redor dos objetos até que eles tenham largura máxima de 1 píxel.

O algoritmo de Zhang e Suen (1984) usa o conhecimento prévio da imagem como base à esqueletização. Utilizando um filtro de tamanho 3x3, cada píxel na imagem é avaliado em

²https://www.suearthtools.com/dp/tools/pos_sun.php

Figura 31: VANTs utilizados para imageamento da área de estudo




Fonte: <https://www.dji.com/>

relação à quantidade de elementos conectados a ele. Dependendo da vizinhança os pixels são marcados para remoção ou marcados como não removíveis.

O algoritmo de Lee, Kashyap e Chu (1994a) realiza a esqueletização iterativa sem conhecimento prévio da estrutura da imagem, sendo utilizado também para afinamento de objetos 3D. Em sua implementação são utilizadas, *octrees* para particionamento das área no entorno do voxel (menor elemento no espaço 3D) escolhido e uma tabela de derivação da relação de Euler (relação entre vértices, arestas e faces) é observada para garantir a estrutura do objeto durante o afinamento (ZASIŃSKI; KOCIŃSKI; MATERKA, 2017).

O algoritmo da transformada do eixo medial (*Medial Axis Transform - Mat*) (LEE, 1982; CHOI; CHOI; MOON, 1997), por outro lado é baseado nas transformadas de distância percorrendo o corpo do objeto como um círculo que tem seu diâmetro ajustado para estar sempre em contato com as bordas do objeto (Figura 32).

Figura 32: Transformação do eixo medial usando a distância euclidiana. O tamanho dos círculos indica a medida da distância entre as bordas e o centro do círculo e a linha interna indicam o eixo medial.



Fonte: DeFloriani e Spagnuolo (2008).

A transformada de distância $D(i, j)$ é baseada na distância euclidiana

$$d(k, l) = \sqrt{k^2 + l^2} \quad (6.14)$$

onde k e l são dois pixels quaisquer em uma matriz imagem. Considerando uma imagem binária

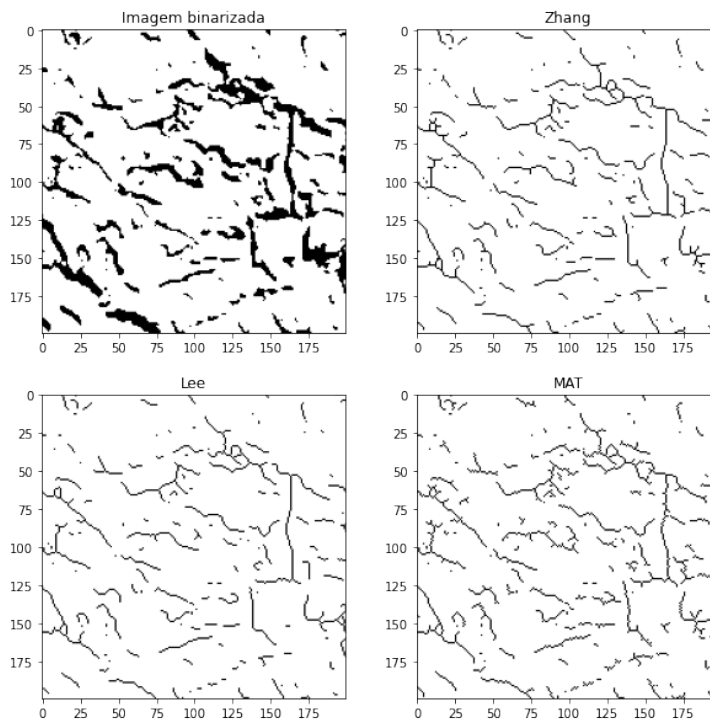
$b(i, j)$ a transformada de distância é dada por

$$D(i, j) = \min_{k, l: b(k, l)=0} d(i - k, j - l) \quad (6.15)$$

que nos dará a informação para cada píxel de objeto (com valor 1) na imagem até o elemento de fundo mais próximo (com valor 0).

Na implementação utilizada, o algoritmo MAT utiliza uma passagem de filtro 3x3 avaliando quantos píxels estão conectados ao píxel central, e dependendo desta avaliação, os píxels são marcados para remoção ou não. Na próxima iteração do algoritmo, os píxels são removidos e a transformação de distância é calculada para cada píxel do centro do objeto até sua borda, onde a distância euclidiana é calculada.

Figura 33: Métodos de esqueletização baseados em afinamento (a,b) e em transformação do eixo medial (c) a partir de imagem binarizada (a).



Fonte: Elaborado pelo autor.

Devido a menor presença de artefatos apresentados pela implementação do algoritmo de Lee (1982) (Figura 33), este é o método preferencial para a obtenção dos perfis de fratura. Entretanto, a transformada de distância euclidiana é combinada a essa esqueletização para obtenção dos dados de abertura de fraturas.

6.3.4 Detecção de linhas e extração de dados topológicos

A detecção de linha para caracterização e estatística de fraturas emprega uma vetorização em várias etapas dos perfis de fratura esqueletizados. O método proposto é brevemente apresentado

no pseudocódigo em Algoritmo 2.

Algoritmo 2: Detecção e vetorização de rede de fraturas a partir de imagem binarizada esqueletizada.


Entrada: Imagem binarizada e esqueletizada B

Saída: Lista de adjacência A , mapa de vértices V .

1. Para cada $i \in B$ faça
2. Capturar vizinhança v de i .
3. Se $v = 2$ então
4. Lista de terminações T recebe posição de i .
4. Se $v \geq 3$ então
5. Lista de nodos J recebe posição de i .
6. Para cada terminação t em T faça
7. $s[t] \leftarrow$ posição de píxels pertencentes aos segmentos (*Algoritmo de crescimento por região*)
8. Para cada nodo j em J faça
9. $s[j] \leftarrow$ posição de píxels pertencentes aos segmentos (*Algoritmo de crescimento por região*)
10. Para cada nodo j em J faça
11. Identificar elementos em s vizinhos a j e adicionar nodo na lista V
12. Para cada terminação t em T faça
13. Adicionar elementos t na lista V e na lista A dado elementos de píxel terminando t ou em j
14. Criar elementos em V e em A para elemento de A que tem elementos de perfil em s mais distante da reta de elementos em A

A passagem do filtro é ilustrada na Figura 34, onde são duas situações comuns ao convolucionar a vizinhança 3x3. Após marcar as regiões de nós e terminações, estas regiões são utilizadas como pontos iniciais para um algoritmo de crescimento de regiões que caminhará junto ao perfil de fratura central.

Figura 34: Detalhe das vizinhanças de píxels indicando um nó de terminação e um nó de conexão usado para detecção de linha sobre os perfis de fratura esqueletizados.



Fonte: Elaborado pelo autor.

A Figura 35 ilustra a execução do Algoritmo 1 demonstrando a execução do algoritmo proposto. Na etapa 1 (Figura 35a) são identificadas terminações e nós após a passagem da janela de observações exemplificada na Figura 34, com essas áreas demarcadas em verde para

terminações, e em azul para nós ou junções.

Na etapa 2 (Figura 35b) é exemplificado a aplicação do algoritmo de crescimento e a direção em que ele caminha para cada terminação e nó. Os pixels já observados são excluídos do conjunto de dados observáveis ao algoritmo de crescimento por região, evitando que um segmento entre dois nós seja vetorizado repetidamente, não executando o algoritmo novamente para um segundo nó ou terminação de um mesmo delineamento.

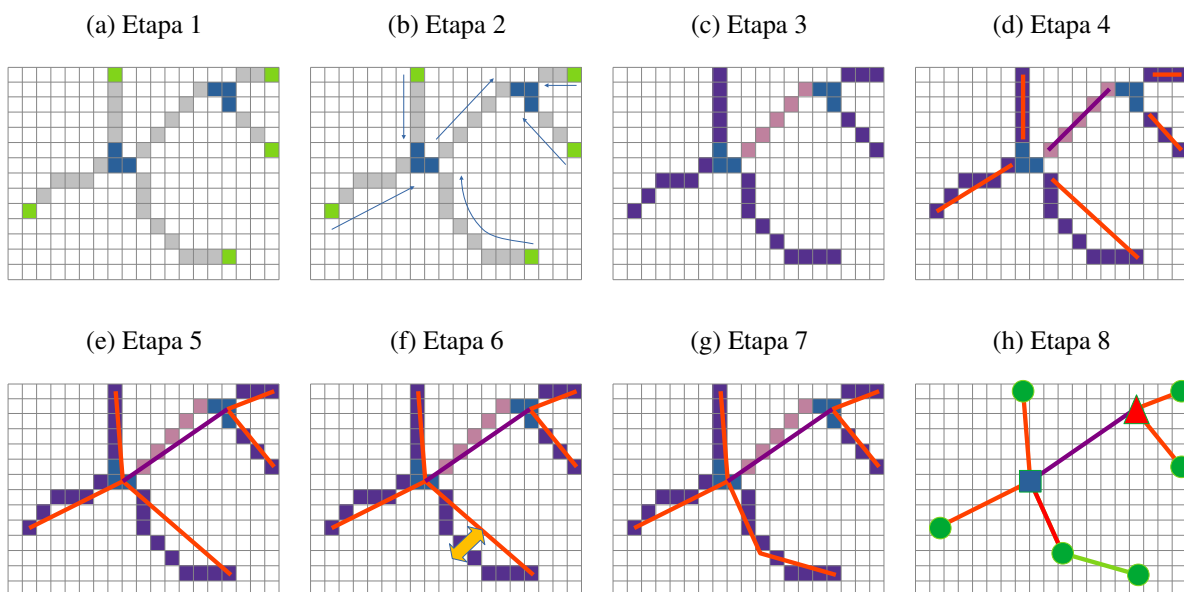
Na etapa 3 (Figura 35c) são identificados os segmentos individuais I-C (terminação para nó) e C-C (nó para nó) e I-I (terminação para terminação). Na Figura 35c estes elementos estão indicados em roxo para elementos I-C, e em rosa para elementos C-C, enquanto elementos I-I não são mostrados.

Na etapa 4 (Figura 35d) as terminações e nós dos elementos identificados na etapa anterior são usados para descrever os segmentos de reta que descreverão os delineamentos de fratura. É possível observar que esses elementos ainda não estão conectados estando adjacentes às áreas de conexão. Na etapa 5 (Figura 35e) as terminações próximas à uma conexão terão sua posição atualizada para o centroide das terminações que chegam à essa região.

Na etapa 6 (Figura 35f) os pixels mais distantes de cada segmento de reta são utilizados como ponto de referência para a separação do segmento de reta em segmentos menores mais próximos ao delineamento obtido na esqueletização, como visto na etapa 7 (Figura 35g).

A última etapa (Figura 35g) é a descrição dos elementos topológicos, e da rede de fraturas em elementos de grafo como a matriz de adjacência e como elemento de *shape* com os segmentos de fraturas georreferenciados.

Figura 35: Detecção de segmentos e rede topológica a partir da detecção de nodos e algoritmo de crescimento e pós processamento. Fonte autor.



Fonte: Elaborado pelo autor.

6.4 Rede Discreta de Fraturas e estatísticas

Após a extração da rede de fraturas e elementos topológicos a partir da imagem das fraturas segmentadas e esqueletizadas utilizando o método de detecção de linhas proposto, foram conduzidas a extração das estatísticas de fratura que caracterizam o modelo DFN do afloramento. Essas estatísticas são agrupadas na Tabela 3. A primeira dessas estatísticas se refere às direções agrupadas pelo diagrama de rosetas. O diagrama de rosetas é um histograma circular no qual as observações são agrupadas por intervalos de direções em graus, onde 0° é norte. Para a comparação dos levantamentos aéreos a posição do Sol em relação ao afloramento também é demarcada nas respectivas rosetas. Além disso, neste estudo os elementos agrupados em cada conjunto da roseta são ponderados utilizando os comprimentos de cada fratura detectada, para evitar que fraturas muito pequenas e em grande quantidade tenham mais relevância do que fraturas grandes, mas em menor quantidade.

As estatísticas de comprimento e abertura seguem a avaliação da distribuição estatística que mais se ajusta a distribuição do dado, seguindo o apresentado na seção 2.4.2, onde são observadas distribuições de lei de potência, exponencial e log-normal.

A intensidade de fraturas (P_{21}) é estimada observando áreas amostrais de 5m^2 , utilizando a ortofoto georreferenciada como referência para o posicionamento das fraturas e para as áreas amostrais.

As informações topológicas são comparadas utilizando os mapas topológicos com os elementos I (terminações), X (cruzamentos) e Y (encontro de fraturas adjacentes).

É possível observar a conectividade das redes de fraturas utilizando gráficos ternários, de modo que as extremidades do triângulo são referências aos elementos I, X e Y. Neste gráfico, a posição demarcada neste espaço indicará uma baixa ou alta conectividade do afloramento. Além disso, a conectividade é dada porcentagem de nodos conectados P_c dada pela Equação 2.7, e pelo índice de conectividade hidráulica f dado pela Equação 2.8.

Tabela 3: Parâmetros e estatísticas extraídas da rede de fraturas.

Parâmetro	Definição	Amostragem	Equação
Densidade $P_{20}(D_{\text{área}})$	Número de fraturas por área (m-2)	Área amostral	$\frac{N}{A}$
Intensidade $P_{21}(D_{\text{área}})$	Comprimento de fraturas por área (mxm-2)	Área amostral	$\frac{\sum_{i=1}^N L_i}{A}$
Média de comprimentos	Média de comprimentos (m)	Afloramento	$\frac{\sum_{i=1}^N L_i}{N}$
Média de aberturas		Afloramento	$\frac{\sum_{i=1}^N W_i}{N}$
Distribuição de comprimentos	Ajustamento de distribuição modelo	Afloramento	-
Distribuição de aberturas	Ajustamento de distribuição modelo	Afloramento	-
Orientação	Clusterização por intervalo direcional ponderado (roseta)	Ponderado amostral	$\sum_{i=1}^k m_i * L_i$
Porcentagem de nodos	Razão ponderada entre tipos de nodos P_c	Afloramento	$\frac{3N_y + 4N_x}{N_i + N_y + N_x}$
Conectividade hidráulica	-	Afloramento	$max \left(0, \frac{2,94 * (4N_x + 2N_y)}{4N_x + 2N_y + N_i} - 2, 13 \right)$


Fonte: Elaborado pelo autor.

7 RESULTADOS E DISCUSSÃO

7.1 Avaliação de métodos de segmentação semântica por deep learning

Na fase de treinamento dos modelos CNN, considerando o conjunto de validação, cada um dos modelos obteve pontuações F1 de 91,2% e 89,6% para U-Net e Segnet respectivamente, e uma pontuação mIoU de 97,2% e 96,9% para a U-Net e a Segnet, respectivamente. Os gráficos na Figura 36 mostram a evolução de aprendizado considerando os dados de validação.


Figura 36: Comparativo da curva de aprendizado para as duas redes de segmentação semântica selecionadas.



Fonte: Elaborado pelo autor.

Para o conjunto de teste, as mesmas pontuações de métricas foram aplicadas com uma pontuação média F1 de 68% para a segmentação Segnet e 89% para a segmentação Unet. Para a pontuação mIoU cada conjunto recebeu uma pontuação média de 51% e 79% para a Segnet e a U-net, respectivamente. A Figura 37 mostra uma das imagens do conjunto de teste para comparação visual com a imagem do afloramento e a respectiva máscara ground truth.

Figura 37: Segmentação semântica por Redes neurais convolucionais de codificação-decodificação.



Fonte: Elaborado pelo autor.

Modelos CNN para segmentação semântica têm se mostrado úteis para segmentação de imagens, e são mostrados aqui como alternativas válidas para segmentação de fraturas em ortomosaicos. Embora, com algumas ressalvas, uma investigação profunda das variações do modelo CNN e testes expandidos ainda devam ser realizados.

Considerando os dois modelos testados, o U-net apresentou imagens segmentadas mais próximas da verdade do que o modelo Segnet mesmo com valores de validação quase idênticos. A U-net também apresentou um tempo de aprendizagem reduzido.

Com segmentação automática adequada, a caracterização de fratura de afloramento a partir de imagens permite uma extração otimizada de características de fratura para gerar modelos de rede de fraturas discretas com maior precisão. Trabalhos futuros explorando esta abordagem avaliarão variações e melhoramentos sobre a rede de segmentação U-net, enquanto que uma caracterização completa da rede DFN também será conduzida.

7.2 Avaliação dos métodos de segmentação assistida por superpixels

A Tabela 4 apresenta as pontuações médias de F1 entre usuários usando cada método. Os usuários obtiveram resultados semelhantes independentemente de sua experiência na análise de fraturas. Quanto maior o número de usuários, melhor definir uma máscara de verdade a partir da consolidação de múltiplas segmentações. Os resultados na Tabela 4 nos permitem consolidar uma máscara de segmentação considerando os superpixels com pelo menos quatro dos seis votos de fazer parte de uma fratura nas máscaras de segmentação obtidas dos três usuários usando os dois métodos. Em comparação com a segmentação consolidada, os usuários O1, O2 e O3 obtiveram pontuações médias de F1 de 0,958, 0,949 e 0,951 com iFG e 0,958, 0,949 e 0,950 com iRG, respectivamente. Figura 38 ilustra as diferenças entre as interpretações do usuário e a máscara consolidada usando iFG.

Tabela 4: Média dos valores de F1 entre usuários para cada método.

	iFG			iRG		
	O1	O2	O3	O1	O2	O3
O1	-	0.971	0.979	-	0.969	0.978
O2	0.971	-	0.966	0.969	-	0.967
O3	0.979	0.966	-	0.978	0.967	-

Tabela 5 mostra o número de cliques para adicionar/remover regiões e o tempo (em minutos) para concluir a segmentação para cada usuário e método. Usuários com mais experiência em análise de fraturas (O1 e O3) podem concluir a segmentação cerca de quatro vezes mais rápido que O2 usando iRG e cinco vezes mais rápido que O2 usando iFG. Independentemente da experiência do usuário, o iFG proporcionou ganho de eficiência de 19% a 33% em relação ao iRG de acordo com o número de cliques do usuário. Observe que O2 gastou mais tempo completando a segmentação com iFG do que iRG, mesmo com menos intervenções no iFG.




Figura 38: Máscaras de segmentação de cada usuário usando iFG (b, c, d) e uma segmentação consolidada das máscaras criadas pelos três usuários usando ambos os métodos considerando 4 das 6 segmentações para cada imagem.

Tabela 5: Cliques para adicionar/remover regiões e tempo (em minutos) para concluir a segmentação para cada usuário e método.

	iRG		iFG		iFG/iRG	
	Cliques	Tempo	Cliques	Tempo	Cliques	Tempo
O1	643	25'	481	21'	-25%	-16%
O2	1597	100'	1296	109'	-19%	+9%
O3	304	26'	203	19'	-33%	-27%

Neste caso, a falta de experiência na análise de fraturas afetou o tempo do usuário devido à incerteza em diferenciar fratura de não fratura.

Foi apresentado um novo método, o Forest Growing interativo (iFG), para segmentação de fraturas em imagens de afloramentos de UAV-SfM. O iFG explora o algoritmo Image Foresting Transform para definição de superpixel e delineamento de fratura em um gráfico de superpixel. Ele divide a imagem em superpixels (VARGAS-MUNOZ et al., 2019) e delinea fraturas ao crescer uma floresta de caminho ótimo enraizada em sementes de superpixel selecionadas limitadas a um determinado limite de custo de caminho.

Os experimentos com 15 imagens mostraram que o iFG proporciona ganho de eficiência em relação a uma abordagem semelhante, o Region Growing (iRG), também disponível na ferramenta de segmentação desenvolvida. Como ambos os métodos são baseados em estruturas de grafos de superpixel, espera-se que seus ganhos de eficiência sejam consideravelmente maiores do que os métodos baseados em pixels. Os experimentos também demonstraram que a experiência do usuário pode afetar significativamente o tempo do usuário, mas não a eficácia da segmentação. Devido à formação cárstica ser suscetível à erosão e dissolução, fraturas geradas por estresse mecânico e menor abertura foram muitas vezes misturadas em superpixels que apresentavam rocha exposta, obrigando os usuários a segmentar essas fraturas diretamente. Em contraste, fraturas com aberturas mais visíveis foram mais facilmente segmentadas.

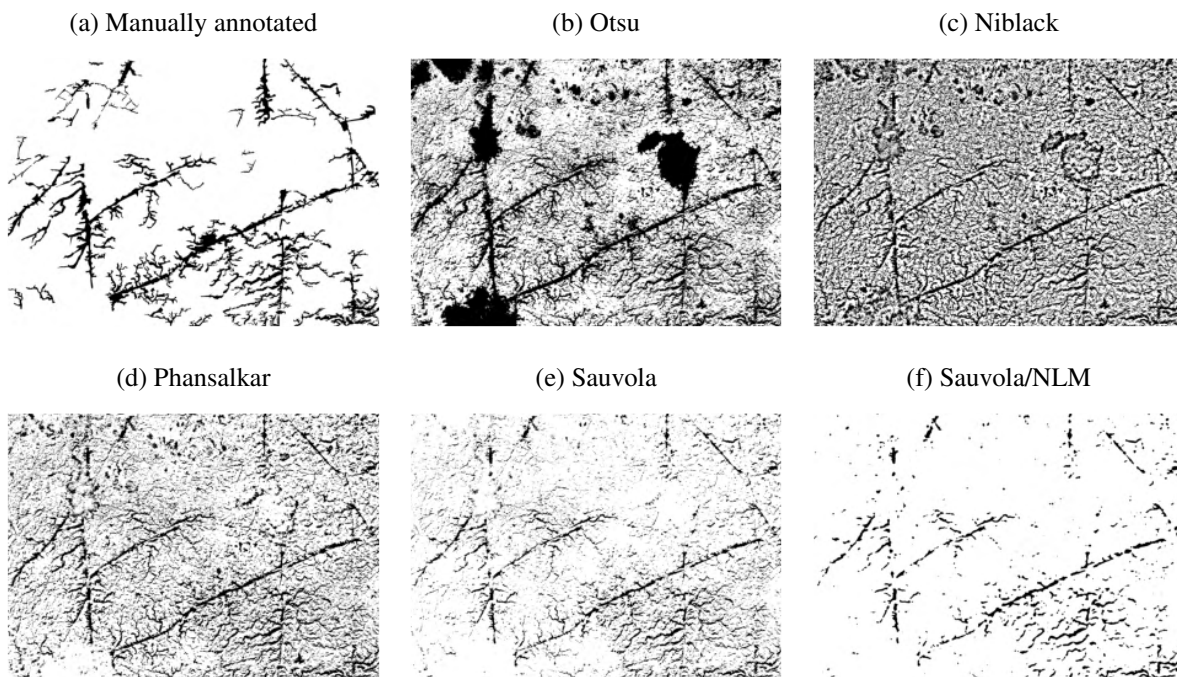
A alta similaridade entre as máscaras de segmentação de três especialistas utilizando os dois métodos criou uma segmentação consolidada. No entanto, trabalhos futuros visam incorporar interpretações de mais usuários, melhorando ainda mais a segmentação consolidada para treinar

redes neurais profundas como a apresentada na Seção 7.1, além de avaliar a sua capacidade de replicar as interpretações dos usuários.

7.3 Avaliação dos métodos de segmentação por limiarização adaptativa

A avaliação inicial, conforme proposta no Capítulo 6, foi realizada na região do afloramento utilizando o *dataset* de ground truth anotado pixel-a-pixel. Resultados preliminares, como na Figura 39 e Tabela 6, mostraram melhores resultados de segmentação para o método de limiar local de Sauvola, sendo esta técnica a utilizada como método adaptativo base para o resto do trabalho.

Figura 39: Testes iniciais de segmentação de limiarização adaptativa global e local.




Fonte: Elaborado pelo autor.

Esses resultados foram obtidos utilizando um tamanho de janela convolutiva de 91x91 pixels. Esse tamanho foi estabelecido após a identificação de que usando os valores padrão para o tamanho da janela (23x23 no trabalho original proposto por Sauvola e Pietikak (2000)), a abertura das fraturas poderia ultrapassar essa região em largura gerando artefatos ou falhas na segmentação das regiões de fratura. Testes com janelas convolutivas de tamanhos arbitrários foram aplicados conforme exemplificado na Figura 40.

A razão para isso se deve ao impacto do desvio padrão no nível de limiar, áreas com baixo desvio padrão conduzem, em geral, a um nível de limiar baixo, configurando a área como primeiro plano (branco). Isso também explica por que as áreas de vegetação foram suprimidas da segmentação por serem mais uniformes e com baixo desvio padrão do que as áreas fraturadas.

Apesar de apresentar os melhores resultados, a segmentação de fraturas baseada na limia-

Figura 40: Avaliação de tamanhos de janela arbitrários para o Sauvola. Em (b) usando uma janela pequena a detecção de fratura é ruidosa e com artefatos quando as áreas de fratura ultrapassam o tamanho da janela, enquanto foram detectados elementos de fratura com geometria mais próxima das áreas em preto (a) à medida que foi aumentada o tamanho de amostragem da janela.



Fonte: Elaborado pelo autor.

rização local adaptativa de Sauvola (Figura 39e) apresenta um alto nível de ruído em relação à segmentação utilizada como *ground truth* (Figura 39a), que segmenta as fraturas principais e adjacentes, justificando a aplicação de um método de redução de ruídos binário. Conforme apresentado no Capítulo 6, o método de redução de ruídos *Non-Local Means* foi a técnica escolhida para esta tarefa.

A Figura 39f mostra a imagem limiarizada após a aplicação da técnica de *denoising* mostrando uma imagem mais próxima da imagem de *ground truth* do que os outros métodos avaliados. Os valores de mIoU, SSIM, F-score e PSNR aumentaram para 0,91, 0,85, 0,95 e 59,13, respectivamente, conforme mostrado na Tabela 6 para a abordagem Sauvola/NLM.

Tabela 6: Resultados de segmentação em comparação com o *ground truth* anotado.

	mIoU	SSIM	F1	PSNR
Niblack	0.65	0.29	0.78	53.11
Otsu	0.69	0.40	0.82	53.75
Phansalkar	0.81	0.51	0.89	55.72
Sauvola	0.890	0.70	0.94	58.03
Sauvola/NLM	0.91	0.85	0.95	59.13

Fonte: Elaborado pelo autor.

Esses resultados mostram a eficiência do método proposto na detecção de fraturas em imagens de afloramentos. Apesar de não serem diretamente comparados com outros métodos já explorados em trabalhos relacionados, eles mostraram resultados promissores e uma oportunidade de pesquisa ao visitar métodos de visão computacional muitas vezes negligenciados por trabalhos recentes.

Em termos de resultados de segmentação contra trabalhos relacionados que usaram imagens de afloramento carstificado altamente fraturado, como no trabalho de Callataj (2016), apresentam técnicas de segmentação baseadas em limiarização global que em nossos testes segmentou


erroneamente áreas de vegetação como áreas de fratura. Os trabalhos que aplicaram limitação global tendem a limitar a área de observação para áreas sem vegetação ou já segmentadas por um processo anterior (BARDUCCI; MECOCCI; PAPERINI, 2002; ANTONY; DOVE, 2006; LIU; JIN; WANG, 2009; LIU et al., 2013; WANG et al., 2017; PRABHAKARAN et al., 2019; ZENG et al., 2020; WEISMÜLLER et al., 2020).

Considerando a aplicação de métodos de segmentação semântica por *deep learning*, foram realizados estudos preliminares onde foram avaliadas as redes Segnet e U-net (MARQUES et al., 2021). Apesar dos resultados apresentarem valores inferiores de mIoU (0,79 contra 0,91 deste trabalho), como apontado nos trabalhos de (SANTOSO; HE; HOTEIT, 2019; LU et al., 2020; CHEN et al., 2021; BYUN et al., 2021), esses resultados podem ter sido influenciados pela qualidade e quantidade do conjunto de dados de treinamento. Ainda, pode ser destacado nesse trabalho, a vantagem de o método adaptativo proposto não necessitar de uma fase de treinamento como os métodos de *deep learning*.

7.4 Estudo de caso: Caracterização DFN por múltiplos levantamentos aéreos

Após avaliar o método proposto usando o conjunto de validação apresentado na Seção 6.2, parâmetros como a avaliação do viés da posição da luz solar e sua influência foram averiguados na detecção de fraturas. Nesta etapa, vários voos sobre o Lajedo Rosario foram executados usando o DJI Mavic Pro 2 e o DJI Phantom RTK conforme detalhado na Seção 6.3.2.

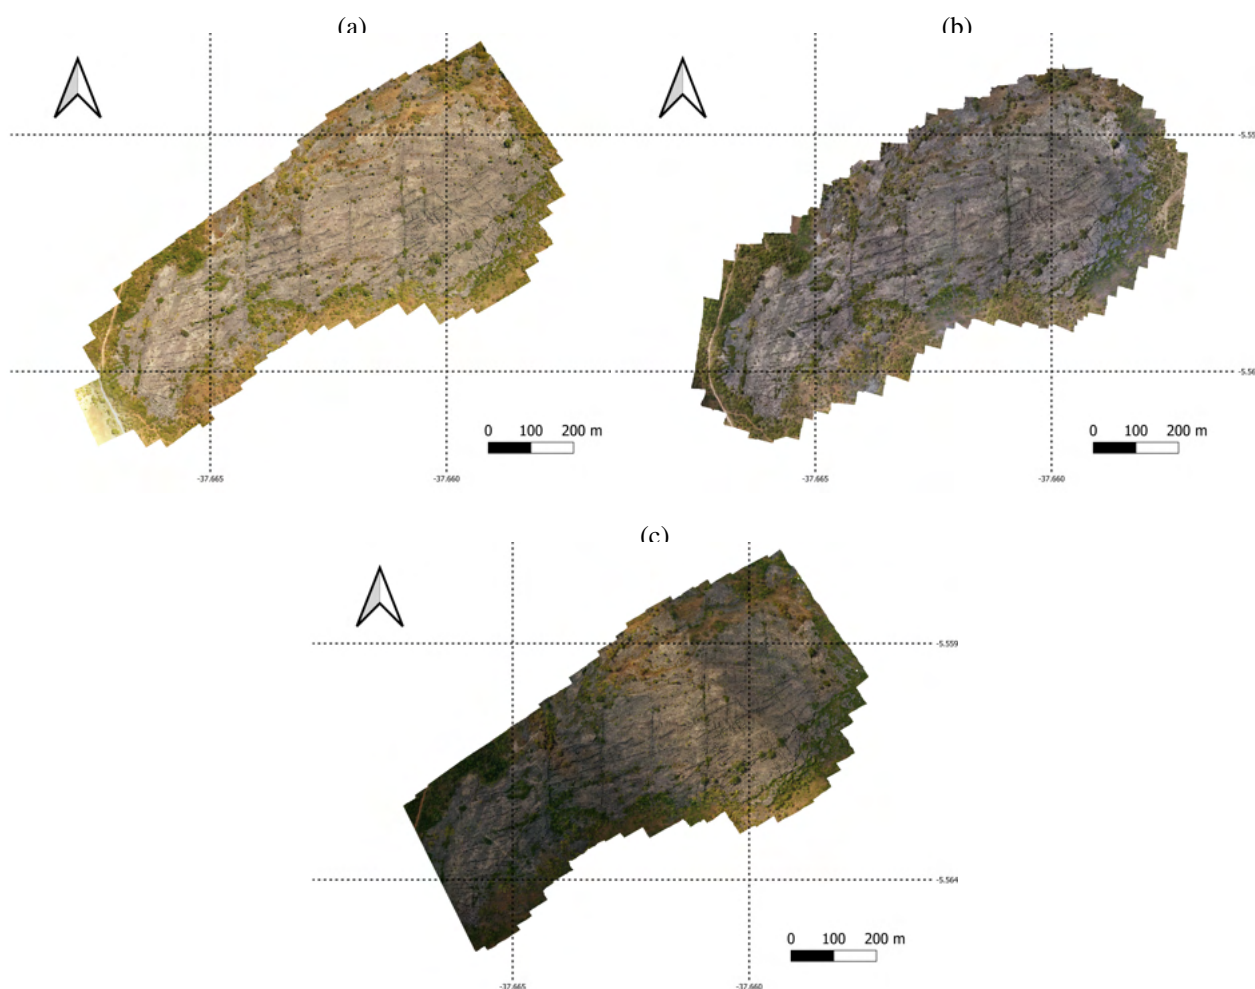
Figura 41: Processamento fotogramétrico das imagens adquiridas por VANT no software Agisoft Metashape.



Fonte: Autor.

Os voos com o DJI Mavic Pro 2 foram realizados pela manhã (10h) e à tarde (14h34) com duração de 35 a 40 minutos, recuperando 443 e 431 imagens respectivamente. O processamento fotogramétrico no Agisoft Metashape (ilustrado na Figura 41) gerou ortofotos com 2,27 cm/pixel e 2,58 cm/pixel. O voo com o DJI Phantom, feito à tarde (13h46), recuperou 605 imagens, com processamento fotogramétrico gerando uma ortofoto com resolução de 6,69 cm/pixel. É possível observar que a ortofoto na Figura 42c possui áreas sombreadas por nuvens durante o voo. Entretanto, a região estudada se situa na região central iluminada, conforme apresentado na Figura 30.

Figura 42: Ortofotos geras pelo processo de fotogrametria digital SfM/MVS.

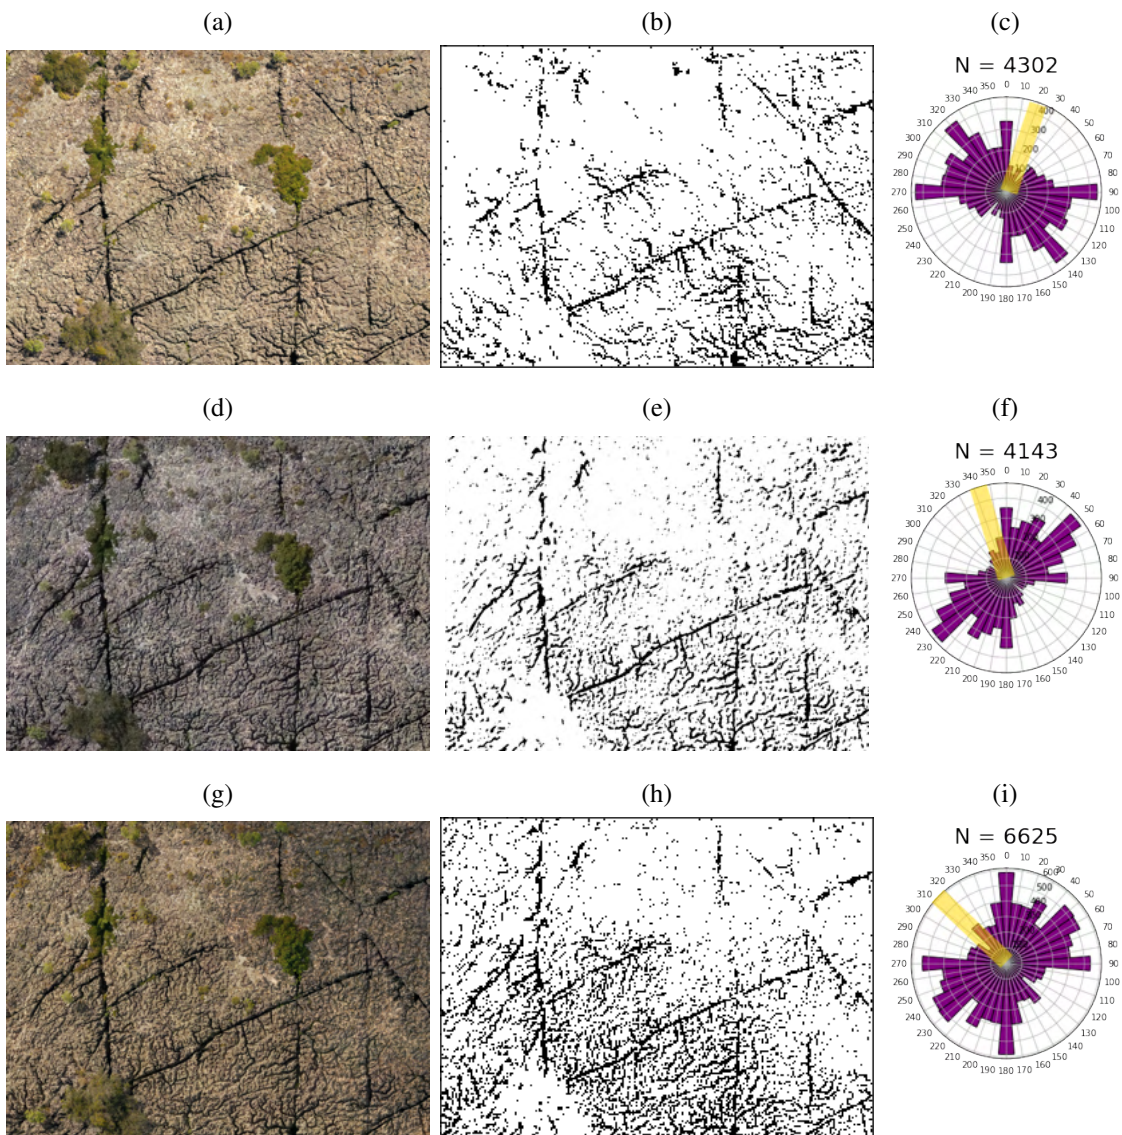


Fonte: Elaborado pelo autor.

A Figura 43 mostra os recortes referentes à área de estudo e a caracterização das fraturas considerando as três aquisições do VANT, mostrando as diferenças de tonalidade de cor, luz e sombras. Essa diferença também influencia na caracterização da fratura e nas estatísticas direcionais em cada caso, mostrando que mais fraturas foram detectadas na direção perpendicular à direção do Sol, o que é observado ao analisar o diagrama de roseta ponderada tanto no número de discontinuidades detectadas quanto nas principais direções destacadas.

Isso confirma a hipótese de que a posição da fonte de luz pode infligir um viés indesejado na detecção da fratura como também apontado no trabalho de Lemy e Hadjigeorgiou (2003), porém esse viés somente foi observado em um afloramento vertical (face interior de caverna). Outros trabalhos como (WEISMÜLLER et al., 2020) apontam a importância de capturar as imagens do afloramento com o UAV durante o tempo ensolarado, contrariando as condições de nebulosidade recomendadas ideais para fotogrametria de uso geral. Além disso, (MOHEBBI et al., 2017) destaca a importância de a fonte de luz estar em uma posição oblíqua em relação à face do afloramento que desejamos detectar discontinuidades usando áreas sombreadas.


Figura 43: Análise da segmentação em imagens adquiridas em voos múltiplos, onde: a, d, g são as imagens de afloramento obtidas a partir do processamento SfM-MVS de cada voo do UAV; b, e, h são a segmentação resultante de cada imagem; c, e, f são os diagramas de roseta ponderados das direções de descontinuidades com a direção do Sol marcada em amarelo.



Fonte: Elaborado pelo autor.

Para superar este viés inerente da iluminação, foi conduzida a combinação dos resultados de segmentação de fraturas, de modo que a interpretação de fraturas seja mais precisa. A Figura 44 mostra as áreas de fraturas segmentadas e acumuladas de acordo com a sobreposição dessas áreas, considerando os três voos, após o redimensionamento e alinhamento das imagens. A segmentação resultante utilizada para a geração do DFN considera áreas segmentadas como fratura em pelos menos duas das três segmentações combinadas.

Figura 44: Sobreposição das segmentações após a aplicação do método de segmentação proposto em cada imagem. Áreas em roxo indicam concordância de áreas



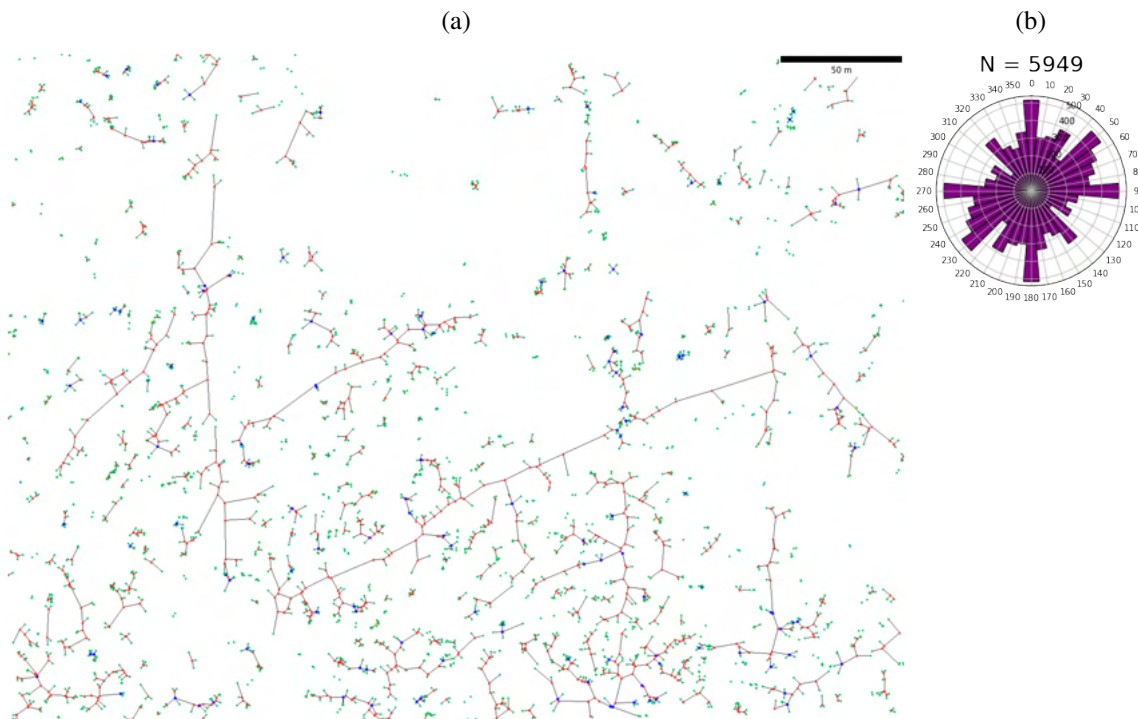
Fonte: Elaborado pelo autor.

A partir da segmentação combinada foi aplicado o método proposto de esqueletização e de detecção de linhas para a obtenção das discontinuidades e informações de comprimento, direção e abertura para a criação do modelo DFN geológico da região estudada.

A Figura 45 mostra o resultado da detecção e caracterização da fratura para obter o DFN usando a segmentação combinada dos três voos do UAV após os procedimentos de esqueletização por transformada do eixo medial para análise de abertura (Figura 46) e detecção de linha (Figura 45). O diagrama de roseta ponderada mostra quatro direções principais de discontinuidades de fratura: N-S, E-W, NE-SW e NW-SE.

Essas principais direções identificadas se alinham com as principais direções de fratura observadas na formação Jandaíra (N-S e E-W) e suas direções secundárias (NE-SW e NW-SE)

Figura 45: Descontinuidade detectadas de aquisição combinada de UAV (a) e estatísticas direcionais no diagrama de roseta ponderada (b).



Fonte: Elaborado pelo autor.

(RABELO et al., 2020; LOPES; CASTRO; BERTOTTI, 2018).

O ajuste de distribuição log-log para dados de abertura e dados de comprimento de fratura são apresentados nas Figuras 47 e 48, respectivamente. Como esperado para este tipo de dados de fratura e afloramento, a distribuição de comprimento está mais próxima da distribuição de lei de potência de maneira que o coeficiente de determinação R^2 é 0,97. Para os dados de abertura, o ajuste contra a distribuição log-normal apresentou uma melhor pontuação R^2 com um valor de 0,97.


Nesta abordagem os dados de abertura são obtidos pela matriz de distâncias do Medial Axis Transform porém os únicos pixels considerados são os que aparecem simultaneamente na esqueletização de Lee (1982).

A diferença entre os métodos de esqueletização pode levar a avaliações de distribuição de aberturas distintas devido a presença de segmentos muito pequenos como no MAT, ou de segmentos de maior comprimento no algoritmo de Zhang e Suen (1984). Nesse trabalho esse viés é reduzido considerando uma amostragem aleatória de 30% sobre esse dado.

Como resultados, a Figura 49a mostra o índice de intensidade de fratura estimado P_{21} usando áreas de amostra de 5m, e a Figura 49b mostra uma interpolação desses dados de intensidade de fratura.

Em relação ao trabalho publicado em Marques et al. (2022) são apresentadas também as análises baseadas na topologia da rede de fratura (Figura 45a), destacando uma conectividade

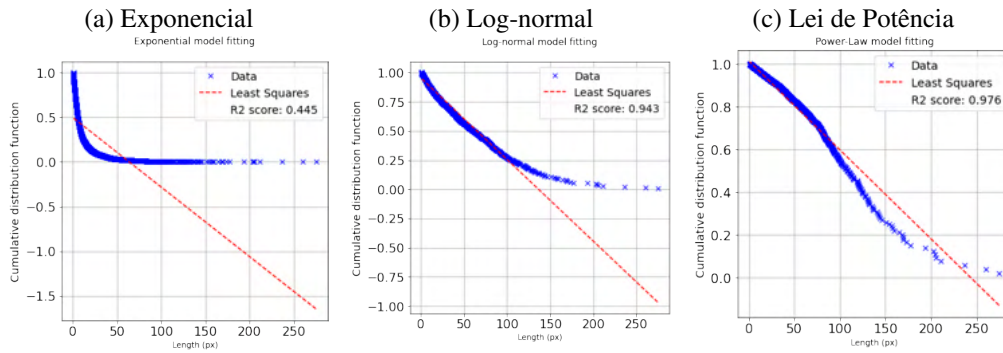
Figura 46: Abertura das fraturas identificadas pela técnica de esqueletização baseada no *Medial Axis Transform*.



Fonte: Elaborado pelo autor.

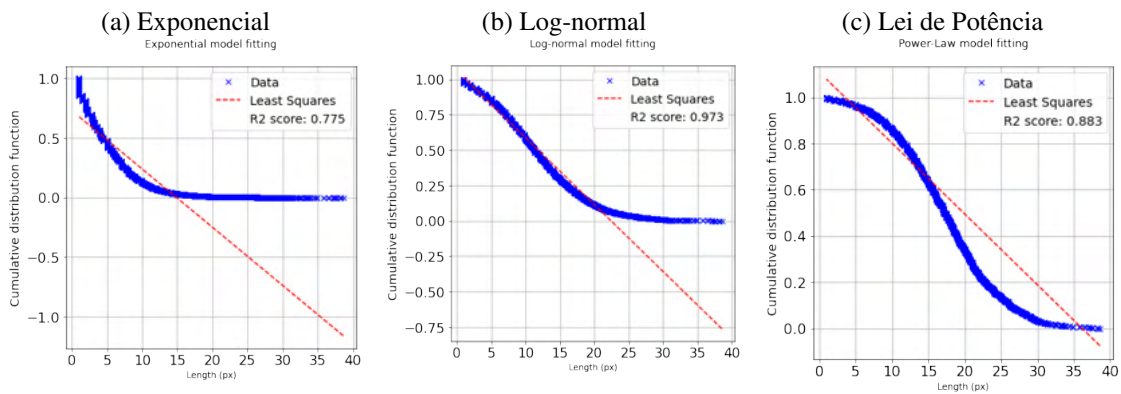
hidráulica nula e poucos nodos conectados para a região estudada (P_c igual a 0,7) com predominância de nodos I (terminações). Entretanto, uma maior análise quanto a influência da variação das segmentações e posição solar na análise topológica ainda é necessária.

Figura 47: Ajuste de distribuição dos comprimentos das descontinuidades em pixels para as distribuições de probabilidade exponencial, log-normal e lei de potência.




Fonte: Elaborado pelo autor.

Figura 48: Ajuste de distribuição da abertura de fratura em pixels contra as distribuições de probabilidade exponencial, log-normal e lei de potência, usando uma amostra de um terço do tamanho dos dados da estimativa de abertura.



Fonte: Elaborado pelo autor.

Figura 49: Intensidades de fratura por área (P21) para amostragens por área de 5m²(a), e interpolação de dados de intensidade pelo algoritmo Lanczos.



Fonte: Elaborado pelo autor.

8 CONCLUSÃO

A segmentação de fraturas em imagens ainda é uma tarefa desafiadora na computação aplicada à geologia, o que pode ser observado pelo diferente número de métodos desenvolvidos ao longo dos anos. Devido à natureza das técnicas e as grandes diferenças entre os cenários como composição e geometria do afloramento, condições de luz e acessibilidade da técnica de detecção escolhida, a detecção automatizada de fraturas e a interpretação estatística dos atributos da fratura podem sofrer com a existência de falsos negativos e falsos positivos durante o processo de segmentação. Portanto ao aperfeiçoar técnicas de segmentação e identificação de fraturas podem contribuir para uma melhor extração da rede de fraturas em relação à interpretação manual e à interpretação automática tradicional, aumentando a fidelidade dos modelos DFN.

Diante da hipótese apresentada, é proposto neste trabalho o uso de um métodos de limiarização adaptativa, comumente empregado na detecção de caracteres, combinados com um método de eliminação de ruído, como proposta principal deste trabalho. Em nossa avaliação, a técnica de Sauvola teve um desempenho melhor do que outros métodos de limiarização adaptativa, por ser mais preciso na segmentação da fratura evitando também áreas ruidosas como áreas com vegetação. Complementarmente ao método de segmentação, também é apresentado um método de vetorização capaz de extrair linhas de fratura usando elementos de topologia na rede de fraturas.

Em relação as condições climáticas, elas podem influenciar grandemente a detecção de fraturas, infligindo um viés indesejado na análise de atributos de fratura, hipótese que foi confirmada pela avaliação de várias aquisições de UAV. A combinação dessas aquisições levou a dados mais precisos para a análise dos atributos da fratura e uma melhor estrutura para a caracterização da rede de fraturas.

No que diz respeito às abordagens mais recentes para detectar fraturas em imagens, como os métodos de aprendizado profundo usando CNN, este trabalho e trabalhos relacionados que se baseiam em métodos tradicionais de visão computacional apresentam algumas vantagens como a possibilidade de processar a imagem inteira sem a necessidade de dividir as imagens em *patches* devido às limitações de memória e processamento ao treinar CNNs. Apesar de apresentarem melhores resultados na maioria dos casos, as CNNs para segmentação de fraturas precisam de conjuntos de dados que devem abranger a maioria dos cenários esperados, e os métodos de processamento de imagem e visão computacional podem contribuir para aumentar os conjuntos de dados de treinamento, ao mesmo tempo em que fornecem resultados instantâneos para a caracterização de fraturas em afloramentos.

Em relação a proposta de segmentação assistida, apresentamos uma nova abordagem de segmentação interativa baseada em superpixels obtidos por operações de grafo para otimizar a segmentação de fraturas em imagens de afloramento adquiridas por UAV-SfM. A metodologia proposta segmenta a imagem em superpixels (VARGAS-MUNOZ et al., 2019) reduzindo a quantidade de objetos a serem avaliados em uma imagem, o que trás uma redução do custo

computacional, além de permite aos usuários selecionar entre os dois algoritmos propostos para delimitação de fraturas.

A metodologia proposta foi incorporada em um aplicativo de segmentação de fraturas que permitiu aos especialistas segmentar fraturas em um conjunto de imagens. Os usuários levaram um tempo variado em cada imagem, dependendo da complexidade da imagem e da experiência do usuário na identificação de fraturas. Devido à formação cárstica ser suscetível à erosão e dissolução, fraturas geradas por estresse mecânico e com menor abertura eram muitas vezes misturadas em superpixels que apresentavam rocha nua, obrigando os usuários a segmentar diretamente essas áreas, enquanto fraturas com aberturas mais visíveis eram mais facilmente segmentadas com os algoritmos propostos. Os resultados finais podem ser usados como *ground truth* consolidado para treinar modelos de segmentação automática mais complexos como as redes de segmentação semântica também abordadas.

8.1 Contribuições

As contribuições deste trabalho são apontadas nos itens descritos abaixo:

- Contribuição 1: Revisão sistemática do estado da arte de métodos de segmentação de fraturas em imagens;
- Contribuição 2: Estratégia de aquisição de imagens por VANT para a geração de redes de fratura mais fiéis às observações pelos especialistas em campo;
- Contribuição 3: Método de segmentação de fraturas adaptativa baseada em limiarização local e técnica de supressão de ruídos em dados binários de baixo custo computacional;
- Contribuição 4: Método de vetorização e extração de rede topológica de fraturas baseado em algoritmo de crescimento, grafos e ajustamento linear.

Adicionalmente às contribuições listadas são destacadas abaixo os trabalhos publicados e participações em eventos durante o desenvolvimento deste doutoramento.

8.2 Artigos publicados

8.2.1 Artigos diretamente relacionados à tese desenvolvida

- SOUZA, E. M. de et al. How much wavelet decomposition can improve the detection of surface fractures in remote sensing images? In: IGARSS 2020 - 2020 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2020. Anais. [S.l.: s.n.], 2020. p. 2619–2622.

- MARQUES, A. et al. Deep learning application for fracture segmentation over outcrop images from uav-based digital photogrammetry. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM IGARSS, 2021., 2021. Anais. . . [S.l.: s.n.], 2021. p. 4692–4695.
- RACOLTE, G. et al. Spherical k-means and elbow method optimizations with fisher statistics for 3d stochastic dfn from virtual outcrop models. IEEE Access, [S.l.], v. 10, p. 63723–63735, 2022.
- MARQUES, A. et al. Adaptive segmentation for discontinuity detection on karstified carbonate outcrop images from uav-sfm acquisition and detection bias analysis. IEEE Access, [S.l.], v. 10, p. 20514–20526, 2022.
- MARQUES JUNIOR, A. et al. Interactive fracture segmentation based on optimum connectivity between superpixels. IEEE Geoscience and Remote Sensing Letters, [S.l.], v. 19, p. 1–5, 2022.
- MARQUES, A. et al. DC-GAN for fracture data generation based on Segmented outcrop images acquired from UAV, 2022. Anais. . . [S.l.: s.n.], 2022. Artigo aceito em evento ainda não publicado.

8.2.2 Levantamento fotogramétrico por VANT e acurácia cartográfica

- Vitti, Dalva M. Castro, Frederico Fábio Mauad, Ademir Marques Jr, Leonardo Campos Inocêncio, and Maurício Roberto Veronez. "Análise Direcional de Erros Sistemáticos em Ortomosaico gerado por meio de RPAS." *Revista Brasileira de Cartografia* 70 (2018): 1566-1594.
- Vitti, Dalva Maria de Castro, Ademir Marques Junior, Taina Thomassin Guimarães, Emi-lie Caroline Koste, Leonardo Campos Inocencio, Maurício Roberto Veronez, and Frederico Fábio Mauad. "Geometry accuracy of DSM in water body margin obtained from an RGB camera with NIR band and a multispectral sensor embedded in UAV." *European Journal of Remote Sensing* 52, no. sup1 (2019): 160-173.
- Marques Junior, Ademir, Dalva Maria De Castro, Taina Thomassin Guimarães, Leonardo Campos Inocencio, Maurício Roberto Veronez, Frederico Fábio Mauad, and Luiz Gon-zaga Jr. "Statistical assessment of cartographic product from photogrammetry and fixed-wing UAV acquisition." *European Journal of Remote Sensing* 53, no. 1 (2020): 27-39.

8.2.3 Estudo de dados espectrais em afloramentos de carbonatos e melhoramento de resolução espacial

- Marques Junior, Ademir, Eniuce Menezes de Souza, Marianne Müller, Diego Brum, Daniel Capella Zanotta, Rafael Kenji Horota, Lucas Silveira Kupssinskü, Maurício Roberto Veronez, Luiz Gonzaga, and Caroline Lessio Cazarin. "Improving Spatial Resolution of Multispectral Rock Outcrop Images Using RGB Data and Artificial Neural Networks." *Sensors* 20, no. 12 (2020): 3559.
- Müller, M. et al. A QUANTITATIVE ANALYSIS ON DIFFERENT CARBONATE INDICATORS BASED ON SPACEBORNE DATA IN A CONTROLLED KARST AREA. In: IGARSS 2020-2020 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2020. Anais. . . [S.l.: s.n.], 2020.

8.2.4 Estudos de modelos digitais de afloramentos e modelagem 3d fotogramétrica

- Horota, Rafael Kenji, Ademir Marques, Pedro Rossa, Eniuce Menezes De Souza, Alysson Soares Aires, Caroline Lessio Cazarin, Mauricio Roberto Veronez, and Luiz Gonzaga. "Printgrammetry: Google Earth Imagery Based 3D Model Generation for VR Applications." In IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium, pp. 4292-4295. IEEE, 2019.
- Hossa, Pedro, Rafael Kenji Horota, Ademir Marques Junior, Alysson Soares Aires, Eniuce Menezes De Souza, Gabriel Lanzer Kannenberg, Jean Luca De Fraga et al. "MOSIS: Immersive Virtual Field Environments for Earth Sciences." In 2019 IEEE Conference on Virtual Reality and 3D User Interfaces (VR), pp. 1140-1141. IEEE, 2019.
- Marques Jr, Ademir, Rafael Kenji Horota, Eniuce Menezes de Souza, Lucas Lupssinskü, Pedro Rossa, Alysson Soares Aires, Leonardo Bachi, Mauricio Roberto Veronez, Luiz Gonzaga Jr, and Caroline Lessio Cazarin. "Virtual and digital outcrops in the petroleum industry: A systematic review." *Earth-Science Reviews* (2020): 103260.

8.2.5 Participação em eventos

- Chair/Organizador de sessão no IGARSS - IEEE International Geoscience and Remote Sensing Symposium 2019/2022.
- Participação e classificação em concurso de tese de 3 minutos com o título "FROM FRACTURES TO PETROLEUM EXTRACTION: HOW FAR CAN WE GO USING AUTOMATED METHODS?" no IGARSS - IEEE International Geoscience and Remote Sensing Symposium 2019.

- Participação no IX WWlet 2019 Wavelet and Applications em trabalho apresentado com o título "Wavelet Neural Networks for prediction and classification".
- Participação no III Seminário de Inteligência Artificial Aplicada à Indústria do Petróleo em trabalho apresentado com o título "DEEP LEARNING METHODS FOR FRACTURE SEGMENTATION IN OUTCROP IMAGES", 2021.

8.3 Trabalhos Futuros

Trabalhos futuros deste trabalho de tese visam a exploração de técnicas e melhoramentos das metodologias empregadas tanto na segmentação de imagens quanto na caracterização de fraturas em imagens de afloramentos trazendo mais informações relacionadas à redes de fraturas não trazidas aqui.

Quanto a segmentação adaptativa, trabalhos futuros nesta pesquisa visam expandir a caracterização de DFN analisando o viés de detecção de fratura em relação à topologia enquanto explora modelagem estocástica e simulação de fluxo de fluido de reservatório. Uma maior exploração das estatísticas de fraturas e geração dos modelos estocásticos a partir dos dados obtidos também são colocados como trabalhos futuros. É válido salientar que uma extensa avaliação dos métodos de segmentação de fraturas ainda não foi vista na literatura e uma possível publicação da revisão conduzida neste trabalho será um dos subprodutos desta tese.

Outros trabalhos futuros são listados abaixo:

- Exploração de técnicas de segmentação baseadas em entropia;
- Combinação das técnicas de caracterização de fraturas com as segmentações superpixel e *deep learning*;
- Aplicação de outros métodos de redução de ruído binário;
- Avaliação do impacto dos parâmetros de segmentação no estudo topológico;
- Caracterização DFN em imagens baseada em RQD, e fractal por box counting.

REFERÊNCIAS

- ABDOLLAHI, A.; PRADHAN, B.; ALAMRI, A. M. An Ensemble Architecture of Deep Convolutional Segnet and Unet Networks for Building Semantic Segmentation from High-resolution Aerial Images. **Geocarto International**, [S.l.], v. 0, n. 0, p. 1–13, 2020.
- ABU-AIN, W. et al. Skeletonization Algorithm for Binary Images. **Procedia Technology**, [S.l.], v. 11, p. 704–709, jan 2013.
- ACHANTA, R. et al. Slic superpixels compared to state-of-the-art superpixel methods. **IEEE transactions on pattern analysis and machine intelligence**, [S.l.], v. 34, n. 11, p. 2274–2282, 2012.
- ADLER, P. M.; THOVERT, J. F.; MOURZENKO, V. V. Fractured Porous Media. **Fractured Porous Media**, [S.l.], v. 9780199666, p. 1–184, 2013.
- ANDREWS, B. et al. How do we see fractures? Quantifying subjective bias in fracture data collection. **Solid Earth**, [S.l.], v. 10, n. 2, p. 487–516, 2019.
- ANTONY, A. V.; DOVE, J. E. Semiautomatic rock mass discontinuity detection using digital images. In: GEOCONGRESS 2006: GEOTECHNICAL ENGINEERING IN THE INFORMATION TECHNOLOGY AGE, 2006. **Anais...** [S.l.: s.n.], 2006. v. 2006, p. 275.
- ARGIALAS, D. P.; MAVRANTZA, O. D. COMPARISON OF EDGE DETECTION AND HOUGH TRANSFORM TECHNIQUES FOR THE EXTRACTION OF GEOLOGIC FEATURES. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [S.l.], v. 34, n. Part XXX, p. 1–6, 2004.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: a deep convolutional encoder-decoder architecture for image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S.l.], v. 39, n. 12, p. 2481–2495, 2017.
- BARDUCCI, A.; MECOCCHI, A.; PAPERINI, A. Detection of linear geological features (jointing) by Hough transform of multispectral remotely sensed images. In: SPIE - THE INTERNATIONAL SOCIETY FOR OPTICAL ENGINEERING, 2002. **Proceedings...** [S.l.: s.n.], 2002. v. 4886, p. 145–150.
- BARTON, N. et al. Suggested methods for the quantitative description of discontinuities in rock masses. In: INTERNATIONAL JOURNAL OF ROCK MECHANICS AND MINING SCIENCES AND GEOMECHANICS ABSTRACTS, 1978. **Anais...** [S.l.: s.n.], 1978. v. 15, n. 6, p. 319–368.
- BASIRAT, R.; GOSHTASBI, K.; AHMADI, M. Determination of the Fractal Dimension of the Fracture Network System Using Image Processing Technique. **Fractal and Fractional**, [S.l.], v. 3, n. 2, 2019.
- BEER, A.; STEAD, D.; COGGAN, J. Technical note estimation of the joint roughness coefficient (jrc) by visual comparison. **Rock mechanics and rock engineering**, [S.l.], v. 35, n. 1, p. 65–74, 2002.

- BELEM, F. C.; GUIMARAES, S. J. F.; FALCAO, A. X. Superpixel Segmentation Using Dynamic and Iterative Spanning Forest. **IEEE Signal Processing Letters**, [S.l.], v. 27, p. 1440–1444, 2020.
- BERNAL, J. et al. Lindens: a program for lineament length and density analysis. **Computers & Geosciences**, [S.l.], 2002.
- BERNSEN, J. Dynamic thresholding of gray-level images. In: EIGHTH INT'L CONF. PATTERN RECOGNITION, PARIS, 1986, 1986. **Proceedings...** [S.l.: s.n.], 1986.
- BERTOTTI, G.; BISDOM, K. **Fracture patterns in the jandeira fm. (ne brazil)**. <https://data.4tu.nl/repository/uuid:be07fe95-417c-44e9-8c6a-d13f186abfbb>. Acessado em 17 de Março de 2020.
- BERTOTTI, G. et al. Outcropping analogs and multiscale fracture patterns in the jandaíra formation. In: FIRST EAGE/SBGf WORKSHOP 2013, RIO DE JANEIRO-FRACTURES IN CONVENTIONAL AND UNCONVENTIONAL RESERVOIRS, 2013. **Anais...** [S.l.: s.n.], 2013. p. cp–365.
- BILMES, A. et al. Digital outcrop modelling using “structure-from-motion” photogrammetry: acquisition strategies, validation and interpretations to different sedimentary environments. **Journal of South American Earth Sciences**, [S.l.], v. 96, n. July, p. 102325, 2019.
- BISDOM, K.; NICK, H. M.; BERTOTTI, G. An integrated workflow for stress and flow modelling using outcrop-derived discrete fracture networks. **Computers and Geosciences**, [S.l.], 2017.
- BISHOP, C. M.; NASRABADI, N. M. **Pattern recognition and machine learning**. [S.l.]: Springer, 2006. v. 4, n. 4.
- BJORLYKKE, K. **Petroleum geoscience: from sedimentary environments to rock physics**. [S.l.]: Springer Science & Business Media, 2010.
- BOLAND, A.; CHERRY, G.; DICKSON, R. **Doing a systematic review: a student's guide**. [S.l.]: Sage, 2017.
- BONNET, E. et al. Scaling of fracture systems in geological media. **Reviews of geophysics**, [S.l.], v. 39, n. 3, p. 347–383, 2001.
- BUADES, A.; COLL, B.; MOREL, J. M. On image denoising methods. **Mathematics**, [S.l.], p. 1–40, jun 2004.
- BUADES, A.; COLL, B.; MOREL, J.-M. Non-local means denoising. **Image Processing On Line**, [S.l.], v. 1, p. 208–212, 2011.
- BUCKLEY, S. J. et al. Integration of terrestrial laser scanning, digital photogrammetry and geostatistical methods for high-resolution modelling of geological outcrops. In: INT. ARCH. PHOTOGRAMM. REMOTE SENS. SPAT. INF. SCI., 2006. **Anais...** [S.l.: s.n.], 2006. v. 36, n. B5, p. 1–6.
- BUCKLEY, S. J. et al. Terrestrial laser scanning for use in virtual outcrop geology. **Photogrammetric Record**, [S.l.], v. 25, n. 131, p. 225–239, 2010.

- BUCKLEY, S. J. et al. Lime: software for 3-d visualization, interpretation, and communication of virtual geoscience models. **Geosphere**, [S.l.], v. 15, n. 1, p. 222–235, 2019.
- BURGER, W.; BURGE, M. J. **Digital image processing: an algorithmic introduction using java**. [S.l.]: Springer, 2016.
- BYUN, H. et al. A deep convolutional neural network for rock fracture image segmentation. **Earth Science Informatics**, [S.l.], 2021.
- CALLATAÏ, G. de. **Hough transform application to natural fracture networks: detection, characterization and simulation**. 2016. 58 p.
- CANNY, J. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S.l.], v. PAMI-8, n. 6, p. 679–698, 1986.
- CASINI, G. et al. Fracture characterization and modeling from virtual outcrops. **AAPG Bulletin**, [S.l.], v. 100, n. 1, p. 41–61, 2016.
- CASSAB, R. Paleontologia da formação jandaíra, cretáceo superior da bacia potiguar, com ênfase na paleobiologia dos gastrópodos. **Rio de Janeiro**, [S.l.], 2003.
- CHEN, J. et al. Automated extraction and evaluation of fracture trace maps from rock tunnel face images via deep learning. **International Journal of Rock Mechanics and Mining Sciences**, [S.l.], v. 142, 2021.
- CHOI, H. I.; CHOI, S. W.; MOON, H. P. Mathematical theory of medial axis transform. **Journal of mathematical sciences**, [S.l.], v. 181, n. 1, p. 57–88, 1997.
- CIESIELSKI, K. C.; FALCÃO, A. X.; MIRANDA, P. A. Path-Value Functions for Which Dijkstra's Algorithm Returns Optimal Mapping. **Journal of Mathematical Imaging and Vision**, [S.l.], v. 60, n. 7, p. 1025–1036, 2018.
- DE WAELE, J. et al. Geomorphology and natural hazards in karst areas: a review. **Geomorphology**, [S.l.], v. 134, n. 1-2, p. 1–8, 2011.
- DEFIORIANI, L.; SPAGNUOLO, M. **Shape analysis and structuring**. [S.l.]: Springer, 2008.
- DEKORWITZ, W. S. **Rock joint systems**. 1984. Tese (Doutorado em Ciência da Computação) — Massachusetts Institute of Technology, 1984.
- DOUGLAS, D. H.; PEUCKER, T. K. Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. **Cartographica: the international journal for geographic information and geovisualization**, [S.l.], v. 10, n. 2, p. 112–122, 1973.
- DUDA, R.; HART, P. Use of hough transform to detect curves and lines in pictures. **Commun. ACM**, [S.l.], v. 15, p. 11–15, 1972.
- EINSTEIN, H. H.; BAECHE, G. B. Probabilistic and statistical methods in engineering geology. **Rock mechanics and rock engineering**, [S.l.], v. 16, n. 1, p. 39–72, 1983.

FALCÃO, A.; BRAGANTINI, J. The role of optimum connectivity in image segmentation: can the algorithm learn object information during the process? **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, [S.l.], v. 11414 LNCS, p. 180–194, 2019.

FALCÃO, A. X.; STOLFI, J.; ALENCAR LOTUFO, R. de. The image foresting transform: theory, algorithms, and applications. **IEEE transactions on pattern analysis and machine intelligence**, [S.l.], v. 26, n. 1, p. 19–29, 2004.

FOSSEN, H. **Structural geology**. 1a. ed. United Kingdom: Cambridge University Press, 2010. 481 p.

FURUKAWA, Y.; HERNÁNDEZ, C. **Multi-view stereo: a tutorial**. [S.l.: s.n.], 2015. 217 p. v. 2, n. 1.

GALVÃO, F. L.; GUIMARÃES, S. J. F.; FALCÃO, A. X. Image segmentation using dense and sparse hierarchies of superpixels. **Pattern Recognition**, [S.l.], v. 108, p. 1–14, 2020.

GOMES, I. P. et al. Fraturas, carste e cavernas nos calcários jandaíra em felipe guerra, rio grande do norte. **Geologia USP. Série Científica**, [S.l.], v. 19, n. 1, p. 43–67, 2019.

GONZAGA, L. et al. A multioutcrop sharing and interpretation system: exploring 3-d surface and subsurface data. **IEEE Geoscience and Remote Sensing Magazine**, [S.l.], v. 6, n. 2, p. 8–16, jun 2018.

GRAAF, S. de et al. Fracturing and calcite cementation controlling fluid flow in the shallow-water carbonates of the Jandaíra Formation, Brazil. **Marine and Petroleum Geology**, [S.l.], v. 80, p. 382–393, 2017.

GUO, L. et al. A semi-automated methodology for rock mass discontinuity trace map construction. In: INTERNATIONAL CONFERENCE ON IMAGE ANALYSIS AND SIGNAL PROCESSING, IASP 2012, 2012., 2012. **Proceedings...** [S.l.: s.n.], 2012. p. 1–5.

HAJI, S. H.; ABDULAZEEZ, A. M. Comparison of optimization techniques based on gradient descent algorithm: a review. **PalArch's Journal of Archaeology of Egypt/Egyptology**, [S.l.], v. 18, n. 4, p. 2715–2743, 2021.

HARDEBOL, N. J.; BERTOTTI, G. Digifract: a software and data model implementation for flexible acquisition and processing of fracture data from outcrops. **Computers and Geosciences**, [S.l.], v. 54, p. 326–336, 2013.

HARZING, A.-W.; ALAKANGAS, S. Google scholar, scopus and the web of science: a longitudinal and cross-disciplinary comparison. **Scientometrics**, [S.l.], v. 106, n. 2, p. 787–804, 2016.

HASSANEIN, A. S. et al. A survey on hough transform, theory, techniques and applications. **arXiv preprint arXiv:1502.02160**, [S.l.], 2015.

HEALY, D. et al. Fracpaq: a matlab™ toolbox for the quantification of fracture patterns. **Journal of Structural Geology**, [S.l.], v. 95, p. 1–16, 2017.

HODGETTS, D. et al. Integrating digital and traditional field techniques using virtual reality geological studio (vrgs). In: EAGE CONFERENCE AND EXHIBITION INCORPORATING SPE EUROPEC 2007, 69., 2007. **Anais...** [S.l.: s.n.], 2007. p. cp–27.

HOLDEN, E. J. et al. Improving assessment of geological structure interpretation of magnetic data: an advanced data analytics approach. **Computers and Geosciences**, [S.l.], v. 87, p. 101–111, 2016.

HOUGH, P. V. Method and means for recognizing complex patterns. **US patent**, [S.l.], v. 3, n. 6, 1962.

HU, M. Integrated Machine Learning and Numerical Modeling for Multiscale Analyses of Coupled Processes in Geosystems. In: IOP CONFERENCE SERIES: EARTH AND ENVIRONMENTAL SCIENCE, 2021. **Anais...** [S.l.: s.n.], 2021. v. 861, n. 3.

JAUD, M. et al. Assessing the accuracy of high resolution digital surface models computed by photoscan® and micmac® in sub-optimal survey conditions. **Remote Sensing**, [S.l.], v. 8, n. 6, p. 465, 2016.

KEMENY, J. et al. Digital imaging for rock mass characterization. In: GEOPHYSICS 2002. THE 2ND ANNUAL CONFERENCE ON THE APPLICATION OF GEOPHYSICAL AND NDT METHODOLOGIES TO TRANSPORTATION FACILITIES AND INFRASTRUCTURE FEDERAL HIGHWAY ADMINISTRATION (FHWA-WRC-02-001), TRANSPORTATION RESEARCH BOARD, CALIFORNIA DEPARTMENT OF TRANSPORTATION, 2002. **Anais...** [S.l.: s.n.], 2002.

KHAN, K. S. et al. **Undertaking systematic reviews of research on effectiveness: crd's** guidance for carrying out or commissioning reviews. [S.l.]: NHS Centre for Reviews and Dissemination, 2001. n. 4 (2n).

KITCHENHAM, B. Procedure for undertaking systematic reviews. **Computer Science Department, Keele University (TRISE-0401) and National ICT Australia Ltd (0400011T. 1), Joint Technical Report**, [S.l.], 2004.

KITCHENHAM, B.; BUDGEN, D.; BRERETON, O. P. Evidence-based software engineering and systematic literature reviews. **Lecture Notes in Computer Science**, [S.l.], v. 4034, p. 3, 2006.

KOIKE, K.; NAGANO, S.; OHMI, M. Lineament analysis of satellite images using a Segment Tracing Algorithm (STA). **Computers & Geosciences**, [S.l.], v. 21, n. 9, p. 1091–1104, nov 1995.

KORNILOV, A.; SAFONOV, I.; YAKIMCHUK, I. A review of watershed implementations for segmentation of volumetric images. **Journal of Imaging**, [S.l.], v. 8, n. 5, p. 127, 2022.

KRIG, S. **Computer vision metrics**. [S.l.]: Springer Nature, 2014.

KUBAT, M. **An introduction to machine learning**. [S.l.]: Springer, 2017.

LA BRUNA, V. et al. High-permeability zones in folded and faulted silicified carbonate rocks—implications for karstified carbonate reservoirs. **Marine and Petroleum Geology**, [S.l.], v. 128, p. 105046, 2021.

LABATE, D. et al. Sparse multidimensional representation using shearlets. In: WAVELETS XI, 2005. **Anais...** [S.l.: s.n.], 2005. v. 5914, p. 254–262.

- LALIBERTE, A. S. et al. Acquisition, orthorectification, and object-based classification of unmanned aerial vehicle (uav) imagery for rangeland monitoring. **Photogrammetric Engineering & Remote Sensing**, [S.l.], v. 76, n. 6, p. 661–672, 2010.
- LANEN, X. M. T. van et al. Applications of digital outcrop models: two fluvial case studies from the triassic wolfville fm., canada and oukaimeden sandstone fm., morocco. **Geological Journal**, [S.l.], v. 44, n. 6, p. 742–760, 2009.
- LARSEN, K.; SENGER, K.; GRUNDEVÅG, S.-A. Fracture characterization in upper permian carbonates in spitsbergen: a workflow from digital outcrop to geo-model. **Marine and Petroleum Geology**, [S.l.], v. 122, n. September, p. 104703, 2020.
- LEE, D.-T. Medial axis transformation of a planar shape. **IEEE Transactions on pattern analysis and machine intelligence**, [S.l.], n. 4, p. 363–369, 1982.
- LEE, T.-C.; KASHYAP, R. L.; CHU, C.-N. Building skeleton models via 3-d medial surface axis thinning algorithms. **CVGIP: Graphical Models and Image Processing**, [S.l.], v. 56, n. 6, p. 462–478, 1994.
- LEE, T.; KASHYAP, R.; CHU, C. Building Skeleton Models via 3-D Medial Surface Axis Thinning Algorithms. **CVGIP: Graphical Models and Image Processing**, [S.l.], v. 56, n. 6, p. 462–478, nov 1994.
- LEI, Q.; LATHAM, J.-P.; TSANG, C.-F. The use of discrete fracture networks for modelling coupled geomechanical and hydrological behaviour of fractured rocks. **Computers and Geotechnics**, [S.l.], v. 85, p. 151–176, 2017.
- Lemes Galvão, F.; FALCÃO, A. X.; Shankar Chowdhury, A. Risf: recursive iterative spanning forest for superpixel segmentation. **Proceedings - 31st Conference on Graphics, Patterns and Images, SIBGRAPI 2018**, [S.l.], p. 408–415, 2019.
- LEMY, F.; HADJIGEORGIOU, J. Discontinuity trace map construction using photographs of rock exposures. **International Journal of Rock Mechanics and Mining Sciences**, [S.l.], v. 40, n. 6, p. 903–917, 2003.
- LEMY, F.; HADJIGEORGIOU, J. A digital face mapping case study in an underground hard rock mine. **Canadian Geotechnical Journal**, [S.l.], v. 41, n. 6, p. 1011–1025, 2004.
- LENG, B. et al. Rock mass trace line identification incorporated with grouping algorithm at tunnel faces. **Tunnelling and Underground Space Technology**, [S.l.], v. 110, n. January, p. 103810, 2021.
- LEPILLIER, B. et al. From outcrop scanlines to discrete fracture networks, an integrative workflow. **Journal of Structural Geology**, [S.l.], v. 133, apr 2020.
- LIU, C. et al. Automatic quantification of crack patterns by image processing. **Computers and Geosciences**, [S.l.], v. 57, p. 77–80, 2013.
- LIU, C.; REN, C. Research on Coal-Rock Fracture Image Edge Detection Based on Tikhonov Regularization and Fractional Order Differential Operator. **Journal of Electrical and Computer Engineering**, [S.l.], v. 2019, 2019.

- LIU, M.; JIN, W. B.; WANG, W. X. Detection of rock fractures junction in gray-level images. In: INTERNATIONAL CONGRESS ON IMAGE AND SIGNAL PROCESSING, CISP'09, 2009., 2009. **Proceedings...** [S.l.: s.n.], 2009.
- LOPES, J. A. G.; CASTRO, D. L. de; BERTOTTI, G. Quantitative analysis of the tectonic subsidence in the Potiguar Basin (NE Brazil). **Journal of Geodynamics**, [S.l.], v. 117, p. 60–74, jun 2018.
- LU, F. et al. Convolution neural network based on fusion parallel multiscale features for segmenting fractures in coal-rock images. **Journal of Electronic Imaging**, [S.l.], v. 29, n. 2, 2020.
- M. Tóth, T. Fracture network characterization using 1D and 2D data of the Mórággy Granite body, southern Hungary. **Journal of Structural Geology**, [S.l.], v. 113, p. 176–187, aug 2018.
- MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Trans. Pattern Anal. Mach. Intell.**, Washington, DC, USA, v. 11, n. 7, p. 674–693, July 1989.
- MARQUES, A. et al. Virtual and digital outcrops in the petroleum industry: a systematic review. **Earth-Science Reviews**, [S.l.], v. 208, n. June, p. 103260, 2020.
- MARQUES, A. et al. Deep learning application for fracture segmentation over outcrop images from uav-based digital photogrammetry. In: IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM IGARSS, 2021., 2021. **Anais...** [S.l.: s.n.], 2021. p. 4692–4695.
- MARQUES, A. et al. Adaptive segmentation for discontinuity detection on karstified carbonate outcrop images from uav-sfm acquisition and detection bias analysis. **IEEE Access**, [S.l.], v. 10, p. 20514–20526, 2022.
- MARQUES JUNIOR, A. et al. Statistical assessment of cartographic product from photogrammetry and fixed-wing uav acquisition. **European Journal of Remote Sensing**, [S.l.], v. 53, n. 1, p. 27–39, 2020.
- MARQUES JUNIOR, A. et al. Interactive fracture segmentation based on optimum connectivity between superpixels. **IEEE Geoscience and Remote Sensing Letters**, [S.l.], v. 19, p. 1–5, 2022.
- MASOUD, A.; KOIKE, K. Applicability of computer-aided comprehensive tool (linda: lineament detection and analysis) and shaded digital elevation model for characterizing and interpreting morphotectonic features from lineaments. **Computers and Geosciences**, [S.l.], v. 106, n. June, p. 89–100, 2017.
- MATAS, J.; GALAMBOS, C.; KITTLER, J. Robust detection of lines using the progressive probabilistic hough transform. **Computer Vision and Image Understanding**, [S.l.], 2000.
- MEDEIROS, A. K. Alves de; CÓRDOBA, V. C. Stratigraphic analysis of ponta do mel carbonate platform, albian-cenomanian in potiguar basin, ne of brazil. **Journal of South American Earth Sciences**, [S.l.], v. 102, p. 102675, 2020.
- MENEZES, D. F. et al. Subsidence rings and fracture pattern around dolines in carbonate platforms – Implications for evolution and petrophysical properties of collapse structures. **Marine and Petroleum Geology**, [S.l.], v. 113, n. October 2019, p. 104113, 2020.

- MENEZES, L. Caracterização faciológica e parametrização de análogos a reservatórios petrolíferos fluviais da formação açu (unidade açu-3)–bacia potiguar. 2002. 54f. **Relatório (Graduação em Geologia)–Departamento de Geologia. Universidade Federal do Rio Grande do Norte. Natal, Rio Grande do Norte, [S.l.], 2002.**
- MIDDLETON, M. et al. Geological lineament interpretation using the object-based image analysis approach: results of semi-automated analyses versus visual interpretation. **Geological Survey of Finland, Special Paper**, [S.l.], v. 57, p. 135–154, 2015.
- MIRANDA, T. S. et al. Quantifying aperture, spacing and fracture intensity in a carbonate reservoir analogue: crato formation, ne brazil. **Marine and Petroleum Geology**, [S.l.], v. 97, n. July, p. 556–567, 2018.
- MOHEBBI, M. et al. Rock mass structural data analysis using image processing techniques (case study: choghart iron ore mine northern slopes). **Journal of Mining & Environment**, [S.l.], v. 8, n. 1, p. 61–74, 2017.
- MOHER, D. et al. Preferred reporting items for systematic reviews and meta-analyses: the prisma statement. **PLoS medicine**, [S.l.], v. 6, n. 7, p. e1000097, 2009.
- MONTERO, A. S.; LANG, J. Skeleton pruning by contour approximation and the integer medial axis transform. **Computers & Graphics**, [S.l.], v. 36, n. 5, p. 477–487, 2012.
- MURPHY, K. P. **Machine learning: a probabilistic perspective**. [S.l.]: MIT press, 2012.
- N, S.; S, V. Image Segmentation By Using Thresholding Techniques For Medical Images. **Computer Science & Engineering: An International Journal**, [S.l.], v. 6, n. 1, p. 1–13, feb 2016.
- NACCACHE, N. J.; SHINGHAL, R. An investigation into the skeletonization approach of hilditch. **Pattern Recognition**, [S.l.], v. 17, n. 3, p. 279–284, 1984.
- NASON, G. P.; SILVERMAN, B. W. The stationary wavelet transform and some statistical applications. In: WAVELETS AND STATISTICS, 1995. **Anais...** Springer, 1995. p. 281–299.
- Nelson Kennedy Babu, C. **List algorithm: lineament identification and stockworks targeting within aster satellite image**. [S.l.: s.n.], 2017. (2).
- NIBLACK, W. **An introduction to digital image processing**. [S.l.]: Strandberg Publishing Company, 1985.
- NOBLE, W. S. What is a support vector machine? **Nature biotechnology**, [S.l.], v. 24, n. 12, p. 1565–1567, 2006.
- NYBERG, B.; NIXON, C. W.; SANDERSON, D. J. Networkgt: a gis tool for geometric and topological analysis of two-dimensional fracture networks. **Geosphere**, [S.l.], v. 14, n. 4, p. 1618–1634, aug 2018.
- OTSU, N. A threshold selection method from gray-level histograms. **IEEE transactions on systems, man, and cybernetics**, [S.l.], v. 9, n. 1, p. 62–66, 1979.
- PAGE, M. J. et al. The prisma 2020 statement: an updated guideline for reporting systematic reviews. **Systematic reviews**, [S.l.], v. 10, n. 1, p. 1–11, 2021.

- PAL, S.; GULLI, S. **Deep learning with keras**: implementing deep learning models and neural networks with the power of python. [S.l.]: Packt Publishing, 2017.
- PEACOCK, D. C. et al. Glossary of fault and other fracture networks. **Journal of Structural Geology**, [S.l.], v. 92, p. 12–29, nov 2016.
- PESSOA NETO, O. d. C. et al. Bacia potiguar. **Boletim de Geociências da PETROBRÁS**, [S.l.], v. 15, n. 2, p. 357–369, 2007.
- PHANSALKAR, N. et al. Adaptive local thresholding for detection of nuclei in diversity stained cytology images. In: INTERNATIONAL CONFERENCE ON COMMUNICATIONS AND SIGNAL PROCESSING, 2011., 2011. **Anais...** [S.l.: s.n.], 2011. p. 218–220.
- PI, Z. et al. Digital image processing method for characterization of fractures, fragments, and particles of soil/rock-like materials. **Mathematics**, [S.l.], v. 9, n. 8, 2021.
- POLLARD, D. D.; AYDIN, A. Progress in understanding jointing over the past century. **Geological Society of America Bulletin**, [S.l.], v. 100, n. 8, p. 1181–1204, 1988.
- POWELL, K. R.; PETERSON, S. R. Coverage and quality: a comparison of web of science and scopus databases for reporting faculty nursing publication metrics. **Nursing outlook**, [S.l.], v. 65, n. 5, p. 572–578, 2017.
- PRABHAKARAN, R. et al. An automated fracture trace detection technique using the complex shearlet transform. **Solid Earth Discussions**, [S.l.], p. 1–40, 2019.
- PRINGLE, J. K. et al. Virtual outcrop models of petroleum reservoir analogues: a review of the current state-of-the-art. **First Break**, [S.l.], v. 24, n. 3, p. 33–42, 2006.
- QUAN, S. et al. Scattering feature-driven superpixel segmentation for polarimetric sar images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S.l.], v. 14, p. 2173–2183, 2021.
- RABELO, J. G. et al. Karstification and fluid flow in carbonate units controlled by propagation and linkage of mesoscale fractures, Jandaíra Formation, Brazil. **Geomorphology**, [S.l.], v. 357, 2020.
- RACOLTE, G. et al. Spherical k-means and elbow method optimizations with fisher statistics for 3d stochastic dfn from virtual outcrop models. **IEEE Access**, [S.l.], v. 10, p. 63723–63735, 2022.
- RIZZO, R. E. et al. Riding the right wavelet: quantifying scale transitions in fractured rocks. **Geophysical Research Letters**, [S.l.], v. 44, n. 23, p. 11,808–11,815, 2017.
- ROBERTS, L. G. **Machine perception of three-dimensional solids**. 1963. Tese (Doutorado em Ciência da Computação) — Massachusetts Institute of Technology, 1963.
- ROBINSON, G. S. Edge detection by compass gradient masks. **Computer graphics and image processing**, [S.l.], v. 6, n. 5, p. 492–501, 1977.
- ROGERS, S. et al. Integrating photogrammetry and discrete fracture network modelling for improved conditional simulation of underground wedge stability. In: DEEP MINING 2017: EIGHTH INTERNATIONAL CONFERENCE ON DEEP AND HIGH STRESS MINING, 2017. **Anais...** [S.l.: s.n.], 2017. p. 599–610.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: convolutional networks for biomedical image segmentation. In: LECTURE NOTES IN COMPUTER SCIENCE (INCLUDING SUBSERIES LECTURE NOTES IN ARTIFICIAL INTELLIGENCE AND LECTURE NOTES IN BIOINFORMATICS), 2015. **Anais...** [S.l.: s.n.], 2015.

RUSS, J. C. The image processing handbook. **Microscopy and Microanalysis**, [S.l.], v. 17, n. 5, p. 843, 2007.

SÆVIK, P. N.; NIXON, C. W. Inclusion of Topological Measurements into Analytic Estimates of Effective Permeability in Fractured Media. **Water Resources Research**, [S.l.], v. 53, n. 11, p. 9424–9443, 2017.

SALVINI, R. et al. The use of an unmanned aerial vehicle for fracture mapping within a marble quarry (carrara, italy): photogrammetry and discrete fracture network modelling. **Geomatics, Natural Hazards and Risk**, [S.l.], v. 8, n. 1, p. 34–52, 2017.

SANDERSON, D. J.; NIXON, C. W. The use of topology in fracture network characterization. **Journal of Structural Geology**, [S.l.], v. 72, p. 55–66, 2015.

SANTOSO, R.; HE, X.; HOTEIT, H. Application of machine-learning to construct simulation models from high-resolution fractured formation. In: SOCIETY OF PETROLEUM ENGINEERS - ABU DHABI INTERNATIONAL PETROLEUM EXHIBITION AND CONFERENCE 2019, ADIP 2019, 2019. **Anais...** [S.l.: s.n.], 2019.

SAUVOLA, J.; PIETIKAK, M. **Adaptive document image binarization**. [S.l.: s.n.], 2000.

SEERS, T. D.; HODGETTS, D. Comparison of digital outcrop and conventional data collection approaches for the characterization of naturally fractured reservoir analogues. **Geological Society Special Publication**, [S.l.], v. 374, n. 1, p. 51–77, 2014.

SINGH, S.; GUPTA, P. Comparative study id3, cart and c4. 5 decision tree algorithm: a survey. **International Journal of Advanced Information Science and Technology (IJAIST)**, [S.l.], v. 27, n. 27, p. 97–103, 2014.

SINGH, T. et al. A new local adaptive thresholding technique in binarization. **IJCSI International Journal of Computer Science Issues**, [S.l.], v. 8, n. 6, 2011.

SINGH, T. R. et al. A new local adaptive thresholding technique in binarization. **arXiv preprint arXiv:1201.5227**, [S.l.], 2012.

SKANSI, S. **Introduction to deep learning: from logical calculus to artificial intelligence**. [S.l.]: Springer, 2018.

SOUZA, E. M. de et al. How Much Wavelet Decomposition can Improve the Detection of Surface Fractures in Remote Sensing Images? In: IGARSS 2020 - 2020 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2020. **Anais...** IEEE, 2020. p. 2619–2622.

STEGER, C. Extraction of curved lines from images. In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, 1996. **Proceedings...** [S.l.: s.n.], 1996. v. 2, p. 251–255.

STEGER, C. An unbiased detector of curvilinear structures. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S.l.], v. 20, n. 2, p. 113–125, 1998.

STEGER, C. **SUBPIXEL-PRECISE EXTRACTION OF LINES AND EDGES**. [S.l.: s.n.], 2000.

Stephen Mak B.A.Sc, b. W. **ASSESSING FRACTURE NETWORK CONNECTIVITY OF PREFEASIBILITY-LEVEL HIGH TEMPERATURE GEOTHERMAL PROJECTS USING DISCRETE FRACTURE NETWORK MODELLING**. [S.l.: s.n.], 2014.

SZELISKI, R. Computer vision: algorithms and applications. **Choice Reviews Online**, [S.l.], v. 48, n. 09, p. 48–5140–48–5140, 2011.

TELLING, J. et al. Review of Earth science research using terrestrial laser scanning. **Earth-Science Reviews**, [S.l.], v. 169, p. 35–68, jun 2017.

THIELE, S. T. et al. Rapid, semi-automatic fracture and contact mapping for point clouds, images and geophysical data. **Solid Earth**, [S.l.], 2017.

TIAN, X.; DAIGLE, H. Machine-learning-based object detection in images for reservoir characterization: a case study of fracture detection in shales. **Leading Edge**, [S.l.], v. 37, n. 6, p. 435–442, 2018.

TIBANA, P.; TERRA, G. Seqüências carbonáticas do cretáceo na bacia potiguar. **Boletim Técnico da Petrobrás**, [S.l.], v. 24, n. 3, p. 174–183, 1981.

TOMASI, C.; MANDUCHI, R. Bilateral filtering for gray and color images. **Proceedings of the 1998 IEEE International Conference on Computer Vision**, [S.l.], 1998.

TURNER, D.; LUCIEER, A.; WATSON, C. An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (uav) imagery, based on structure from motion (sfm) point clouds. **Remote sensing**, [S.l.], v. 4, n. 5, p. 1392–1410, 2012.

VARGAS-MUNOZ, J. E. et al. An Iterative Spanning Forest Framework for Superpixel Segmentation. **IEEE Transactions on Image Processing**, [S.l.], v. 28, n. 7, p. 3477–3489, 2019.

VASUKI, Y. et al. Semi-automatic mapping of geological structures using uav-based photogrammetric data: an image analysis approach. **Computers & Geosciences**, [S.l.], v. 69, p. 22–32, aug 2014.

VERHOEVEN, G. Taking computer vision aloft—archaeological three-dimensional reconstructions from aerial photographs with photoscan. **Archaeological prospection**, [S.l.], v. 18, n. 1, p. 67–73, 2011.

VOLLGGER, S. A. et al. Review of drones, photogrammetry and emerging sensor technology for the study of dykes: best practises and future potential. **Journal of Volcanology and Geothermal Research**, [S.l.], 2019.

WANG, W. An edge based segmentation algorithm for rock fracture tracing. In: CONFERENCE ON COMPUTER GRAPHICS, IMAGING AND VISION: NEW TRENDS 2005, 2005. **Proceedings...** [S.l.: s.n.], 2005. v. 2005, p. 43–48.

WANG, W. et al. Rock fissure pattern characterization by combining 1-D fractal dimension and statistical analysis. **IEEE/CAA Journal of Automatica Sinica**, [S.l.], 2017.

WANG, W. et al. Crack and Fracture central line delineation on Steger and Hydrodynamics with improved Fractional differential. **International Journal of Wavelets, Multiresolution and Information Processing**, [S.l.], v. 18, n. 5, p. 1–21, 2020.

WANG, W.; HAKAMI, E. A segmentation algorithm for rock fracture detection. In: LECTURE NOTES IN COMPUTER SCIENCE, 2005. **Anais...** [S.l.: s.n.], 2005. v. 3687, n. PART II, p. 580–588.

WANG, W.; LIANG, Y. Rock fracture centerline extraction based on hessian matrix and steger algorithm. **KSII Transactions on Internet and Information Systems**, [S.l.], v. 9, n. 12, p. 5073–5086, 2015.

WANG, W.; WAN, J.; YANG, Z. Rock fracture extracting on fractional differential. In: INTERNATIONAL WORKSHOP ON INTELLIGENT SYSTEMS AND APPLICATIONS, ISA 2010, 2010., 2010. **Proceedings...** [S.l.: s.n.], 2010.

WANG, W. X.; LI, W. S.; YU, X. Fractional differential algorithms for rock fracture images. **Imaging Science Journal**, [S.l.], v. 60, n. 2, p. 103–111, 2012.

WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. **IEEE transactions on image processing**, [S.l.], v. 13, n. 4, p. 600–612, 2004.

WATKINS, H. et al. Appraisal of fracture sampling methods and a new workflow to characterise heterogeneous fracture networks at outcrop. **Journal of Structural Geology**, [S.l.], v. 72, p. 67–82, 2015.

WEISMÜLLER, C. et al. Mapping the fracture network in the lilstock pavement, bristol channel, uk: manual versus automatic. **Solid Earth**, [S.l.], v. 11, n. 5, p. 1773–1802, 2020.

WEIXING, W.; HAIJUN, L.; YING, H. Rock fracture tracing based on image processing and SVM. In: THIRD INTERNATIONAL CONFERENCE ON NATURAL COMPUTATION, ICNC 2007, 2007. **Proceedings...** [S.l.: s.n.], 2007. v. 1, p. 632–635.

WESTOBY, M. J. et al. 'structure-from-motion' photogrammetry: a low-cost, effective tool for geoscience applications. **Geomorphology**, [S.l.], v. 179, p. 300–314, dec 2012.

XU, C.; DOWD, P. A new computer code for discrete fracture network modelling. **Computers and Geosciences**, [S.l.], 2010.

YAMASHITA, R. et al. Convolutional neural networks: an overview and application in radiology. **Insights into imaging**, [S.l.], v. 9, n. 4, p. 611–629, 2018.

YANOWITZ, S. D.; BRUCKSTEIN, A. M. A new method for image segmentation. **Computer Vision, Graphics, and Image Processing**, [S.l.], v. 46, n. 1, p. 82–95, 1989.

YAO, J.-P.; WANG, W.-X. Color image segmentation of rock fracture stuffing base on image fusion. In: SPIE - THE INTERNATIONAL SOCIETY FOR OPTICAL ENGINEERING, 2006. **Proceedings...** [S.l.: s.n.], 2006. v. 6199.

YIN, J. et al. Slic superpixel segmentation for polarimetric sar images. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], v. 60, p. 1–17, 2021.

ZASIŃSKI, P.; KOCIŃSKI, M.; MATERKA, A. On extracting skeletons from binary 3d images. In: INTERNATIONAL CONFERENCE ON SYSTEMS, SIGNALS AND IMAGE PROCESSING (IWSSIP), 2017., 2017. **Anais...** [S.l.: s.n.], 2017. p. 1–5.

ZEEB, C. et al. Evaluation of Sampling methods for fracture network characterization using Outcrops. **AAPG Bulletin**, [S.l.], v. 97, n. 9, p. 1545–1566, 2013.

ZENG, Q.-H. et al. Automatic Extraction of Fractures in Digital Geological Outcrop of Carbonate Rocks and Its Application. **Springer Series in Geomechanics and Geoengineering**, [S.l.], p. 2297–2309, 2020.

ZENG, Q.; ZHANG, H.; LU, W. Fracture patterns and controlling factors using lidar: an outcrop case study of kuqa depression, tarim basin, nw china. In: SOCIETY OF PETROLEUM ENGINEERS - ABU DHABI INTERNATIONAL PETROLEUM EXHIBITION AND CONFERENCE 2016, 2016. **Anais...** [S.l.: s.n.], 2016. v. 2016-Janua.

ZHANG, T.; SUEN, C. Y. A fast parallel algorithm for thinning digital patterns. **Communications of the ACM**, [S.l.], v. 27, n. 3, p. 236–239, 1984.


ZUO, L. et al. Fracture Detection and Numerical Modeling for Fractured Reservoirs. **Energies**, [S.l.], v. 12, n. 3, p. 386, 2019.

APÊNDICE A – TRABALHOS ADICIONAIS DESENVOLVIDOS

A.1 Extração de fraturas como vales/curvas e estimativa de abertura


Além da extração de fraturas como linhas, foram investigadas abordagens para extração das fraturas como curvas e também para permitir estimar a abertura das mesmas. Algumas metodologias, tais como decomposição *wavelet* (NASON; SILVERMAN, 1995), geometria diferencial (STEGER, 2000) e curvatura gaussiana, foram integradas para aproveitar as vantagens de cada abordagem e atingir melhores resultados. Utilizando geometria diferencial a partir do algoritmo de *Steger* os centros e aberturas das fraturas foram estimados, conforme apresentado na Figura 50, onde as conectividades entre as fraturas são também estimadas (Figura 51)

Figura 50: Estimativa da abertura de fratura considerando uma abertura máxima de 30cm.



Fonte: Elaborado pelo autor.

Figura 51: Identificação de nodos por algoritmo de Steger para a estimativa da conectividade entre as fraturas.

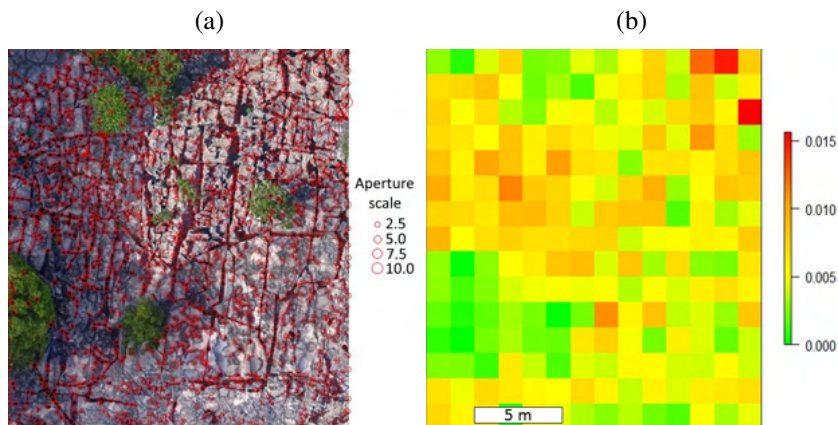


Fonte: Elaborado pelo autor.

Vale ressaltar que as informações de abertura ilustradas na Figura 50 são estimadas para

cada ponto e por fratura. Entretanto, no caso em que deseja-se estimar as aberturas das fraturas em determinadas áreas (janelas amostrais), pode-se utilizar a metodologia de decomposição *wavelet* e Curvatura Gaussiana, a qual permite que tais estimativas sejam obtidas de modo bastante rápido. A Figura 52 mostra este resultado.

Figura 52: Estimativa da abertura por área obtida a partir da metodologia de decomposição em *wavelet* e Curvatura Gaussiana.

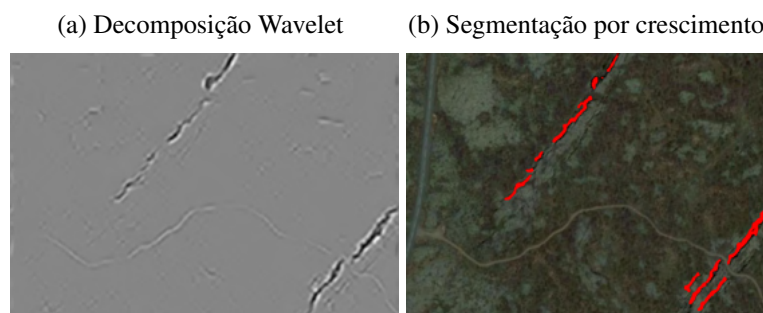


Fonte: Elaborado pelo autor.

A partir das estatísticas e medidas geométricas de fraturas apresentadas anteriormente, é possível calcular outras medidas geométricas, tais como coeficientes de rugosidade, e posteriormente, o coeficiente de rugosidade mecânico de Barton (*Joint Roughness Coefficient - JRC*).

Em trabalho publicado em (SOUZA et al., 2020), a técnica de segmentação e de estimativa de aberturas utilizando decomposição *wavelet* e matriz *Hessiana* (matriz de derivadas parciais de segunda ordem) foi aplicada na detecção de falhas e quantificação de aberturas em imagens de satélite de Thingvellir na Islândia. A metodologia foi complementada por uma técnica de crescimento por região de modo a obter o preenchimento total de cada fratura como apresentado na Figura 53.

Figura 53: Segmentação de fraturas em escalas regionais em imagens de satélite de Thingvellir-Islandia.



Fonte: Adaptado de Souza et al. (2020).