



SEGMENTAÇÃO SEMÂNTICA PARA INTERPRETAÇÃO AUTOMÁTICA DE ESTRUTURAS GEOLÓGICAS LINEARES

Davi Bortolotti Batista

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação, do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, CEFET/RJ, como parte dos requisitos necessários à obtenção do título de mestre.

Orientador(a): D.Sc. Diego Barreto Haddad
Coorientador(a): D.Sc. Gabriel Matos de Araujo

Rio de Janeiro,

Janeiro 2022

SEGMENTAÇÃO SEMÂNTICA PARA INTERPRETAÇÃO AUTOMÁTICA DE
ESTRUTURAS GEOLÓGICAS LINEARES

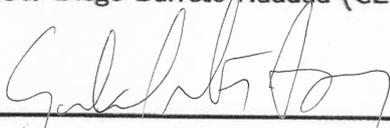
Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação, do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, CEFET/RJ, como parte dos requisitos necessários à obtenção do título de mestre.

Davi Bortolotti Batista

Banca Examinadora:



Presidente, Professor D.Sc. Diego Barreto Haddad (CEFET/RJ) (Orientador(a))



Professor D.Sc. Gabriel Matos de Araujo (CEFET/RJ) (Coorientador(a))



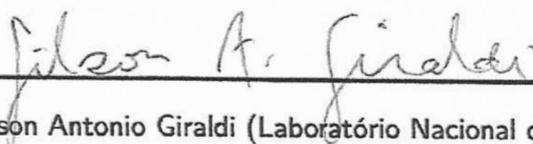
Professor D.Sc. Douglas de Oliveira Cardoso (CEFET/RJ)



Professora D.Sc. Milena Faria Pinto (CEFET/RJ)



Professor D.Sc. Kenji Nose Filho (Universidade Federal do ABC Paulista)



Professor D.Sc. Gilson Antonio Giraldi (Laboratório Nacional de Computação Científica)

Ficha catalográfica elaborada pela Biblioteca Central do CEFET/RJ

B333 Batista, Davi Bortolotti
Segmentação ao semântica para interpretação automática de estruturas geológicas lineares / Davi Bortolotti Batista. — 2022.
65f. : il. (algumas color.) , enc.

Dissertação (Mestrado) Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, 2022.

Bibliografia : f. 58-65

Orientador: Diego Barreto Haddad

Coorientador: Gabriel Matos de Araujo

1. Mecânica do solo. 2. Redes neurais (Computação). 3. Geologia. 4. Drones. 5. Visão por computador. I. Haddad, Diego Barreto (Orient.). II. Araujo, Gabriel Matos de (Coorient.). III. Título.

CDD 625.732

DEDICATÓRIA

Aos meus amigos da Geologia, com os quais dividi inúmeros trabalhos de campo e experiências que levarei para toda minha vida. Ao grande amor de minha vida, Petrina. Ao meu grande amigo e irmão, Leandro Romano.

AGRADECIMENTOS

O presente trabalho foi desenvolvido com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

Agradeço também ao meu orientador, Diego, e ao meu co-orientador, Gabriel, profissionais extremamente didáticos, dedicados, disponíveis e prestativos. Ao meu colega Vitor Lamy Savastano, sem o qual esta pesquisa não teria sido possível. Aos meus amigos e esposa, que me aconselharam e deram forças para seguir até o fim.

RESUMO

Segmentação Semântica para Interpretação Automática de Estruturas Geológicas Lineares

A interpretação automática de estruturas geológicas pode agilizar a etapa de trabalho de campo necessária na geotecnia, engenharia civil e na exploração de recursos naturais como petróleo, água e minério, provendo aos geocientistas um maior volume de informações advindas de afloramentos rochosos. Parâmetros geológicos enriquecem e melhoram a capacidade preditiva dos modelos geológicos numéricos e estatísticos. As fraturas geológicas são de grande interesse pois indicam regimes de tensões pretéritos e atualmente ocorrentes na litosfera terrestre, além de serem canais preferenciais de fluidos economicamente importantes.

Este trabalho propõe uma nova metodologia combinando aprendizado profundo, segmentação semântica e algoritmos clássicos de visão computacional para interpretação de estruturas geológicas lineares de imagens de Veículos Aéreos Não Tripulados VANT. Resultados mostraram métricas de Interseção sobre União (IoU, do inglês *Intersection over Union*) de até 74% para os resultados do modelo treinado antes do pós-processamento, e até 78% depois. A segmentação predita foi usada como máscara para binarização e detecção de linhas para extrair fraturas com precisão. A comparação de direções de *strike* oriundas da interpretação geológica e oriundas das estruturas extraídas automaticamente exibiu tendências e comportamentos muito similares. Os resultados foram comparados com outras técnicas historicamente usadas na área de geo-processamento e com anotações manualmente executadas pelos geocientistas, demonstrando precisão maior e visíveis vantagens.

Palavras-chave: Fraturas, Aprendizado Profundo, Redes Neurais Convolucionais, Geologia Estrutural, Imagens Aéreas

ABSTRACT

Semantic Segmentation for Automatic Interpretation of Linear Geological Structures

Automatic interpretation of geological structures may speed up the fieldwork stage necessary in geotechnics, civil engineering and in the exploration of natural resources, such as oil, water and ore, providing geoscientists with a larger volume of data from rock outcrops. Geological parameters enrich and improve predictive capacity of geological numeric and statistic models. The geological fractures are of great interest, for they indicate past and presently occurring stress regimes in the Earth's lithosphere, besides forming preferential ducts of economically important fluids.

This work proposes a new methodology combining deep learning, semantic segmentation and classic computer vision algorithms for the extraction of linear geological structures from *Unmanned Aerial Vehicle* (UAV) imagery. Results show Intersection over Union (IoU) metrics of up to 74% for trained model predictions before post-processing, and up to 78% after. The predicted segmentation was used as a mask for binarization and line detection to extract fractures accurately. The comparison of strike directions originated from geological interpretation and from automatically extracted structures exhibited very similar trends and behaviors. The results were then compared with other historically used techniques in the geoprocessing area and with the manually executed annotations from geoscientists, demonstrating larger precision and advantages.

Keywords: Fractures, Deep Learning, Convolutional Neural Networks, Structural Geology, Aerial Imagery

LISTA DE ILUSTRAÇÕES

Figura 1 –	Lineamentos (em vermelho) em imagens de satélite e modelos digitais de elevação. Adaptado de Han et al. [2018].	17
Figura 2 –	Mosaico de imagens de VANT adquirido para construção do conjunto de dados.	19
Figura 3 –	Faturas cisalhantes em um afloramento gnáissico. Fonte: Fossen [2010].	23
Figura 4 –	Conjunto de falhas geológicas em um corpo rochoso. Note os planos onde há deslocamento oblíquo das diferentes camadas rochosas. Fonte: Fossen [2010].	23
Figura 5 –	Bloco diagrama de um plano de falha indicando a direção de <i>strike</i> e o mergulho do plano (<i>dip</i>).	24
Figura 6 –	Modelagem estrutural das falhas geológicas de um reservatório em planos para posterior uso no modelo preditivo de produção de petróleo. Fonte: Giuffrida et al. [2019].	25
Figura 7 –	<i>Grid</i> de permeabilidade empregando dados estruturais para simular o comportamento rochoso. Note a diagonal representando uma fratura geológica onde os valores de permeabilidade são mais expressivos. Adaptado de Giuffrida et al. [2019].	26
Figura 8 –	Imagem do conjunto de dados utilizado processada pelos diferentes algoritmos de visão computacional explorados na pesquisa. a) Imagem original. b) Algoritmo de Canny. c) Limiarização adaptativa gaussiana. d) Detecção de segmentos lineares.	29
Figura 9 –	Diferentes operações de análise de morfologia aplicadas a uma imagem binária usando um elemento estruturante quadrado.	32

- Figura 10 – Diagrama exemplificando a arquitetura Densenet. A_0 representa a imagem de entrada e H as transformações compostas por *Batch normalization*, *ReLU* e a convolução 3×3 . Adaptado de Huang et al. [2017]. 35
- Figura 11 – Localização da área de estudo. a) A localização da área de estudo na América do Sul. b) Localização da área no leste do estado do Rio de Janeiro, no município de Cabo Frio. c) Localização da Praia das Conchas, com os afloramentos norte e sul utilizados na análise. Extraído do Google Maps, por Google. 41
- Figura 12 – Fluxo da metodologia para extração de fraturas por segmentação semântica e pós-processamento. 42
- Figura 13 – Processamento de estruturas geológicas interpretadas para treinamento do modelo de segmentação. a) Imagem original; b) Imagem original sobreposta pelos lineamentos interpretados; c) Interpretação geológica convertida para *pixels*, sem dilatação, com 1 *pixel* de largura; d) Estruturas após dilatação por análise de morfologia utilizando um *kernel* de 4×4 *pixels*, para o treinamento do modelo. 44
- Figura 14 – Curva de perda de Dice do modelo DenseNet de 161 camadas, mostrando estabilização da curva de perda ao redor da época 40. 46
- Figura 15 – Curva de perda de *Cross Entropy* do modelo DenseNet de 264 camadas. 47
- Figura 16 – Etapa de dilatação do pós-processamento usando um *kernel* 10×10 para cobertura das geometrias reais das fraturas na imagem. a) Sobreposição da imagem original com a máscara gerada pelo modelo DenseNet com 264 camadas. b) Mesma máscara, após dilatação. 48
- Figura 17 – Resultados do modelo de segmentação semântica e pós-processamento. a) Imagem original. b) Anotações de *ground truth*. c) Segmentação predita gerada pelo modelo DenseNet 264. d) Resultado usando o fluxo de trabalho de pós-processamento proposto nas predições do modelo Densenet 264. e) Segmentação predita pelo modelo DenseNet 161. f) Resultado com pós-processamento na predição do modelo DenseNet 161. 49

- Figura 18 – Resultados do modelo de segmentação e pós-processamento, comparativamente a algoritmos de visão computacional clássicos. a) Imagem original. b) *Ground truth*. c) Resultados finais usando segmentação pela rede DenseNet 161 seguida de pós processamento proposto. d) Resultados finais usando segmentação pela rede DenseNet 264 seguida de pós processamento proposto. e) Segmentação baseada em reconhecimento de bordas Canny. f) Segmentação baseada em binarização a partir de limiarização adaptativa gaussiana. 51
- Figura 19 – Comparação entre as máscaras oriundas dos modelos DenseNet. a) Predição do modelo DenseNet com 161 camadas. b) Predição do modelo Densenet com 264 camadas. 53
- Figura 20 – a-c). Uso de extração de segmentos lineares a partir de visão computacional, como aplicado no pós-processamento, na imagem original inteira. b-d). Uso da mesma metodologia, porém apenas no interior das máscaras resultantes da segmentação semântica pelo modelo DenseNet com 264 camadas. 54
- Figura 21 – a) Predição do modelo DenseNet com 161 camadas, com interpretação das estruturas ocorrendo em blocos soltos. b) Resultado do modelo Densenet com 264 camadas, sem a interpretação nos blocos. 55
- Figura 22 – Comparação entre as máscaras pós-processadas dos modelos DenseNet. a) Resultado do modelo DenseNet com 161 camadas. b) Resultado do modelo Densenet com 264 camadas. 55
- Figura 23 – Diagramas de roseta, à esquerda, exibindo direções de *strike* das estruturas oriundas do conjunto de avaliação e das predições dos modelos de segmentação semântica, e os histogramas, à direita, de suas distribuições de comprimentos. 57

LISTA DE TABELAS

- Tabela 1 – Comparação entre metodologias e fonte de imagens. Notação: STA: Segment Tracing Algorithm. START: Segment Tracing And Rotation Transformation. DCC: Detecção de Contornos de Canny. TH: Transformada Hough. CG: Congruência. SF: Simetria de fases. TV: Votação de tensores. WT: Transformada *Wavelet*. B: Binarização. LAG: Limiarização Adaptativa gaussiana. DSL: Detecção de segmentos lineares. CNN: Convolutional Neural *Convolutional Neural Network*. *Baseada em segmentação semântica. 40
- Tabela 2 – Interseção sobre união (IoU) dos resultados das diferentes técnicas de segmentação utilizadas nas imagens brutas. *Modelo Densenet com 161 e 264 camadas. **Com a etapa de dilatação do pós-processamento. 52
- Tabela 3 – Estatísticas das estruturas extraídas e do dado de referência. Note que todas as metodologia de extração produzem número de fraturas maior que o dado de referência. 56

LISTA DE ALGORITMOS

Algoritmo 1 – Algoritmo de remoção de pequenos objetos para retirada de artefatos 33

LISTA DE ABREVIATURAS E SIGLAS

- CNN** *Convolutional Neural Network*. 18
- DFN** *Discrete Fracture Network*. 25
- DSL** *Detecção de Segmentos Lineares*. 38, 39
- FCN** *Fully Convolutional Network*. 33, 34
- IoU** *Intersection over Union*. 52, 53, 58
- MDE** *Modelo Digital de Elevação*. 37
- MSLD** *Mean–standard Deviation Line Descriptor*. 30
- PCA** *Principal Components Analysis*. 38
- PSR** *Pixel Support Region*. 30
- STA** *Segment Tracing Algorithm*. 37
- SVM** *Support Vector Machine*. 39
- VANT** *Veículo Aéreo Não Tripulado*. 17–19, 25, 28, 39–41, 59

SUMÁRIO

Introdução	16
1 Introdução	16
1.1 Contextualização	16
1.2 Motivação	17
1.3 Objetivos	18
1.4 Metodologia	19
1.5 Organização dos Capítulos	20
2 Referencial Teórico	21
2.1 Conceitos de Geologia	21
2.1.1 Geologia Estrutural	21
2.1.2 A Importância da Geologia Estrutural	22
2.1.3 Terminologia da Geologia Estrutural	22
2.1.4 Modelagem Geológica Estrutural e Redes de Fraturas Discretas	24
2.1.5 Lineamentos	25
2.2 Algoritmos de Visão Computacional	26
2.2.1 Algoritmo de Canny	27
2.2.2 Limiarização Adaptativa Gaussiana	28
2.2.3 Detecção de Segmentos Lineares	30
2.2.4 Análise de Morfologia	30
2.2.5 Remoção de Pequenos Objetos	32
2.2.6 Segmentação Semântica	33
2.3 Comentários Finais	36
3 Revisão Bibliográfica	37
3.1 Lineamentos em Dados de Satélite	37
3.2 Imagens de VANT	39

3.3	Comentários Finais	40
4	Aplicação	41
4.1	Conjunto de Dados	41
4.2	Metodologia	42
4.2.1	Dado de Referência	43
4.2.2	Segmentação Semântica	44
4.2.3	Pós-processamento	47
4.2.4	Comparação com outras técnicas de visão computacional	50
4.3	Comentários Finais	50
5	Resultados	52
5.1	Comentários Finais	56
6	Conclusões	58
6.1	Trabalhos Futuros	59
	Referências	59

1- Introdução

1.1- Contextualização

A interpretação de lineamentos e estruturas geológicas a partir de imagens aéreas é um dos mais importantes complementos à atividade de mapeamento geológico de uma área, bem como à sua descrição. As informações obtidas por meio de imagens de satélite (ou mesmo fotografias capturadas por aviões) são utilizadas há décadas para entendimento em maior escala de uma região e para a identificação de potenciais pontos de interesse: para atividades econômicas, ao indicar potenciais minas e poços de petróleo [Nguemhe Fils et al., 2018]; para engenharia e meio ambiente, identificando áreas de risco ou possíveis direções preferenciais das tensões das rochas e do solo [Ciampalini et al., 2019; Menegoni et al., 2019]; e para atividade acadêmica, no entendimento do contexto geológico, geomorfológico e geográfico de uma área [Nash et al., 1996; Heathfield and Walker, 2015; Fagbohun et al., 2017; Aslett et al., 2018; Deffontaines et al., 2019].

Lineamentos são características lineares, seja naturais ou artificiais. Enquanto aquelas são originárias de formações geológicas, estas, derivadas da intervenção humana, compreendem rodovias, limites de território (como fazendas, ou áreas urbanas) e canais de drenagem lineares [Hashim et al., 2013]. Neste caso, os lineamentos naturais são de interesse das geociências, uma vez que podem representar características das rochas de determinada região. Portanto, a extração de lineamentos naturais de imagens óticas demanda a interpretação de profissionais experientes, sem excluir tarefas cruciais de pré-processamento ou mesmo de pós-processamento de imagens. A Figura 1 mostra exemplos da extração de lineamentos em modelos digitais de elevação e imagens de satélite.

Entretanto, como mencionado em Saint Jean Patrick Coulibaly et al. [2020], nuvens e vegetação podem impedir uma boa observação de lineamentos em imagens obtidas por satélites. Além disso, o processamento de imagens realizado manualmente introduz subjetividade, pois é dependente da habilidade e experiência do especialista executante da tarefa.

VANTs são uma solução notável para automatizar processos de forma pouco custosa e atualmente são empregados em uma vasta gama de aplicações, como inspeção [Biundini

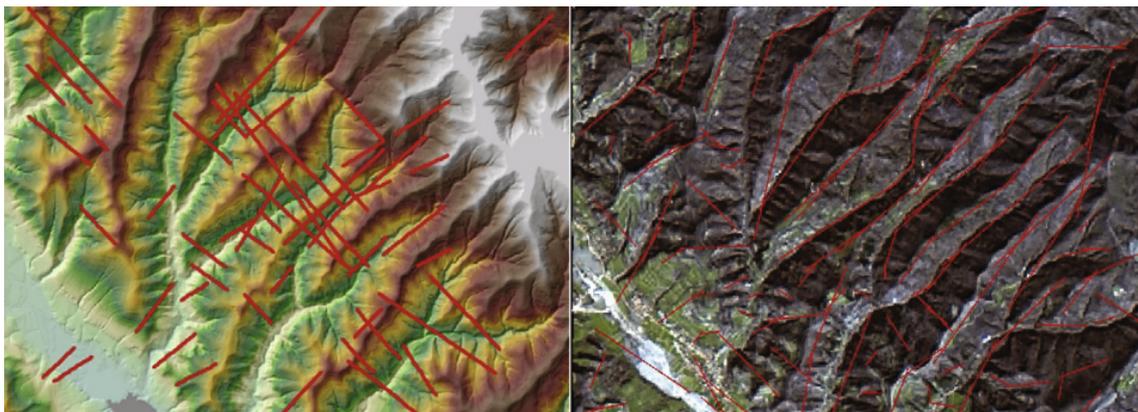


Figura 1 – Lineamentos (em vermelho) em imagens de satélite e modelos digitais de elevação. Adaptado de Han et al. [2018].

et al., 2021b], busca e resgate [Pinto et al., 2020; de Alcantara Andrade et al., 2019], entregas [Chiang et al., 2019], entre outras. O uso de imagens de VANTs possui diversas vantagens, que incluem aquisição mais barata que outros tipos de imageamento aéreo (como aviões, balões e satélites), e flexibilidade na aquisição, uma vez que o pesquisador pode simplesmente ir a campo e adquirir imagens [Biundini et al., 2021a] na resolução, escala e ângulo desejado para a tarefa em questão.

Nas geociências, as imagens obtidas por Veículos Aéreos Não Tripulados (VANTs) concorrem para aprimorar a coleta de dados geométricos e estruturais em áreas de difícil acesso. Ademais, os últimos avanços tanto em *software* quanto em *hardware* neste setor já ampliam sua aplicação em diversos campos, tal como o estudo de desmoronamentos e instabilidade de corpos rochosos [Salvini et al., 2017].

1.2- Motivação

Métodos para extração automática de lineamentos e estruturas envolvem o uso de algoritmos de visão computacional em imagens de satélite [Ahmadirouhani et al., 2017], ou a partir de modelos de elevação digitais [Raghavan et al., 1993] [Han et al., 2018] para obtenção de atributos lineares. Entretanto, há poucos trabalhos utilizando imagens em escala menor, como as oriundas de aquisição por VANTs.

O uso de imagens de VANTs tem muitas vantagens, como aquisição mais barata quando comparada a outros tipos de imagens aéreas, e flexibilidade, uma vez que o pesquisador pode ir

a campo e adquirir o dado na escala, resolução e ângulo que desejar e que for mais interessante para a tarefa em questão, capturando com precisão o tamanho e detalhe dos objetos de estudo [Biundini et al., 2021a].

Além disso, poucos trabalhos utilizam redes convolucionais para extração de lineamentos ou tarefas de sensoriamento remoto em geral [Lary et al., 2016], enquanto sabe-se que tais redes situam-se no estado da arte das técnicas de visão computacional: as redes convolucionais estão entre as melhores técnicas de aprendizado de máquinas para entendimento de conteúdo de imagens e mostram resultados exemplares em tarefas de classificação, segmentação e detecção, ganhando atenção de empresas importantes de tecnologia como Google, Amazon e Facebook [Jan et al., 2019]. A maioria dos grupos participantes de competições de processamento de imagens e visão computacional atualmente empregam modelos baseados em Redes Neurais Convolucionais, ou, em inglês, *Convolutional Neural Networks* (CNNs) [Khan et al., 2020].

A interpretação automática ou semiautomática de estruturas geológicas traz ganho de velocidade na etapa de estudo das rochas em afloramento, para entendimento dos processos específicos à litologia, ambiente de deposição, condições de temperatura, pressão e tempo, os quais são responsáveis por diferenças nas características geométricas ou na frequência e direção das estruturas presentes naqueles corpos rochosos.

Além disso, a adoção de parâmetros numéricos (ou mesmo qualitativos) da geologia estrutural, geralmente obtidos a partir do estudo de afloramentos rochosos ou reaproveitados de jazidas minerais e reservatórios de petróleo já explorados, enriquece e melhora a capacidade preditiva dos modelos geológicos, sendo portanto de grande interesse por parte de profissionais do meio petrolífero [Giuffrida et al., 2019].

1.3- Objetivos

A inspeção visual na análise de lineamentos apresenta alguns problemas, como a subjetividade introduzida pelo intérprete e a direção da fonte de iluminação, que limita os lineamentos detectados nas imagens de satélite. Portanto, a principal contribuição deste trabalho é uma nova metodologia para detecção automática de fraturas geológicas em imagens aéreas capturadas por VANTs, combinando CNNs para segmentação semântica e pós-processamento por algoritmos de visão computacional para extrair estruturas geológicas lineares.

Este trabalho também visou a construção de um banco de dados de imagens de VANTs (Figura 2) de afloramentos rochosos com suas respectivas máscaras de segmentação contendo interpretações de redes de fraturas geológicas, de forma a possibilitar o treino de um modelo de aprendizado de máquinas de segmentação semântica. E por fim, busca explorar diversos algoritmos de visão computacional para uma etapa de pós-processamento, a fim de melhorar a precisão da interpretação automática predita pelo modelo.



Figura 2 – Mosaico de imagens de VANT adquirido para construção do conjunto de dados.

Como resultado deste trabalho, serão construídos e comparados dois modelos de segmentação semântica, implementados a partir da arquitetura DenseNet com diferentes profundidades, capazes de analisar as imagens geradas por VANTs e prever máscaras de pixels que conteriam fraturas geológicas. A partir do pós-processamento, o usuário terá em mãos um mapa de fraturas para realização de análises estruturais quantitativas e qualitativas.

1.4- Metodologia

Esta dissertação propõe o uso de redes neurais profundas para segmentação semântica em soma a algoritmos clássicos de processamento de imagem e de identificação de segmentos de retas para a identificação das fraturas em imagens coletadas por VANTs. Para a criação do modelo, foi necessário gerar o dado de referência (*ground truth*) a partir da interpretação

geológica realizada por um especialista. Este dado, originalmente em forma de vetores de linha, foi convertido para *pixels* e subdividido em um mosaico de 1895 imagens, de forma a ser inserido no modelo como dado de treinamento e para sua avaliação.

Após o treinamento e avaliação dos modelos de segmentação semântica, realizou-se pós-processamento a partir de algoritmos de análise de morfologia, binarização por limiarização e limpeza de artefatos para aumento da precisão das geometrias e direções extraídas. Como passo final, o dado resultante foi transformado novamente em segmentos lineares vetoriais para comparação de azimutes com o dado original.

A título de comparação, duas outras técnicas para extração de estruturas lineares foram aplicadas nas sub-imagens do mosaico, e suas métricas de precisão computadas para medir como a metodologia proposta difere em resultados de demais técnicas.

1.5- Organização dos Capítulos

O Capítulo 2 desta dissertação trata do conhecimento teórico necessário para o entendimento e desenvolvimento deste trabalho, tanto relacionado à geologia, quanto aos algoritmos computacionais utilizados. Já o Capítulo 3 explora a bibliografia pretérita de trabalhos relacionados, tanto relativos à análise de lineamentos quanto à extração de fraturas. O Capítulo 4 explica a fundo as diversas etapas da metodologia proposta para a detecção de fraturas. A apresentação e comparação dos resultados das diversas técnicas está presente no Capítulo 5. Finalmente, o Capítulo 6 abarca as conclusões obtidas e futuros trabalhos propostos.

2- Referencial Teórico

2.1- Conceitos de Geologia

Esta Seção descreve sucintamente a área da geologia estrutural e seus importantes conceitos para o trabalho apresentado aqui, uma vez que a metodologia propõe a extração de feições estruturais de corpos rochosos em imagens de VANTs. Para isto, é abordado o significado das estruturas e o que são fraturas geológicas, assim como a importância do uso de atributos quantitativos e qualitativos oriundas do estudo da geologia estrutural em tarefas econômicas, como na simulação de reservatórios de petróleo. Além disso, define-se o termo 'lineamento' e sua importância na análise de imagens aéreas e dados de satélite, muito explorado na literatura.

2.1.1 Geologia Estrutural

A geologia estrutural, segundo Fossen [2010], tipicamente compreende a descrição, interpretação e observação de estruturas que podem ser encontradas e mapeadas em formações rochosas. A área de estudo visa entender dobras, falhas e outras estruturas deformacionais da litosfera, como se formam e por quê. As deformações resultantes dos regimes de tensão na superfície e subsuperfície terrestre dependem principalmente do material rochoso em questão, sua textura e sua estrutura. O termo deformação, na geologia estrutural, é definida pelo autor como qualquer mudança de forma ou formato de um corpo, seja por movimentos rotacionais e translacionais, mudança de volume ou distorção de suas dimensões.

2.1.2 A Importância da Geologia Estrutural

O estudo das estruturas geológicas permite a compreensão do papel crítico das entidades estruturais e de seus processos, ao controlar propriedades físicas das rochas. Segundo Lei et al. [2017], fraturas, como juntas, falhas e veios, são ubíquas em rochas crustais e compreendem redes complexas que dominam o comportamento hidrogeológico e geomecânico das rochas. O entendimento destas estruturas é relevante para muitos setores, como construção civil, sistemas geotermiais, produção de gás de folhelho (através do *fracking*), manejo de água subterrânea e armazenamento de materiais radioativos.

Na geologia de engenharia, as estruturas geológicas, como falhas, dobras, fraturas e descontinuidades em geral contribuem para estabilização ou desestabilização de encostas e taludes da rochas, dependendo das suas orientações e dos danos tectônicos associados [Stead and Wolter, 2015]. Na geologia do petróleo e hidrogeologia, a presença e frequência destas estruturas, e suas propriedades geométricas, resultam em dutos de canalização preferencial de fluidos e campos de tensão heterogêneos em subsuperfície [Mercuri et al., 2020]. Para entendimento destas, é necessário que se desenvolva modelos geológicos complexos para simulação numérica do comportamento das rochas.

2.1.3 Terminologia da Geologia Estrutural

O termo fratura, historicamente, possui várias conotações na geologia estrutural, mas tem sido, em tempos mais recentes, usado para designar uma heterogeneidade estrutural cujas superfícies opostas são deslocadas relativas uma a outra. O termo pode ser uma classificação mais ampla para descontinuidades em um material rochoso, abrangendo estruturas como juntas, veios, diques e falhas. Alguns autores, porém, restringem o termo para descontinuidades dilatantes ou oblíquas [Price and Cosgrove, 1990]. A Figura 3 exibe um exemplo de fratura com deformação cisalhante.

Falhas geológicas são definidas como estruturas planares ou zonais onde há deslocamento cisalhante em uma rocha (Figura 4). Contígua a este plano há a zona de dano da falha, que é o volume de deformação rúptil circunvizinhante e relacionado à deformação da estrutura em



Figura 3 – Fraturas cisalhantes em um afloramento gnáissico. Fonte: Fossen [2010].

si [Schultz and Fossen, 2008].



Figura 4 – Conjunto de falhas geológicas em um corpo rochoso. Note os planos onde há deslocamento oblíquo das diferentes camadas rochosas. Fonte: Fossen [2010].

O termo falha denomina, por vezes, apenas um plano, uma zona tabular de deformação intensa (também denominada núcleo da falha) ou uma estrutura mais abrangente composta

pelos planos de deslocamento, o material do núcleo da falhas e a zona de dano relacionada.

Outros termos importantes para a geologia estrutural são as medidas de *strike* (direção) e *dip* (mergulho) das estruturas. O termo *strike* refere-se a linha formada pela interseção de um plano horizontal com um plano inclinado, que no caso de uma estrutura geológica, é o mergulho desta estrutura. Os dois termos são ilustrados pela Figura 5.

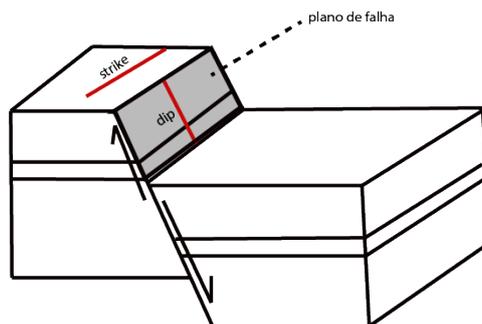


Figura 5 – Bloco diagrama de um plano de falha indicando a direção de *strike* e o mergulho do plano (*dip*).

2.1.4 Modelagem Geológica Estrutural e Redes de Fraturas Discretas

A dificuldade da representação destes sistemas tem várias razões, sendo algumas delas a natureza complexa das descontinuidades - cuja orientação, geometria e topologia depende de inúmeras variáveis, como profundidade da formação na crosta terrestre, regime de tensões geotectônicas e materiais geológicos onde se formam - e, na maioria das vezes, a impossibilidade de observação direta destas estruturas, pois geralmente se encontram em subsuperfície, e muitas vezes, a grandes profundidades.

Para contornar estes problemas, os geocientistas empregam diversas metodologias, como levantamentos sísmicos [Sohail et al., 2020] [Aabø et al., 2020] e perfilagens elétricas [Luo et al., 2019] [Lai et al., 2020] [Momeni et al., 2019] em poços perfurados, para entender a disposição destas estruturas. As limitações e a escala destes métodos, porém, limita o acesso à informação verdadeira contida nas rochas. Como extrapolação, o uso de afloramentos de rocha análogos [Siddiqui et al., 2019] [Del Sole et al., 2020] [Mercuri et al., 2020] e modelos

numéricos permite a aplicação de uma série de regras e padrões para previsão e modelagem 3D destas redes de fraturas [Giuffrida et al., 2019], gerando modelos conhecidos como Redes de Fraturas Discretas ou, em inglês, *Discrete Fracture Networks* (DFNs). A Figura 6 exemplifica a modelagem geológica de estruturas planares, como uma DFN. Estes modelos, por sua vez, são utilizados para construção de *grids* de modelagem contendo propriedades físicas, como porosidade e permeabilidade (como no exemplo da Figura 7), empregados para a predição de fluxo e volume dos fluidos, como hidrocarbonetos, nas rochas.

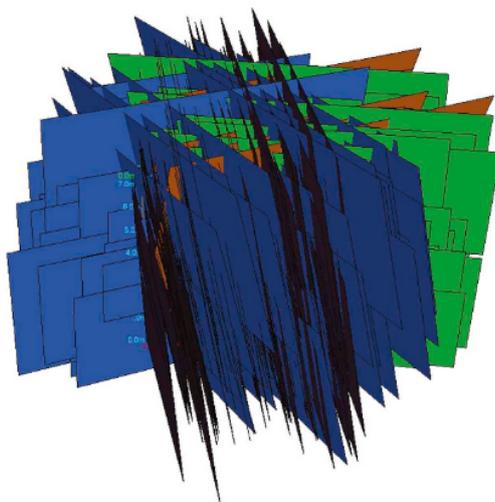


Figura 6 – Modelagem estrutural das falhas geológicas de um reservatório em planos para posterior uso no modelo preditivo de produção de petróleo. Fonte: Giuffrida et al. [2019].

Métricas como concentração de fraturas por metro quadrado, direções preferenciais, comprimento médio e as relações entre estas propriedades são medidas que podem ser extraídas de afloramentos geológicos, e pode ser executado de forma complementar em fotografias aéreas, como de aviões ou VANTs. Este dado, obtido de forma automática ou semiautomática gera agilidade e permite que o modelo compreenda um volume de dados muito maior do que da maneira clássica, a partir de mapeamento geológico *in-situ*.

2.1.5 Lineamentos

Na terra, lineamentos podem se manifestar como mudanças de tom do solo, depressões da superfície, vales e córregos retilíneos, mudanças de tipo ou altura da vegetação e mudanças

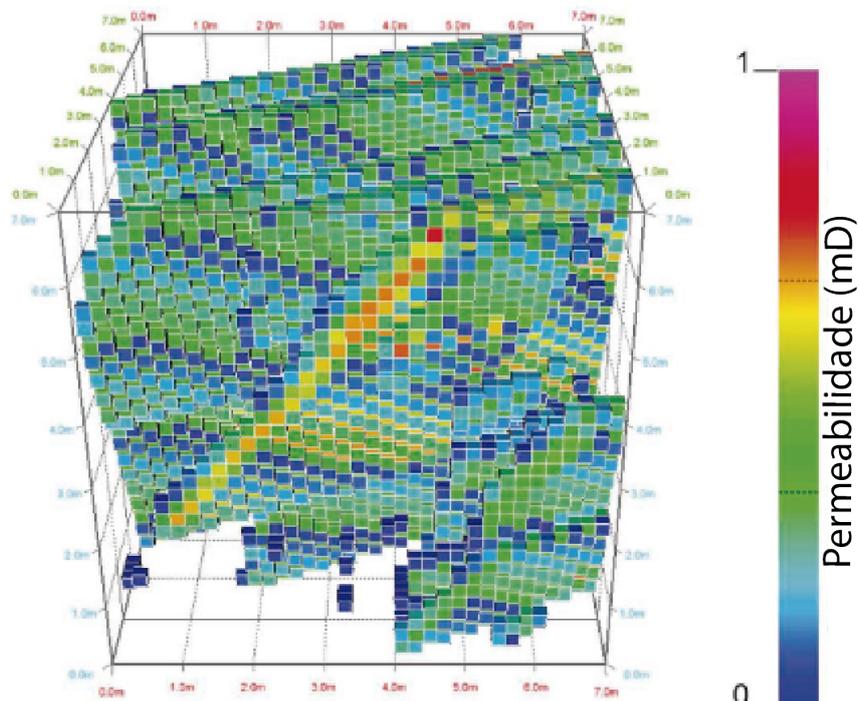


Figura 7 – *Grid* de permeabilidade empregando dados estruturais para simular o comportamento rochoso. Note a diagonal representando uma fratura geológica onde os valores de permeabilidade são mais expressivos. Adaptado de Giuffrida et al. [2019].

abruptas na topografia. Estes fenômenos podem ser o resultado ou consequência de fenômenos estruturais, como juntas, falhas, dobras, fraturas e rachaduras.

Em imagens de satélite, atributos lineares são formados por bordas, que são destacados por mudanças no brilho em imagens e podem ser de difícil reconhecimento. O uso de sensoriamento remoto para extração destes lineamentos apresenta diversas vantagens, como custo-benefício, *datasets* prontos para uso e boa resolução temporal e espacial [Epuh et al., 2020].

2.2- Algoritmos de Visão Computacional

Neste Subcapítulo serão abordados diversos algoritmos e técnicas de visão computacional que, nesta dissertação, serão explorados para extração de segmentos lineares a partir de imagens, com o objetivo da interpretação automática das fraturas presentes nos afloramentos rochosos.

2.2.1 Algoritmo de Canny

Um dos algoritmos mais populares para detecção de bordas é o algoritmo de Canny [Canny, 1986]. Sua implementação consiste da aplicação de um filtro gaussiano para remoção do ruído da imagem, localização dos gradientes de intensidade, supressão das bordas não conectadas aos principais gradientes e o uso de histerese para manter apenas as bordas mais expressivas da imagem.

Os critérios importantes definidos pelo autor para uma detecção de borda bem sucedida são:

- Boa detecção: deve haver baixa de probabilidade de não detecção de bordas reais, e baixa probabilidade de detecção de bordas falsas.
- Boa localização: os pontos marcados como borda pelo operador devem estar o mais próximos possível da borda verdadeira.
- Resposta única: Determinada borda deverá ser capturada apenas uma vez pelo filtro.

O uso de um filtro gaussiano em duas direções elimina grande parte do ruído de uma imagem, e a derivada dos valores resultantes (obtida, por exemplo, por um filtro de Sobel) detecta as bordas mais proeminentes da imagem.

O filtro de Sobel é um operador que computa uma aproximação dos gradientes de uma imagem. O seu uso envolve uma convolução executada na imagem com dois *kernels* de tamanho 3×3 resultando em gradientes nas duas direções:

$$\mathbf{G}_x = \begin{bmatrix} +1 & 0 & -1 \\ +2 & 0 & -2 \\ +1 & 0 & -1 \end{bmatrix} * A \quad \text{e} \quad \mathbf{G}_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} * A \quad (1)$$

sendo \mathbf{A} a imagem original a ser processada.

A partir dos gradientes resultantes, é possível combinar os valores aproximados para obter a magnitude do gradiente e sua direção. Isto é feito a partir do cálculo da hipotenusa (Eq. 2) e do arco tangente (Eq. 3) dos valores.

$$G = \sqrt{G_x^2 + G_y^2} \quad (2)$$

$$\Theta = \arctan2(G_y, G_x) \quad (3)$$

O segundo item é satisfeito através da supressão de valores não-máximos, eliminando as áreas espessas das bordas identificadas pela primeira derivada citada e concentrando a borda em um segmento de 1 pixel de largura.

O algoritmo proposto por Canny executa *limiarização por histerese*, ou seja, se alguma parte de um contorno tiver o valor acima do limite superior, estes pontos são automaticamente marcados como saída, assim como o segmento conectado inteiro a estes valores cujos pontos estiverem acima do limite inferior. Isto também reduz a probabilidade de contornos falsamente segmentados, pois para isto os valores deverão flutuar entre o limite superior e abaixo do inferior. Também ocorre a redução de falsos pontos de borda isolados, pois eles deverão estar acima do limite inferior.

A Figura 8b mostra o resultado da aplicação do algoritmo de Canny sobre uma imagem oriunda do conjunto de dados empregado nesta dissertação.

2.2.2 Limiarização Adaptativa Gaussiana

Esta técnica consiste em usar um filtro considerando os valores dos pixels vizinhos para definir um limiar para binarização em uma área específica ao longo da imagem. O algoritmo percorre a imagem por linhas, guardando os últimos s pixels vistos, e se o pixel atual tiver valor menor que determinado limiar, ele é definido como preto. Quando for maior que este limiar, é definido como branco [Wellner, 1993]. O resultado é uma imagem binarizada, onde só existem pixels com valor branco ou preto, exacerbando as principais características da imagem, como pode ser visto na Figura 8c onde é empregado na imagem original (Figura 8a) de VANT do conjunto de dados usado.

No caso da limiarização adaptativa gaussiana, este limiar é calculado com base em uma soma ponderada pela gaussiana de um bloco de *pixels* vizinhos subtraído de uma constante C .

A soma ponderada gaussiana é calculada a partir de um *kernel* construído pela função gaussiana em duas dimensões:

$$H(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x-x_0)^2 + (y-y_0)^2}{2\sigma^2}} \quad (4)$$

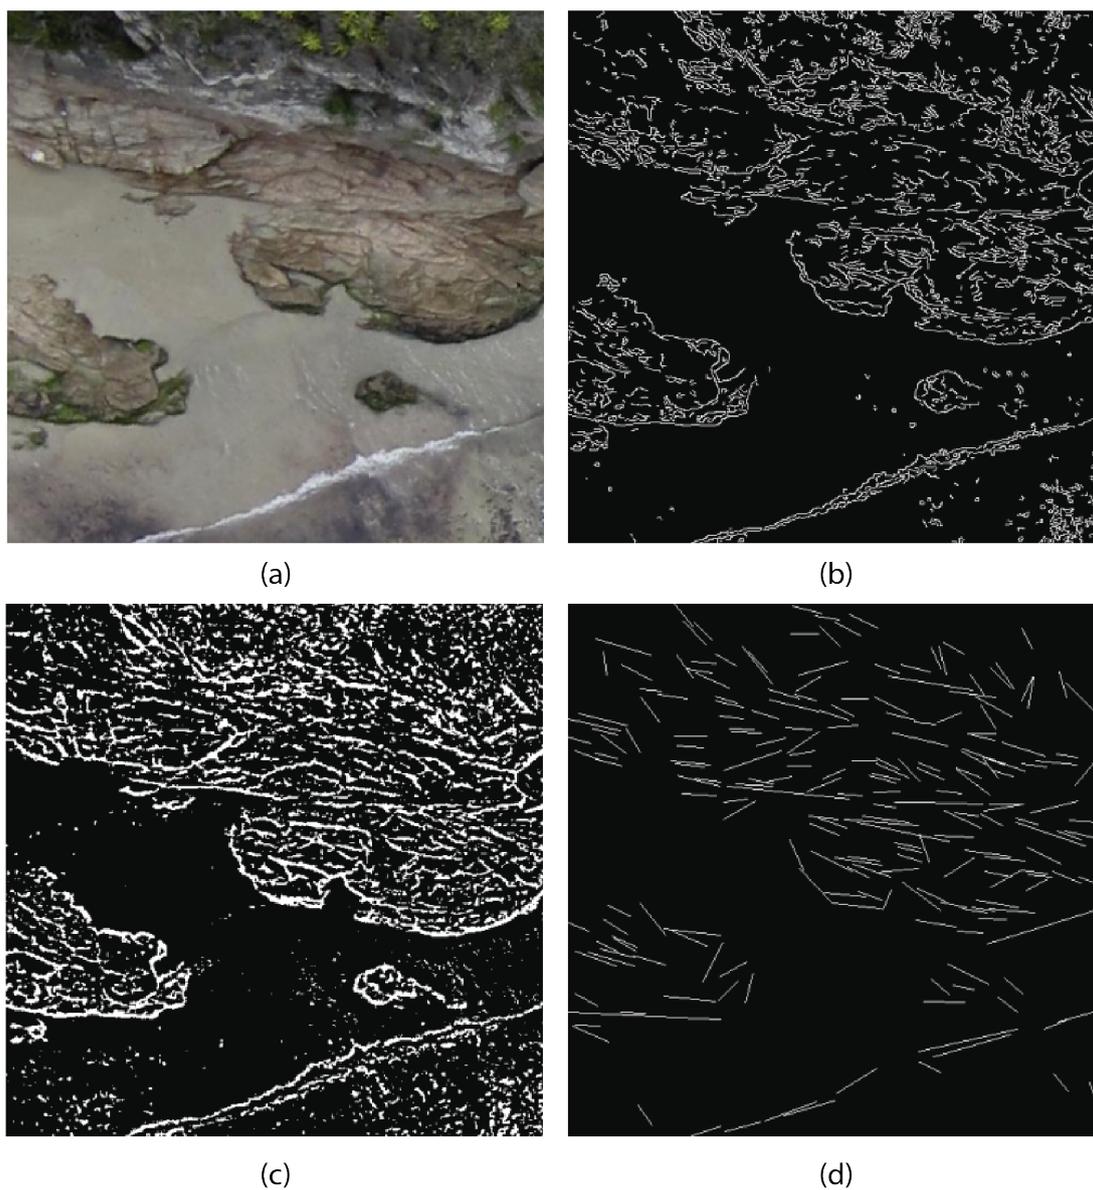


Figura 8 – Imagem do conjunto de dados utilizado processada pelos diferentes algoritmos de visão computacional explorados na pesquisa. a) Imagem original. b) Algoritmo de Canny. c) Limiarização adaptativa gaussiana. d) Detecção de segmentos lineares.

onde x , x_0 , y e y_0 representam a o maior e menor valor nas duas direções da janela calculada pelo bloco de *pixels* usado, e σ é o desvio padrão da distribuição. O *kernel* então é aplicado sequencialmente como janela deslizante na matriz da imagem para ponderar a soma dos valores de intensidade dos *pixels*.

Para iniciar o algoritmo, como não ainda há uma soma ponderada calculada, utiliza-se o valor 127, que seria o valor médio na escala de cinza. É um algoritmo relativamente rápido para limiarização, e que se adapta a condições adversas nas imagens processadas, como mudanças

de iluminação e contraste no dado.

2.2.3 Detecção de Segmentos Lineares

A metodologia proposta por Lee et al. [2014] implementa um algoritmo para extração de segmentos lineares inspirado pelo trabalho de Bay et al. [2005]. Após o processamento por Canny, os segmentos são extraídos a partir da conexão de determinada linha reta com uma vizinha, agregando sequencialmente novos segmentos caso elas satisfaçam a colinearidade com o segmento de linha em questão. Caso o detector encontre um grande valor de curvatura, o segmento atual é retornado apenas se a extensão for mais longa que 20 pixels, e os mesmos passos são repetidos até que todos os pixels da borda atual sejam consumidos. O algoritmo mescla incrementalmente dois segmentos caso eles se sobreponham ou se encontrem muito próximos, ou ainda, com orientação similar.

Vetores descritivos dos segmentos são gerados usando *Mean-standard Deviation Line Descriptor* (MSLD) [Wang et al., 2009] identificando a direção preferencial e fazendo uma análise estatística, permitindo a combinação robusta de dois segmentos, mesmo que possuam ruídos em suas extremidades. O resultado é uma nova imagem contendo a descrição da imagem original apenas por segmentos de linha reta, como pode ser observado na Figura 8d.

O MSLD envolve três passos: Para cada pixel em um segmento linear, é definido uma *Pixel Support Region* (PSR) ou região de suporte de pixel, e esta região é dividida em sub-regiões distintas. Em seguida, é gerada uma matriz de descrição do gradiente linear, ao caracterizar cada região como um vetor. O MSLD é construído ao computar a média e desvio padrão dos vetores colunar da matriz de descrição.

2.2.4 Análise de Morfologia

A análise de morfologia matemática é uma técnica do processamento de imagens que descreve a forma e a estrutura de determinado objeto em uma imagem. As operações morfológicas são baseadas na teoria dos conjuntos.

As operações contidas na análise de morfologia dependem de um elemento estruturante que interage com a imagem original e retornam um resultante. Estes elementos podem ter diferentes formas e tamanhos. A forma indica o arranjo dos uns e zeros em uma matriz, e o tamanho indica o alcance da operação em cada interação [Srisha and Khan, 2013].

As operações primárias são baseadas na adição e subtração de Minkowski [Barki et al., 2009], da geometria. Considerando que A é a imagem a ser processada, e B , o elemento estruturante, podemos definir:

- Dilatação: que adiciona pixels aos limites do objeto contido na imagem, aumentando o tamanho do objeto porém mantendo sua forma geral, além de preencher lacunas e eliminar buracos no interior do objeto. É realizada pela adição de Minkowski, onde a dilatação de A por B é o conjunto, em todos os deslocamentos de B por z a partir de sua origem, onde \hat{B} e A têm um elemento em comum:

$$\mathbf{A} \oplus \mathbf{B} = \{z | (\hat{\mathbf{B}})_z \cap \mathbf{A} \neq 0\} \quad (5)$$

- Erosão: que remove pixels dos limites do objeto, diminuindo seu tamanho e mantendo sua forma geral, além de alargar lacunas e buracos. É definida pelo conjunto de todos os pontos z em que o elemento B transladado por z é um subconjunto da imagem A :

$$\mathbf{A} \ominus \mathbf{B} = \{z | (\mathbf{B})_z \subseteq \mathbf{A}\} \quad (6)$$

A partir da combinação destas, pode-se obter mais duas principais operações:

- Abertura: que é uma combinação de dilatação e erosão, onde um elemento estruturante primeiro erode o dado, e depois dilata o resultante, eliminando pontes estreitas de pixels e suavizando a silhueta do objeto contido na imagem:

$$\mathbf{A} \circ \mathbf{B} = (\mathbf{A} \ominus \mathbf{B}) \oplus \mathbf{B} \quad (7)$$

- Fechamento: como a abertura, porém com a ordem de operações invertidas. O elemento primeiro dilata e depois erode o dado resultante, fechando pequenas lacunas contidas no objeto:

$$\mathbf{A} \cdot \mathbf{B} = (\mathbf{A} \oplus \mathbf{B}) \ominus \mathbf{B} \quad (8)$$

A imagem 9 exemplifica estas operações sobre uma imagem binária, mostrando os resultados a partir de cada uma.

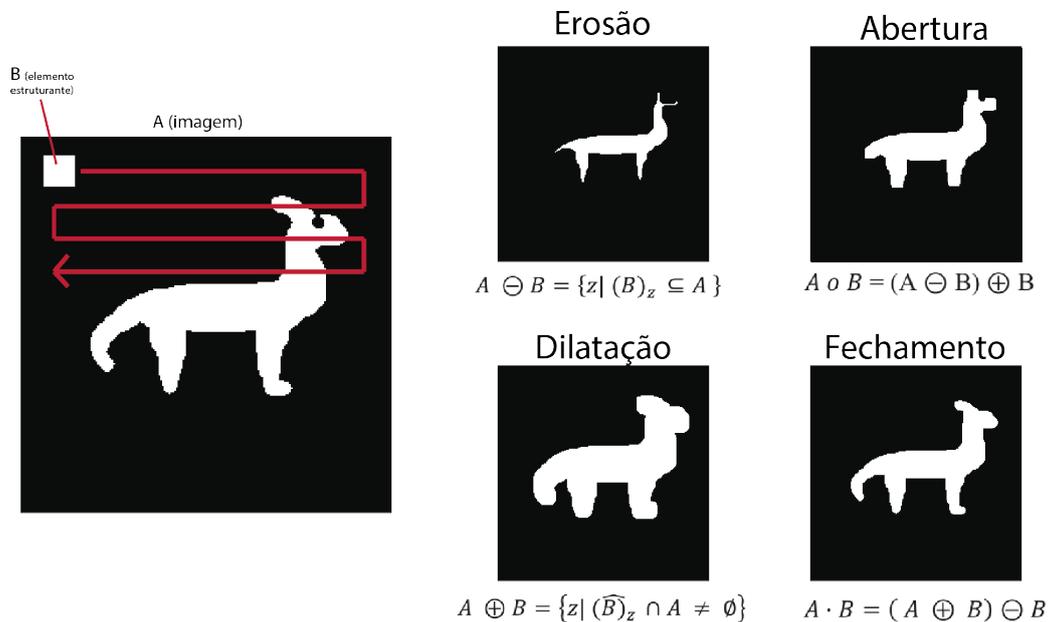


Figura 9 – Diferentes operações de análise de morfologia aplicadas a uma imagem binária usando um elemento estruturante quadrado.

2.2.5 Remoção de Pequenos Objetos

A técnica de remoção de pequenos objetos analisa uma matriz de valores e verifica se o tamanho dos diversos agrupamentos de valores e sua conectividade em relação a outros agrupamentos obedece a um limite definido de tamanho e conectividade. Desta forma, se os agrupamentos forem pequenos demais e não possuírem conectividade com seus agrupamentos vizinhos, eles são removidos da matriz de valores.

Isto é feito da seguinte maneira: Um elemento estruturante com um formato específico determinado pela conectividade caminha pela matriz de valores e verifica quais agrupamentos de valores são sobrepostos pelo elemento. Os valores que obedecem a esta condição são representados em uma outra matriz, de mesmo tamanho da original, com um valor inteiro representando sua classe. Em seguida, a matriz é achatada para um vetor contendo todos os valores das classes, nos quais são executados uma contagem binária que diz o tamanho de cada

agrupamento. A partir dessa contagem, se o agrupamento não for maior que o limite definido, o seu valor original é definido como zero, removendo os *pixels* da imagem desconectados. Este passo-a-passo pode ser explicado pelo Algoritmo 1.

Algoritmo 1 – Algoritmo de remoção de pequenos objetos para retirada de artefatos

Entrada: *matriz*, *tamanhoMin*, *conectividade*

```

1: elemento ← geraElementoEstruturante(conectividade)
2: matrizRotulada ← rotulaAgrupamentos(elemento, matriz)
3: vetorGrupos ← achataMatriz(matrizRotulada)
4: agrupamentos ← contagemBinaria(vetorGrupos)
5: for all agrupamento ∈ agrupamentos do
6:   if agrupamento < tamanhoMin then
7:     matrizSaida[agrupamento] ← 0
8:   end if
9: end for
10: retorna matrizSaida

```

Isto permite que sejam eliminados componentes das matrizes isolados, relativos a artefatos e sem significado para este trabalho. No caso de uma imagem, por exemplo, *pixels* isolados e pequenos o suficientes seriam retirados, mantendo-se apenas os agrupamentos de *pixels* com algum sentido relativo aos demais.

2.2.6 Segmentação Semântica

A tarefa de segmentação semântica faz parte do reconhecimento automático de imagens. A saída de um algoritmo de segmentação semântica, dada uma nova imagem não vista anteriormente, são os conjuntos de *pixels* que estão relacionados semanticamente, ou seja, compartilham significado. Tradicionalmente, estes algoritmos se baseiam na separação de regiões utilizando informação de contornos, bordas, cores e texturas [Zhou et al., 2019]. Um exemplo de segmentação semântica seria, na implementação de um carro autônomo, a identificação de quais regiões da imagem capturada pela câmera seriam estrada, outros veículos, meio-fio, calçada e outros artefatos. Estas regiões (ou conjuntos de *pixels*) seriam segregadas semanticamente pelo algoritmo.

Guo et al. [2018] dividem as metodologias de segmentação de instâncias em 3 categorias: segmentações semânticas baseadas em regiões, baseadas em *Fully Convolutional Networks*

(FCNs) e as fracamente supervisionadas. Neste trabalho será explorada a segmentação baseada em FCNs, descrita a seguir.

Fully Convolutional Networks

Uma rede convolucional do tipo () (*Fully Convolutional Network*, ou Rede Totalmente Convolucional) é um tipo de rede neural convolucional que só executa convoluções sem o uso de camadas totalmente conectadas (*Fully Connected Layer*).

Convolução é simplesmente uma operação de somatório do produto entre duas funções ao longo da região em que elas se sobrepõem, em razão do deslocamento existente entre elas [Goodfellow et al., 2016]. Temos então a fórmula:

$$(f * g)(x) = h(x) = \int_{-\infty}^{\infty} f(u) \cdot g(x - u) du \quad (9)$$

onde x é a variável independente e u é o deslocamento mencionado. No caso de uma convolução de domínio discreto, temos a fórmula:

$$(f * g)(k) = h(k) = \sum_{j=0}^k f(j) \cdot g(k - j) \quad (10)$$

onde f e g são sequências discretas de tamanho n e a fórmula fornece o k -ésimo elemento resultante.

A camada convolucional é o principal componente de uma rede neural convolucional, e consiste em filtros, ou *kernels*, que têm um campo de ação reduzido, mas se estendem pela profundidade do dado de entrada. Cada filtro convolucional executa uma convolução, computando um produto escalar entre a matriz do filtro e o dado. Estes filtros executam, portanto, convoluções em duas dimensões:

$$(f * g)(x, y) = h(k) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} f(i, j) \cdot g(x - i, y - j) \quad (11)$$

A intenção é que as redes neurais convolucionais aprendam, a partir do processo de treinamento, quais os filtros que ativam as melhores características da imagem de forma a chegar ao resultado do dado de referência, evitando a necessidade de extenso pré processamento

da entrada.

Redes convolucionais usadas como classificadores recebem entradas de tamanho fixo e produzem saídas em valores numéricos, como probabilidades ou classes. As camadas totalmente conectadas destas redes, porém, poderiam ser tomadas como convoluções que utilizam *kernels* que cobrem toda a dimensão das entradas. Desta forma, seria possível adaptar redes classificadoras para tarefas de segmentação semântica fazendo poucos ajustes nestas redes, a partir do descarte da última camada classificadora e a conversão de todas as camadas totalmente conectadas em convoluções, tornando-as FCNs [Shelhamer et al., 2017].

DenseNet

A DenseNet, de *Densely Connected Networks* (Rede Densamente Conectada), é uma arquitetura de rede convolucional que introduz conexões diretas entre qualquer camada e todas as camadas anteriores e subsequentes de forma a assegurar máximo fluxo de informação entre as camadas. Ou seja, cada camada recebe dado de entrada adicional das camadas que a precedem, e passa a diante seus mapas de atributos para as camadas seguintes (exemplificado na Figura 10 [Huang et al., 2017]).

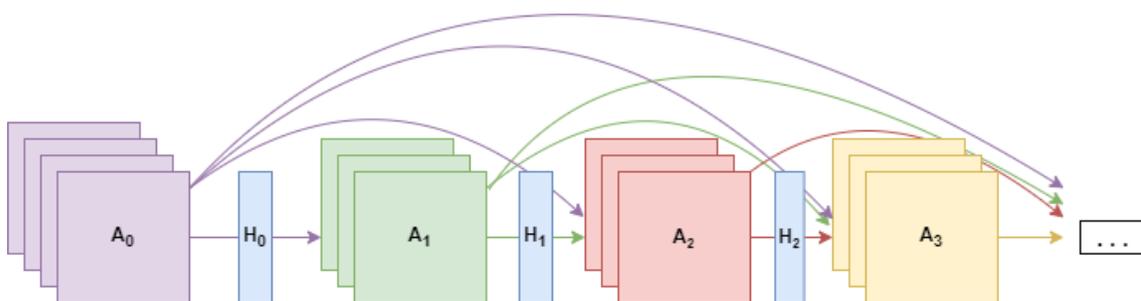


Figura 10 – Diagrama exemplificando a arquitetura Densenet. A_0 representa a imagem de entrada e H as transformações compostas por *Batch normalization*, *ReLU* e a convolução 3×3 . Adaptado de Huang et al. [2017].

Considerando uma imagem A que é processada por uma rede convolucional, e um número de camadas L , cada qual implementando uma transformação não linear $H_\ell(\cdot)$, onde ℓ é o índice da camada. Na Densenet, cada ℓ -ésima camada terá como entrada:

$$\mathbf{A}_\ell = H_\ell([\mathbf{A}_0, \mathbf{A}_1, \dots, \mathbf{A}_{\ell-1}]), \quad (12)$$

considerando \mathbf{A}_ℓ como a saída da ℓ -ésima camada, e o termo $[\mathbf{A}_0, \mathbf{A}_1, \dots, \mathbf{A}_{\ell-1}]$ como a concatenação de todos os mapas de atributo produzidos nas camadas anteriores.

A transformação $H_\ell(\cdot)$ é uma função composta de três operações: *batch normalization*, *rectified linear unit (ReLU)* e uma convolução com *kernel* de tamanho 3×3 .

Além disso, são usadas camadas de transição que fazem o *down-sampling* nos mapas de atributos, realizando convoluções e *pooling*. A cama de transição utilizada pelos autores consiste em uma camada de *batch normalization* e uma convolução de tamanho 1×1 , seguida de uma camada de *average pooling* de 2×2 .

Entre suas vantagens estão que elas requerem substancialmente menos parâmetros e menos computação para conseguir um alto desempenho. Também consegue aprimorar a acurácia consistentemente com o crescimento do número de parâmetros, diminuindo a possibilidade de apresentar sobreajuste dos dados ou degradação da rede.

2.3- Comentários Finais

Este Capítulo teve como objetivo introduzir conceitos importantes que envolvem os objetivos e métodos utilizados neste trabalho. A conceituação da geologia estrutural é essencial para o entendimento das estruturas a serem extraídas pela metodologia proposta, e a definição do algoritmos de visão computacional permitem a compreensão das etapas de pré e pós-processamento, assim como o treino das redes neurais. No próximo Capítulo, serão explorados os trabalhos relacionados da literatura que versam sobre a extração de lineamentos e estruturas geológicas a partir de imagens aéreas.

3- Revisão Bibliográfica

A aplicação de redes neurais convolucionais na interpretação automática de dados geológicos vem ganhando destaque nos últimos anos [Imamverdiyev and Sukhostat, 2019] [Han et al., 2019] [Valentín et al., 2019] [Olivia et al., 2020]. Em contrapartida, algoritmos mais clássicos de visão computacional têm amplo histórico de uso no geoprocessamento, principalmente para extração de lineamentos [Raghavan et al., 1993] [Koike et al., 1995], [Hashim et al., 2013].

A extração de lineamentos geológicos consiste na obtenção, a partir de técnicas computacionais, das principais características lineares de uma imagem, podendo assim representar feições estruturais de interesse. Estas feições, podem, por vezes, indicar *trends* de fraturas, falhas ou outras estruturas geológicas cujo interesse econômico é grande, seja por concentrar minérios, seja para servir como dutos para movimentação de fluidos, como água ou petróleo [Gobashy et al., 2021; Saepuloh et al., 2018]. Tal tarefa é um importante complemento à etapa de trabalho de campo nas geociências [Saint Jean Patrick Coulibaly et al., 2020].

3.1- Lineamentos em Dados de Satélite

A maior parte dos trabalhos citados a seguir aplicam algoritmos de visão computacional para extração de lineamentos, usando dados de satélite e Modelos Digitais de Elevação (MDEs), como *hillshades*, diferindo geralmente nos algoritmos de escolha e processos de pré e pós-processamento.

O algoritmo de aplicação clássica para extração de lineamentos é o *Segment Tracing Algorithm* (STA), introduzido por Koike et al. [1995] como uma abordagem sem filtragem para extração de vales contínuos em uma imagem de satélite. O algoritmo envolve a definição da orientação do vale examinando o desvio local dos níveis de cinza ao longo de uma linha. Em seguida, ele avalia a variação dos níveis de cinza a partir da derivada na direção perpendicular ao vale. O trabalho aplicou o método a sub censo LANDSATTM de 4 bandas de uma área de floresta no Japão e verificou que muitos lineamentos extraídos pelo STA correspondiam a

lineamentos de significância geológica interpretados manualmente, mesmo em áreas de baixo contraste.

O trabalho de Raghavan et al. [1993] aplicou outro algoritmo, o Algoritmo de Detecção de Segmentos Direcionais, ou, em inglês, (*Directional Segment Detection*), a dados de elevação digital. O relevo sombreado (*Shaded Relief*), uma técnica de cartografia que exibe o relevo em três dimensões de uma mapa como se iluminado por uma fonte de luz arbitrária, foi obtido usando o modelo Lambertiano para reflexão difusa. O algoritmo recebe uma direção definida pelo usuário para escanear o dado e diferencia diferentes grupos de *pixels* que definem um lineamento.

Já o trabalho de Raghavan et al. [1995] também aplicou o juntamente a um método baseado na Transformada Hough Generalizada para processar a imagem, em tons de cinza, a partir dos gradientes dos valores de intensidade dos *pixels* e gerar os atributos de lineamento finais. O método foi aplicado a imagens LANDSATTM e relevos sombreados. Os resultados exibiram, mais uma vez, que a maioria dos lineamentos extraídos automaticamente representavam características geomorfológicas e estruturas de significância geológica.

A detecção de contornos do algoritmo de Canny também é combinado com uma série de diferentes métodos de limiarização para extrair atributos lineares, como em Adiri et al. [2017]. Neste caso, os autores empregaram *Principal Components Analysis* (PCA), ou Análise de Principais Componentes, para comprimir a informação contida nas bandas da imagem, removendo redundância e isolando o ruído.

O trabalho de Masoud and Koike [2011] comparou STA à técnica de Detecção de bordas de Canny e ao algoritmo de Detecção de Segmentos Lineares (DSL), tendo o primeiro melhor rendimento em relação aos demais. Mais além, a Transformada de Hough é geralmente usada para pós-processamento ao conectar segmentos lineares vizinhos. Em Soto-Pinto et al. [2013] é usado após tanto Canny quanto Detecção Direcional. Em Han et al. [2018] é aplicada após uma técnica de votação de tensores, onde cada ponto das bordas tem sua informação geométrica representada por um tensor e relacionada com sua vizinhança.

Outra abordagem combinando modelos digitais de elevação a imagens de sensoriamento remoto envolve usar a transformada *Wavelet* de Faber-Schauber aliada a binarização de Otsu para segmentar imagens e extrair lineamentos geológicos Xu et al. [2020].

Todas as metodologias acima extraem lineamentos de dados de satélite, usando características geomorfológicas do terreno para inferir direções estruturais importantes do ponto de vista geológico. Isto difere da metodologia proposta por esta dissertação que tem como objetivo a extração de fraturas reais dos corpos rochosos, mesmo que ambos os resultados

possam indicar direções estruturais cujo significado seja representativo da geologia da área.

3.2- Imagens de VANT

O uso de visão computacional para extração de fraturas de imagens de VANTs difere da identificação de lineamentos, uma vez que são feições lineares específicas de uma imagem que correspondem a fraturas, e não quaisquer linhas com determinada direção repetitiva, como é o caso dos lineamentos. Esta tarefa, porém, ainda não foi extensivamente explorada na literatura. A seguir são descritos os poucos trabalhos relacionados e como eles diferem da metodologia proposta por esta dissertação.

Vasuki et al. [2014] aplicou Detecção de Segmentos Lineares (DSL), congruência e simetria de fases em fotografias de VANTs, além do algoritmo Canny para detecção de bordas, mas utilizaram uma abordagem semiautomática envolvendo a interação de um usuário geocientista para validação tanto das geometrias das fraturas detectadas quanto para conexão de segmentos separados em estruturas únicas.

O algoritmo Canny também foi utilizado por Weixing et al. [2007], o qual propôs um sistema formado por detecção de bordas, algoritmos de limiarização e *Support Vector Machine* (SVM), ou Máquina de Vetores de Suporte, em fotografias de rochas fraturadas, com intuito de executar segmentação nas imagens. As SVM foram utilizadas para classificação das estruturas segmentadas, utilizando média e desvios padrão de uma série de atributos como curvatura, magnitude, e comprimento.

Recentemente, Oliveira et al. [2020] desenvolveram uma metodologia unindo classificadores de imagem, a partir de Redes Neurais Convolucionais, e algoritmos de detecção de contornos para extrair dados de fratura de imagens de VANTs. O algoritmo escolhido para o processamento das estruturas lineares foi a DSL aplicada diretamente em imagens de alta resolução, e também aplicado em imagens préprocessadas usando florestas estruturadas para algoritmos de detecção de contornos rápidos, gerando como resultado imagens com atributos lineares mais expressivos.

A metodologia apresentada por esta pesquisa usa redes convolucionais para segmentação semântica, aplicando algoritmos de visão computacional como a limiarização adaptativa gaussiana e técnicas de análise de morfologia para extrair geometrias de fratura reais de corpos

rochosos a partir das imagens de VANT, e aplica algoritmos de extração de segmentos lineares para obter resultados de direção azimutal mais precisos. A metodologia propõe um fluxo de trabalho contínuo e automático, sem a interação com o usuário. A diferença para os trabalhos supracitados é justamente a criação de máscaras de fraturamento a partir do modelo preditivo de segmentação semântica, aumentando a precisão da geometria das estruturas extraídas.

A Tabela 1 faz a comparação entre os algoritmos utilizados nos trabalhos citados acima, tanto para extração de lineamentos quanto fraturas em imagens de VANT, com a metodologia proposta por esta dissertação.

Tabela 1 – Comparação entre metodologias e fonte de imagens. Notação: STA: Segment Tracing Algorithm. START: Segment Tracing And Rotation Transformation. DCC: Detecção de Contornos de Canny. TH: Transformada Hough. CG: Congruência. SF: Simetria de fases. TV: Votação de tensores. WT: Transformada *Wavelet*. B: Binarização. LAG: Limiarização Adaptativa gaussiana. DSL: Detecção de segmentos lineares. CNN: Convolutional Neural *Convolutional Neural Network*. *Baseada em segmentação semântica.

Referência	Algoritmo	Fonte	Automatizada	Seg*
Raghavan et al. [1993]	DSL	Satélite + MDE	✓	
Koike et al. [1995]	STA	Satélite + MDE	✓	
Raghavan et al. [1995]	START	Satélite + MDE	✓	
Masoud and Koike [2011]	STA/DCC/DSL	Satélite + MDE	✓	
Soto-Pinto et al. [2013]	DCC/DSL/TH	Satélite + MDE	✓	
Vasuki et al. [2014]	DCC/CG/SF	VANT	Semi	
Adiri et al. [2017]	DCC	Satélite + MDE	✓	
Han et al. [2018]	TV/WT	Satélite + MDE	✓	
Saint Jean Patrick Coulibaly et al. [2020]	DSL	Satélite + MDE	✓	
Xu et al. [2020]	WT/B	Satélite + MDE	✓	
Oliveira et al. [2020]	DSL	VANT	✓	
Metodologia proposta	CNN/LAG/DSL	VANT	✓	✓

3.3- Comentários Finais

A partir dos trabalhos explorados neste Capítulo, é possível notar a importância histórica do uso do imageamento aéreo para análises de geologia estrutural a partir da extração automática e semiautomática de lineamentos e estruturas geológicas. Percebe-se também o reduzido uso de imagens de VANTs na literatura, embora cada vez mais crescente. O próximo Capítulo discutirá sobre a construção de um banco de dados de imagens de VANTs e também sobre todas as etapas da metodologia proposta.

4- Aplicação

4.1- Conjunto de Dados

A área de estudos onde foram coletadas as imagens de VANTs utilizadas neste trabalho se localiza na Praia das Conchas, município de Cabo Frio, Rio de Janeiro. A Figura 11 mostra a localização da área no contexto do Brasil e do estado do Rio de Janeiro. Este local compreende dois afloramentos rochosos de ortognaisses Paleoproterozóicos injetados por um conjunto de diques máficos toleíticos.



Figura 11 – Localização da área de estudo. a) A localização da área de estudo na América do Sul. b) Localização da área no leste do estado do Rio de Janeiro, no município de Cabo Frio. c) Localização da Praia das Conchas, com os afloramentos norte e sul utilizados na análise. Extraído do Google Maps, por Google.

As estruturas rúpteis, como as fraturas a serem extraídas por este trabalho, são interpretadas como sendo dos estágios iniciais da abertura Mesozóica do Atlântico Sul [Savastano et al., 2017].

A aquisição de dados foi executada usando um VANT a partir de uma altura média de

100 metros acima do ponto de decolagem, e resultou em uma resolução de 4-5 centímetros por pixel. Os dados foram processados usando o *software* Pix4D Mapper©, que também executou georreferenciamento e ortoretificação. Os lineamentos visíveis nas imagens foram anotados como *shapefiles* e mantiveram as orientações geográficas oriundas do georreferenciamento. O conjunto de imagens e as anotações processadas podem ser encontrados no repositório do IEEE Dataport, no endereço <https://ieee-dataport.org/documents/fractures-uav-imagery-segmentation> [Savastano and Batista, 2021].

4.2- Metodologia

A metodologia proposta por esta dissertação envolve o treinamento de um modelo de segmentação semântica, operações de análise de morfologia na máscara resultante do modelo, binarização da imagem restrita às tais máscaras e por fim, redução de artefatos pela técnica de remoção de objetos, como apresentado na Figura 12. O código que executa tais etapas, tanto relativo ao treino do modelo quanto às etapas de pós processamento, pode ser encontrado no repositório *GitHub* <https://github.com/davibortolotti/saelgs> [Batista, 2021].

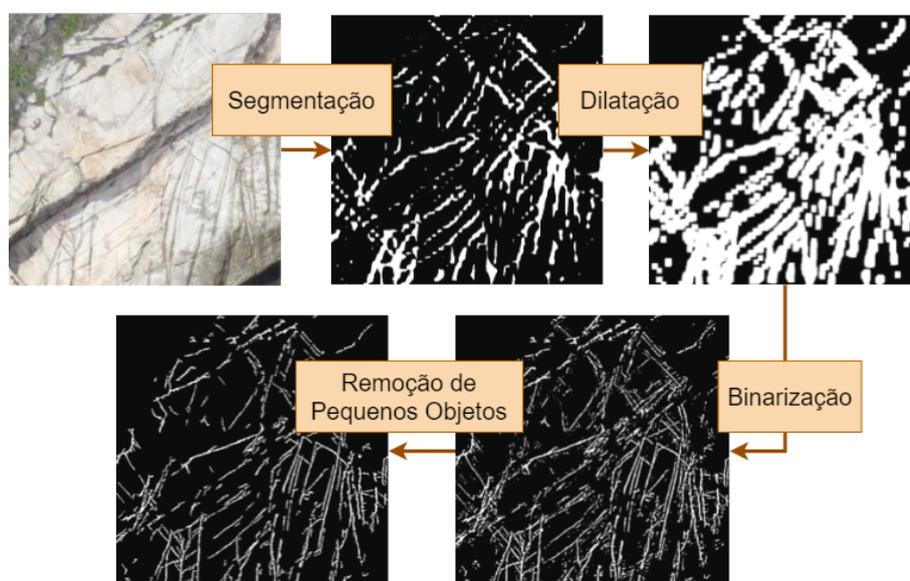


Figura 12 – Fluxo da metodologia para extração de fraturas por segmentação semântica e pós-processamento.

A seguir, cada etapa deste fluxo será descrito com mais detalhe, com os parâmetros numéricos dos algoritmos utilizados e seus resultados parciais.

4.2.1 Dado de Referência

Para criar o dado de referência (*ground truth*), tanto para o treinamento do modelo de segmentação quanto para avaliação dos resultados, os *shapefiles* dos lineamentos anotados manualmente foram convertidos para *pixels* usando a ferramenta "*shape to raster*" do software QGIS©. Os dados de imagem e lineamentos convertidos em pixel foram então divididos em um mosaico de quadrados de 500×500 *pixels* para que fossem inseridos no modelo convolucional. O mosaico de imagens original compreendeu 1895 sub imagens, mas a maioria destas não continha dados de lineamentos. Então, apenas as sub imagens contendo *pixels* de lineamento foram selecionadas para o treino e avaliação do modelo, o que resultou em 275 quadrados.

Os resultados da conversão dos *shapefiles* de lineamentos para anotações em pixel não corresponderam perfeitamente a fraturas na imagem rochosa original. Devido à conversão *shape para raster*, os polígonos resultantes obtiveram medidas de apenas 1 pixel de largura, enquanto muitas fraturas reais excediam esta dimensão nas imagens. A metodologia usada para adquirir a largura ideal para os polígonos em *pixel* nas imagens de *ground truth* foi baseado em análise de morfologia.

Primeiramente, as imagens originais foram binarizadas usando limiarização adaptativa gaussiana (Seção 2.2.2). Posteriormente, a técnica de erosão da análise de morfologia (Seção 2.2.4) foi aplicada valendo-se de diferentes *kernels* para definir qual o tamanho necessário para degradar as fraturas verdadeiras inteiramente. Os resultados mostraram que erosão com *kernels* de 4×4 degradaram completamente a geometria da maioria das fraturas, evidenciando uma espessura média de 4 pixels das fraturas. Este *kernel* resultante foi utilizado para expandir as anotações em forma de pixel para obter uma máscara de segmentação para uso na etapa de construção do modelo. Isto foi executado por análise de morfologia novamente, mas desta vez com a técnica de dilatação, também aplicando o *kernel* de 4×4 obtido na análise anterior, como mostrado na Figura 13.

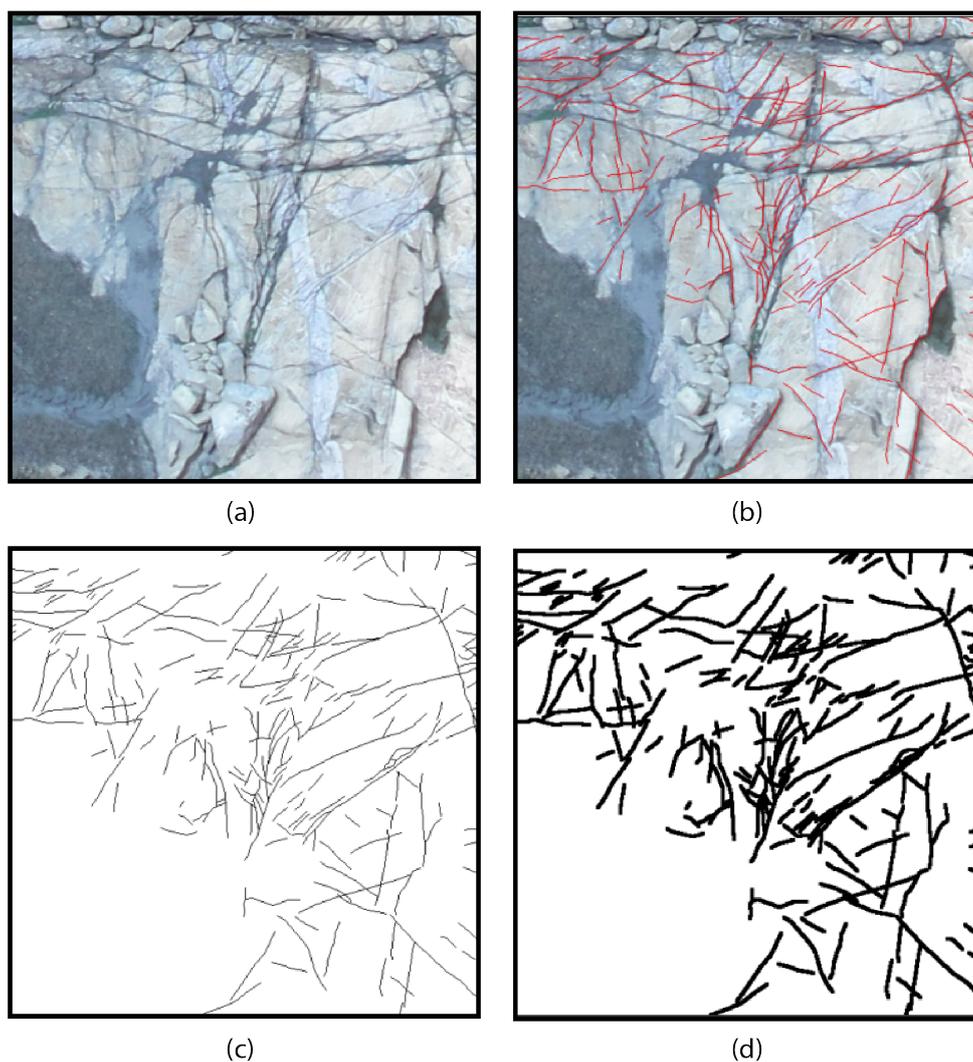


Figura 13 – Processamento de estruturas geológicas interpretadas para treinamento do modelo de segmentação. a) Imagem original; b) Imagem original sobreposta pelos lineamentos interpretados; c) Interpretação geológica convertida para *pixels*, sem dilatação, com 1 *pixel* de largura; d) Estruturas após dilatação por análise de morfologia utilizando um *kernel* de 4×4 *pixels*, para o treinamento do modelo.

4.2.2 Segmentação Semântica

Treino do modelo

O método proposto para predição de áreas fraturadas aplica redes convolucionais para a tarefa de segmentação semântica. Uma vez que os dados disponíveis não são muito numerosos,

a técnica de transferência de aprendizado foi empregada para atingir resultados razoáveis. Uma arquitetura de rede DenseNet, com duas implementações distintas, foi utilizada para segmentação semântica no modelo de previsão de fraturas, classificando os *pixels* das imagens em duas classes: Fratura e Fundo (*Background*). A arquitetura desta rede é descrita na seção 2.2.6.

Segundo Bozinovski [2020], a técnica de transferência de aprendizado consiste em reutilizar um modelo de aprendizado de máquinas treinado para uma tarefa de aprendizado específica em uma segunda tarefa de aprendizado. Para isto, nesta segunda tarefa, os pesos não são iniciados do zero, e sim reaproveitados do primeiro modelo. Com isto, é possível diminuir o tempo de treinamento nesta segunda tarefa, uma vez que o conhecimento gerado pela primeira é aproveitado.

Foram utilizadas duas implementações da rede DenseNet, uma delas com 161 camadas e outra com 264. A implementação de 161 camadas baseou-se em Huang et al. [2017], e foi executada por 40 épocas e taxa de aprendizado variável, começando com valor 0.0005 e, após as 15ª época, 0.00005. As curvas de perda do modelo podem ser observadas na Figura ??, onde percebe-se que não foi atingido sobreajuste no treino do modelo. A função de perda utilizada é a função do coeficiente de Dice, uma vez que esta se comporta bem em conjuntos de dados com classes não balanceadas, como é o caso das classes de fratura e fundo deste trabalho.

A implementação da rede DenseNet com 264 camadas foi descrita em Pleiss et al. [2017] e treinada com cronograma de taxa de aprendizado por cosseno. Devido a eficiência no uso de memória do modelo, ela pôde ser treinada com uma quantidade relativamente pequena de memória, apesar da grande profundidade da rede. Os parâmetros para o treinamento foram a taxa de aprendizado fixa de 10^{-5} , usando uma função de perda de *Cross Entropy*, estabilizando em 150 épocas de treinamento, como observado na Figura 15.

Os modelos pré-treinados esperam imagens de entrada de 3 canais RGB, carregadas em um intervalo de 0 a 1 e normalizadas usando média [0.485, 0.456, 0.406] e desvio padrão [0.229, 0.224, 0.225].

Referente à transferência de aprendizado, ambas as redes foram pré-treinadas com o conjunto de dados ImageNet [Deng et al., 2009], contendo mais de 14 milhões de imagens diversas e suas anotações para detecção de objetos.

As imagens de satélite contendo as fraturas foram então separadas em dois grupos para o treinamento usando o método *holdout*, com 60% e 40% das imagens para treino e avaliação

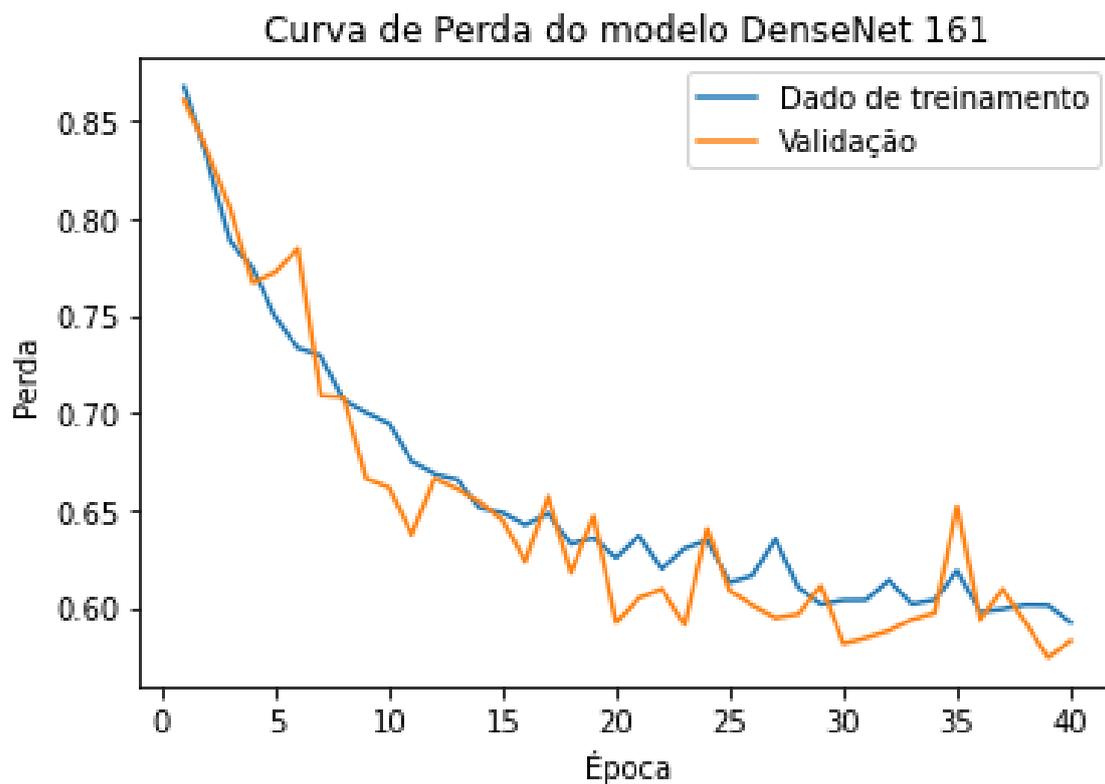


Figura 14 – Curva de perda de Dice do modelo DenseNet de 161 camadas, mostrando estabilização da curva de perda ao redor da época 40.

do modelo, respectivamente. Isto resultou em 193 imagens para treinamento e 82 imagens para avaliação.

Execução do treinamento foi baseado em GPU, executado em uma CPU Intel(R) Core(TM) i5-7400 @ 3.00GHz com quatro núcleos de processamento, 16 GB de memória RAM e uma placa de vídeo NVIDIA GeForce GTX 1070 com 8 GB de memória.

Aumento de dados (*data augmentation*) foi usado em cada lote de treinamento, aplicando uma série de transformações aleatoriamente às imagens de treinamento a cada época. As transformações usadas foram:

- Inversão no eixo horizontal, com probabilidade de 50%.
- Mudança de escala (com limite de 20%), rotação (com limite de 20 graus) e translação (com limite de 20%, com probabilidade de 80% de ocorrência).
- Corte de uma porção aleatória de 320×320 *pixels* da imagem.
- Preenchimento das bordas, caso necessário, com limite de 320 *pixels*.

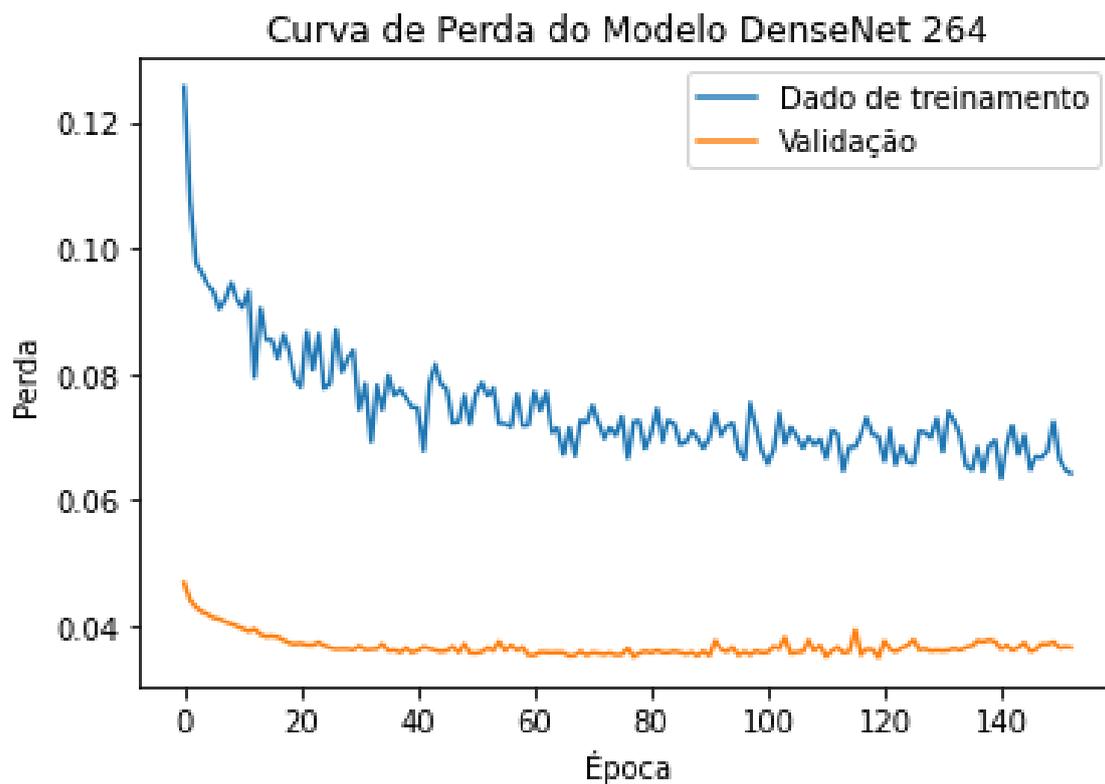


Figura 15 – Curva de perda de *Cross Entropy* do modelo DenseNet de 264 camadas.

- Uma dentre as transformações de *gamma*, luminosidade e contraste aleatório, com probabilidade de 90%.

4.2.3 Pós-processamento

Técnicas de pós-processamento envolveram uma série de metodologias de análise de morfologia, binarização, remoção de pequenos objetos e detecção de linhas para extrair segmentos lineares das máscaras resultantes dos modelos de segmentação.

O primeiro passo após executar a predição das máscaras de fratura a partir das imagens de entrada é a dilatação das máscaras usando análise de morfologia. As máscaras foram dilatadas usando-se um elemento estrutural quadrado de 15×15 *pixels* para aumentar a cobertura das geometrias das fraturas (Figura 16). Esta etapa foi apenas utilizada no modelo Densenet com 264 camadas, pois no modelo de 161 camadas a etapa influenciou negativamente nas métricas de precisão da segmentação.

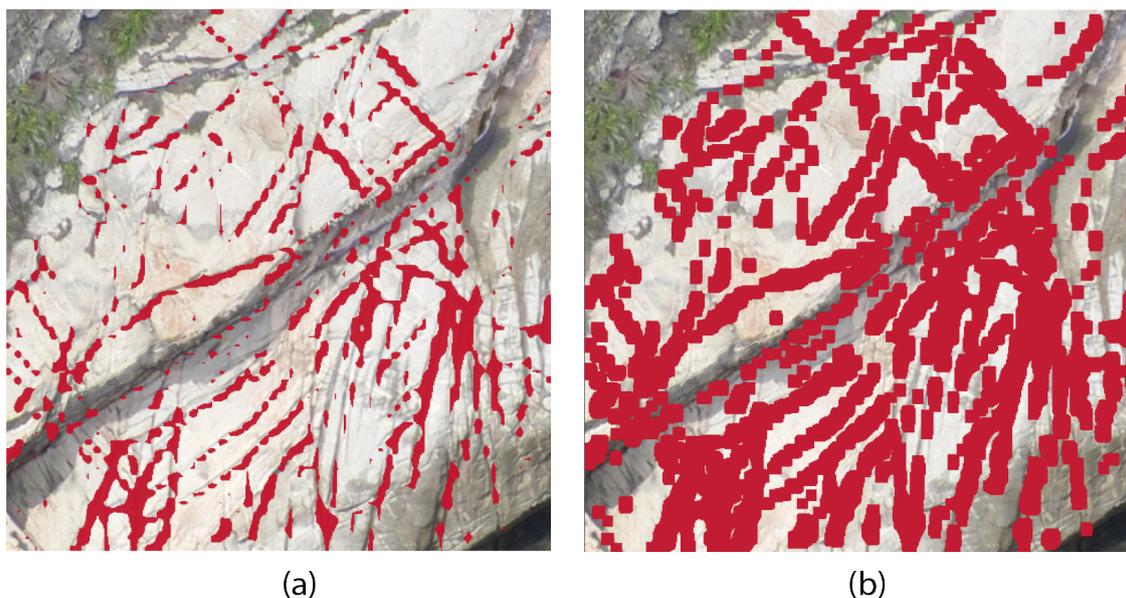


Figura 16 – Etapa de dilatação do pós-processamento usando um *kernel* 10×10 para cobertura das geometrias reais das fraturas na imagem. a) Sobreposição da imagem original com a máscara gerada pelo modelo DenseNet com 264 camadas. b) Mesma máscara, após dilatação.

Em seguida, aplica-se então a binarização na área interior às máscaras a partir de limiarização adaptativa gaussiana, que captura os *pixels* das estruturas lineares. Um mapa de estruturas lineares é obtido pela técnica, e apesar de já aprimorar os atributos lineares, ainda contém um grande volume de artefatos, como *pixels* isolados e segmentos lineares pequenos sem significado geológico. A técnica de limiarização adaptativa utilizada é descrita na seção 2.2.2, e utilizou os parâmetros de 11 para o bloco de *pixels* vizinhos e 8 para a constante do limiar.

Para reduzir os agregados considerados artefatos, foi aplicada a técnica de remoção de pequenos objetos (Seção 2.2.5), com conectividade de 10 *pixels* e ignorando atributos com tamanho menor que 20 *pixels*. Note que isto resulta em um mapa de fraturas limpo, sem estruturas ausentes de significado e *pixels* isolados, como pode ser observado nas Figuras 17d e 17f.



Figura 17 – Resultados do modelo de segmentação semântica e pós-processamento. a) Imagem original. b) Anotações de *ground truth*. c) Segmentação predita gerada pelo modelo DenseNet 264. d) Resultado usando o fluxo de trabalho de pós-processamento proposto nas previsões do modelo Densenet 264. e) Segmentação predita pelo modelo DenseNet 161. f) Resultado com pós-processamento na previsão do modelo DenseNet 161.

4.2.4 Comparação com outras técnicas de visão computacional

Para comparar a metodologia proposta por esta dissertação para extração de fraturas automatizada, dois outros métodos também valendo-se de algoritmos de visão computacional foram aplicados diretamente nas imagens originais. Os algoritmos foram a detecção de bordas de Canny, uma metodologia bastante utilizada historicamente para extração de lineamentos, e limiarização adaptativa gaussiana para binarização da imagem, esta última também utilizada na fase de pós-processamento deste trabalho.

Os valores máximo e mínimo para histerese utilizados no algoritmo de Canny foram, respectivamente 300 e 400, usando um operador de Sobel com tamanho 3×3 . Os parâmetros utilizados na etapa de limiarização e redução de artefatos foram os mesmos aplicados na Seção 4.2.3 e o resultado comparativo das extrações pode ser visto na Figura 18. É possível perceber que as extrações de Canny e limiarização obtiveram resultados muito distintos e pouco geológicos, o que será abordado mais a fundo no próximo Capítulo.

4.3- Comentários Finais

Este Capítulo versou sobre cada etapa da metodologia proposta por esta dissertação: a aquisição do conjunto de dados, criação do dado de referência, pré-processamento, treino do modelo de aprendizado de máquinas e pós-processamento. No Capítulo a seguir serão discutidos os resultados obtidos por este fluxo de trabalho, e a comparação com os outros algoritmos utilizados.

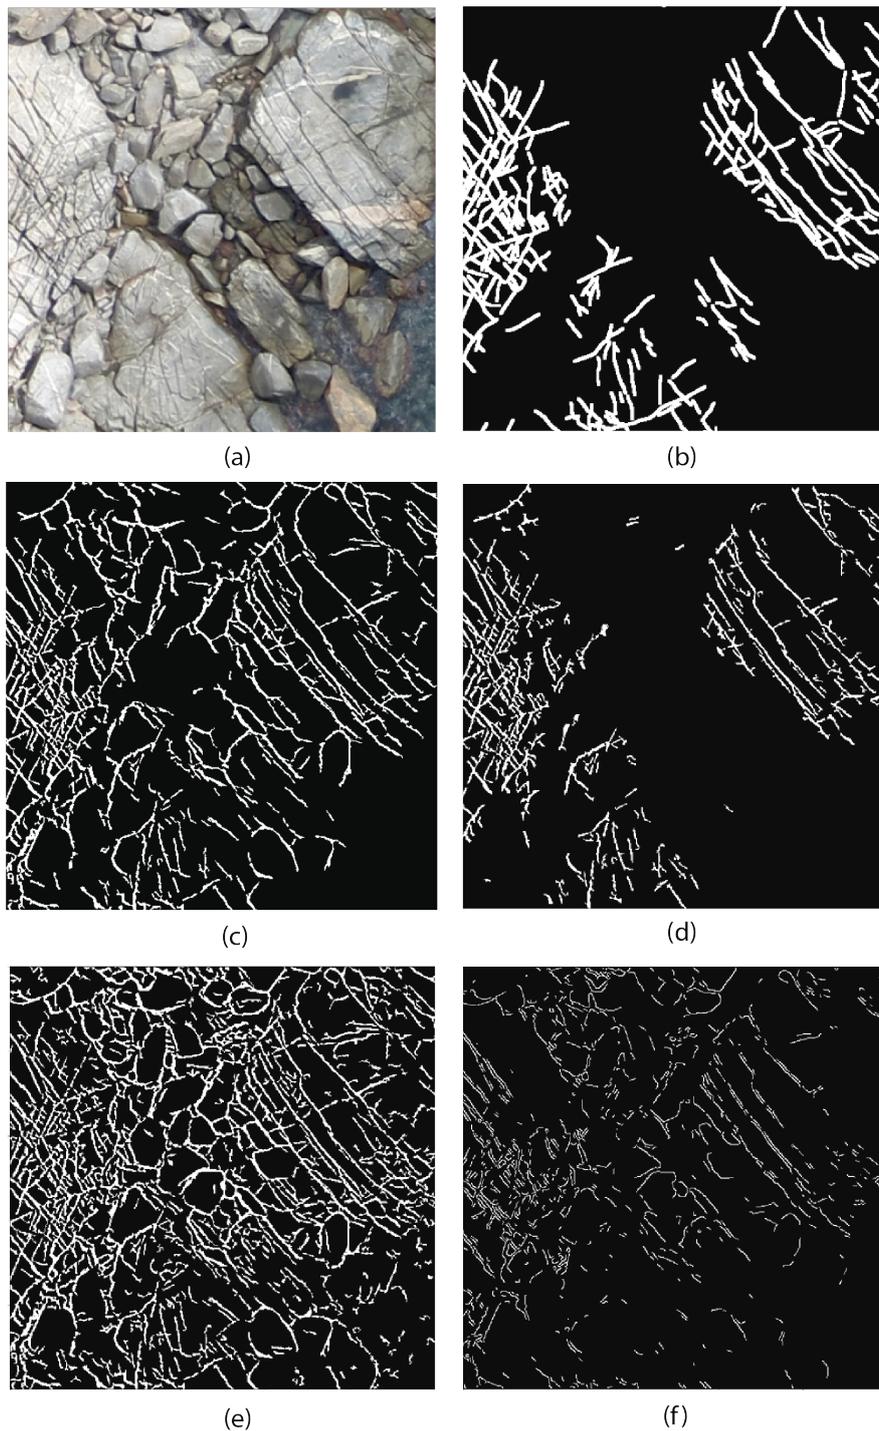


Figura 18 – Resultados do modelo de segmentação e pós-processamento, comparativamente a algoritmos de visão computacional clássicos. a) Imagem original. b) *Ground truth*. c) Resultados finais usando segmentação pela rede DenseNet 161 seguida de pós processamento proposto. d) Resultados finais usando segmentação pela rede DenseNet 264 seguida de pós processamento proposto. e) Segmentação baseada em reconhecimento de bordas Canny. f) Segmentação baseada em binarização a partir de limiarização adaptativa gaussiana.

5- Resultados

A avaliação do modelo de segmentação usando a arquitetura Densenet com 161 e 264 camadas resultou em uma medida de Interseção sobre União (IoU) de 74% e 65% respectivamente, indicando a efetiva capacidade do modelo da predição de área fraturada e resultados superiores aos algoritmos de visão computacional aplicados diretamente nas imagens originais. A medida de IoU, também conhecida como Índice de Jaccard, corresponde a razão entre interseção e a união de dois conjuntos:

$$IoU = \frac{|A \cap B|}{|A \cup B|}, \quad (13)$$

sendo neste caso, A os *pixels* de *ground truth* e B os *pixels* classificados como fraturas pela metodologia.

Tabela 2 – Interseção sobre união (IoU) dos resultados das diferentes técnicas de segmentação utilizadas nas imagens brutas. *Modelo Densenet com 161 e 264 camadas. **Com a etapa de dilatação do pós-processamento.

IoU das Classes	Canny	Binarização	D264*	D264* + Pós-Processamento**	D161*	D161* + Pós-Processamento
Fratura	0.06	0.08	0.39	0.49	0.59	0.66
<i>Background</i>	0.91	0.92	0.91	0.88	0.90	0.90
IoU médio	0.48	0.50	0.65	0.70	0.74	0.78

As máscaras oriundas da predição dos dois modelos DenseNet diferiram bastante, como pode ser observado na Figura 19. O modelo DenseNet de 161 camadas teve maior abrangência, prevendo mais *pixels* de fratura nas imagens, embora em alguns momentos de forma equivocada.

É interessante notar que, no caso da rede Densenet com 264 camadas, embora tendo sido obtidos resultados inferiores de IoU, as áreas preditas e processadas compreenderam em sua maioria apenas fraturas reais contidas nas imagens, ignorando, por exemplo, todos os fundos não rochosos, como telhados de casas, vegetação e *pixels* de água que poderiam introduzir algum erro no modelo.

A Figura 20 compara a binarização da imagem diretamente (Figura 20a) e ao utilizar a predição do modelo de segmentação como máscara e no seu interior aplicar o pós-processamento. O modelo de segmentação ignora corretamente estes *pixels* enquanto o fluxo composto

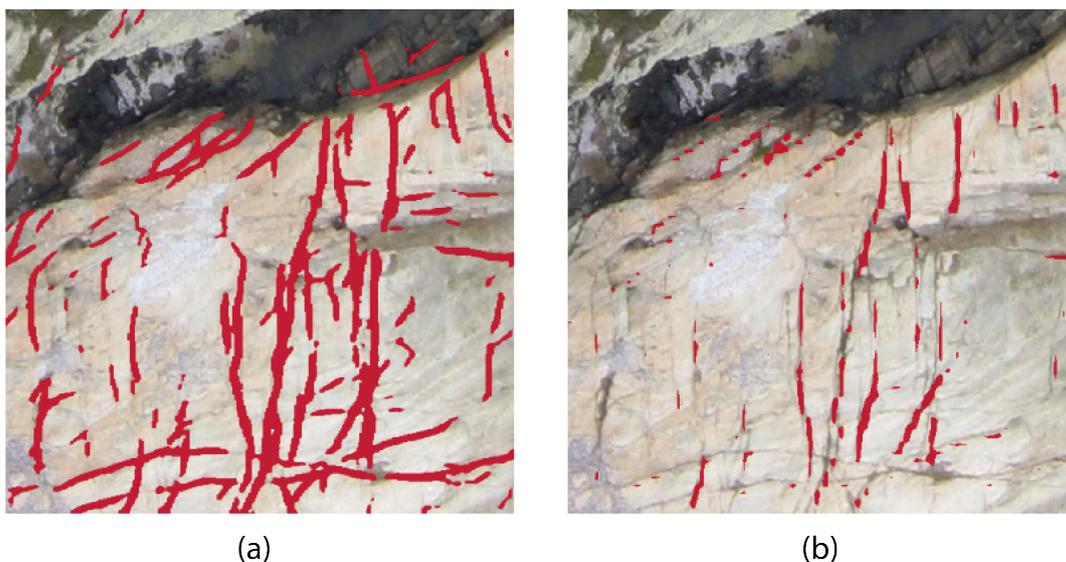


Figura 19 – Comparação entre as máscaras oriundas dos modelos DenseNet. a) Predição do modelo DenseNet com 161 camadas. b) Predição do modelo Densenet com 264 camadas.

puramente de técnicas de visão computacional clássicas interpreta blocos rochosos soltos e cascalho como bordas e estruturas lineares, o que resultaria em resultados severamente distorcidos nas tendências de direção, comprimento e densidade de fraturas. Este comportamento também ocorre nos resultados obtidos na rede DenseNet com 161 camadas (Figura 18c e Figura 21), embora a rede não faça a extração errônea na vegetação ou nas cenas de oceano.

Os pixels de fratura resultantes, no entanto, não capturaram completamente a geometria dos lineamentos no estudo, o que levou à introdução de metodologias de visão computacional mais clássicas para pós-processamento. O pós-processamento executado resultou em uma métrica de IoU mais alta para a classe de Fratura (Tabela 2) em ambos os modelos DenseNet, aumentando o IoU médio para 70% (264 camadas) e 78% (161 camadas). A Figura 22 compara os resultados finais de ambos os modelos.

Uma vez que este é o primeiro trabalho a apresentar o uso deste conjunto de dados para segmentação semântica ou predição de fraturas, não há nenhuma maneira de fazer *benchmark* dos resultados comparativamente a outras publicações. Por isso, a comparação neste trabalho foi feita de forma qualitativa com a interpretação geológica da área de estudo realizada em Savastano et al. [2017].

Para realizar a comparação entre os azimutes das fraturas preditas no grupo de validação com os azimutes contidos na interpretação geológica, as máscaras pós-processadas em seu estado final foram convertidas em linhas vetoriais usando a metodologia proposta em Lee et al.

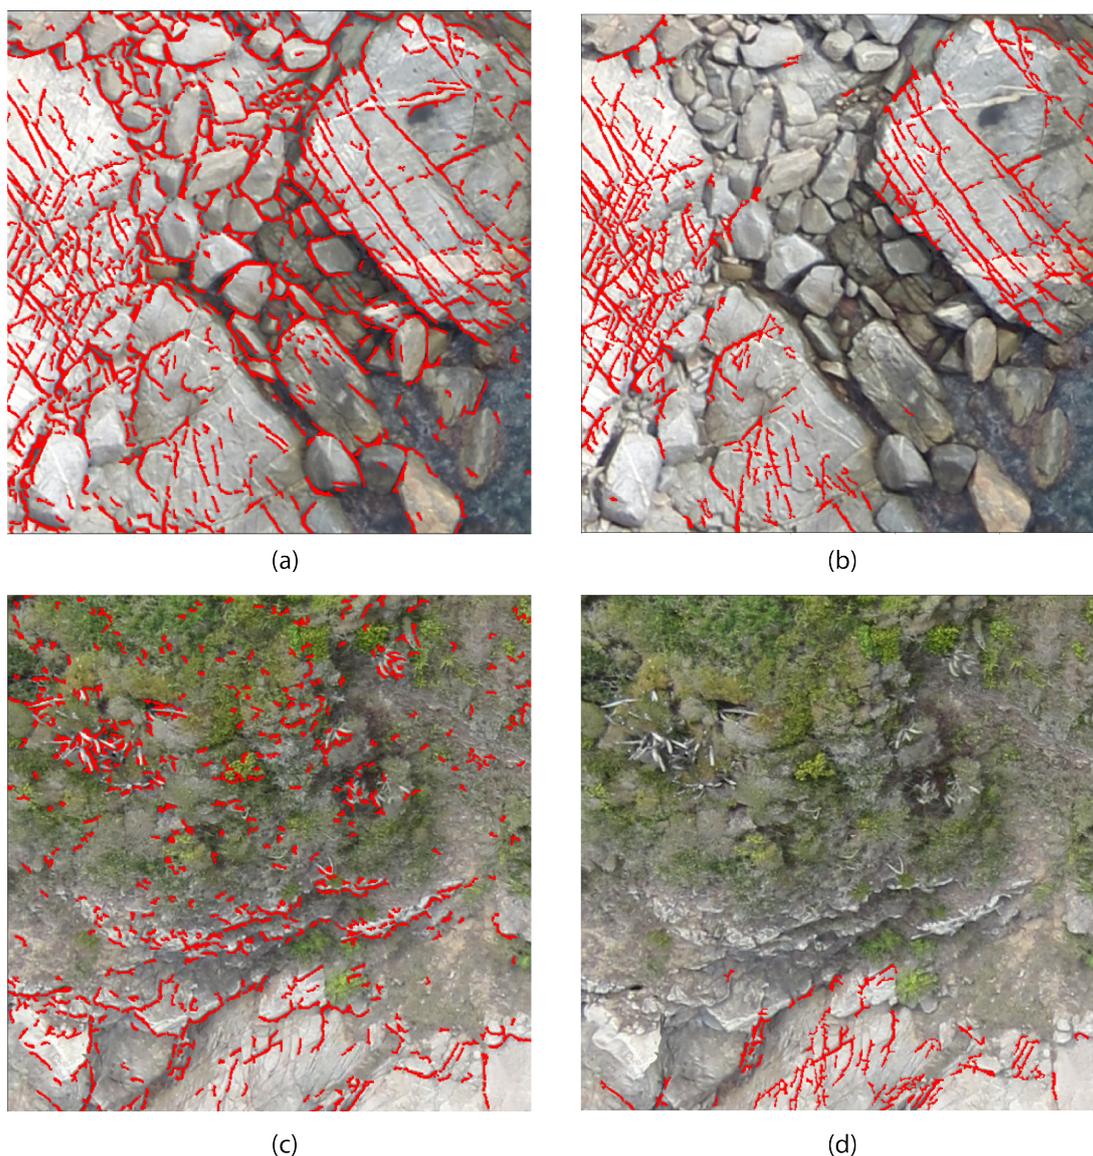


Figura 20 – a-c). Uso de extração de segmentos lineares a partir de visão computacional, como aplicado no pós-processamento, na imagem original inteira. b-d). Uso da mesma metodologia, porém apenas no interior das máscaras resultantes da segmentação semântica pelo modelo DenseNet com 264 camadas.

[2014]. A metodologia usa Canny para processar as bordas e conecta cada segmento de linha reta com seu vizinho, agregando sequencialmente novas linhas enquanto existir colinearidade com o segmento original.

A comparação de direções de *strike* (direção ao longo da estrutura, definido na Seção 2.1.3) do dado anotado e as estruturas preditas finais mostrou comportamentos e tendências muito similares, como visto na Figura 23. A Figura mostra os histogramas de distribuição de comprimento das fraturas e os gráficos do tipo roseta, que são histogramas polares, onde 0° é

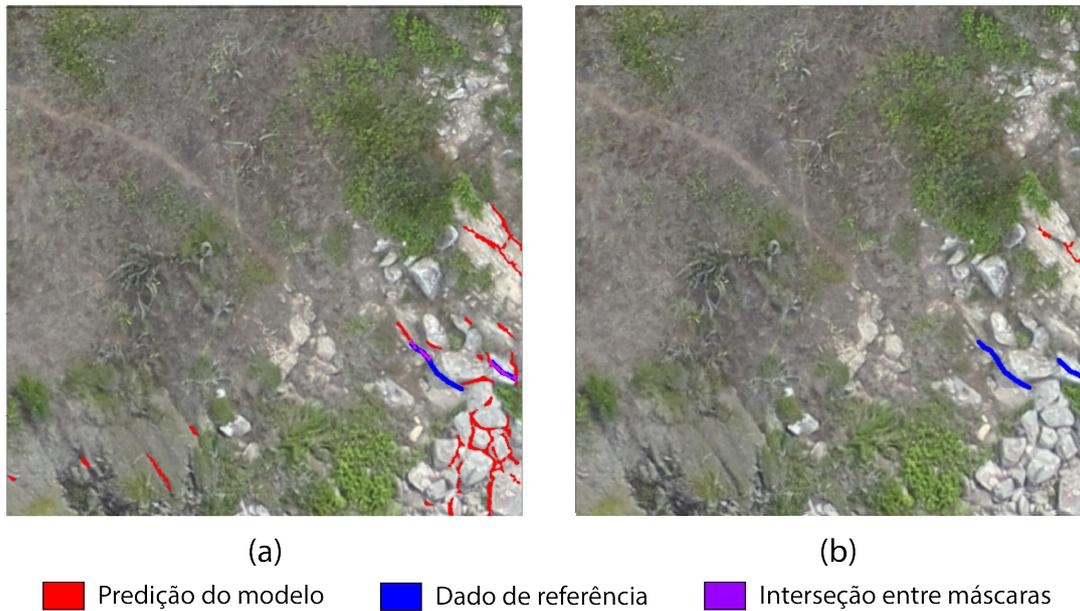


Figura 21 – a) Predição do modelo DenseNet com 161 camadas, com interpretação das estruturas ocorrendo em blocos soltos. b) Resultado do modelo Densenet com 264 camadas, sem a interpretação nos blocos.

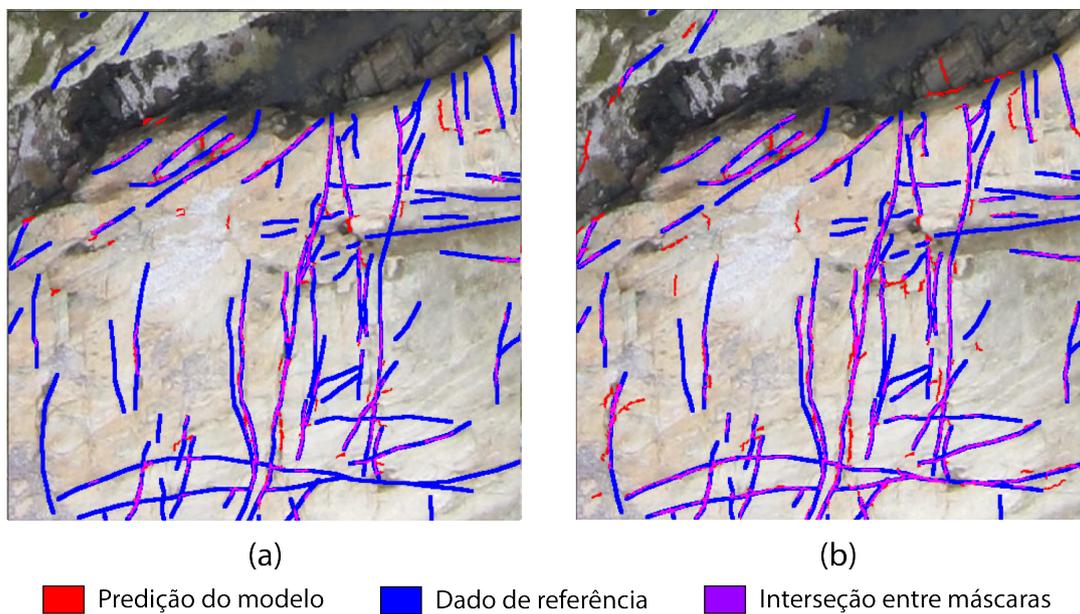


Figura 22 – Comparação entre as máscaras pós-processadas dos modelos DenseNet. a) Resultado do modelo DenseNet com 161 camadas. b) Resultado do modelo Densenet com 264 camadas.

o norte, 90° leste, 180° sul e 270° oeste, e as barras são a frequência da ocorrência da direção.

A segmentação exibiu uma tendência exacerbada N-S que não foi assim vista nos dados

de referência. Isto pode ser uma consequência do algoritmo de detecção de segmentos lineares quebrar as estruturas extraídas em segmentos menores, como pode ser notado na contagem de estruturas e histograma de distribuição de comprimento, assim como nas estatísticas das mesmas na Tabela 3. O algoritmo também produziu uma frequência maior de estruturas pequenas, de até 1 metro, e uma relativa não existência de fraturas acima de 10 metros.

Esta distorção pode introduzir erro em uma análise de geologia estrutural, criando um conjunto de fraturas geológicas não existente na região estudada. Ainda assim, a tendência norte-sul, embora mais sutil, ainda está presente no dado interpretado original, então tal exacerbação poderia não causar grande efeito na interpretação geológica.

Tabela 3 – Estatísticas das estruturas extraídas e do dado de referência. Note que todas as metodologia de extração produzem número de fraturas maior que o dado de referência.

Método	Número de Fraturas	Comprimento Médio (m)	Desvio Padrão	Comprimento Mínimo (m)	Comprimento Máximo (m)
Referência	5484	2.14	2.18	0.16	43.13
DenseNet 161	15115	0.80	0.84	0.20	11.94
DenseNet 264	8284	0.73	0.81	0.20	10.22
Binarização	13536	0.52	0.68	0.20	22.85
Canny	12893	0.51	0.64	0.20	22.85

5.1- Comentários Finais

Estes foram os resultados obtidos pela metodologia proposta. No próximo Capítulo, o último desta dissertação, serão expressas as conclusões adquiridas pela análise destes resultados, além da proposição de trabalhos futuros relacionados ao tema.

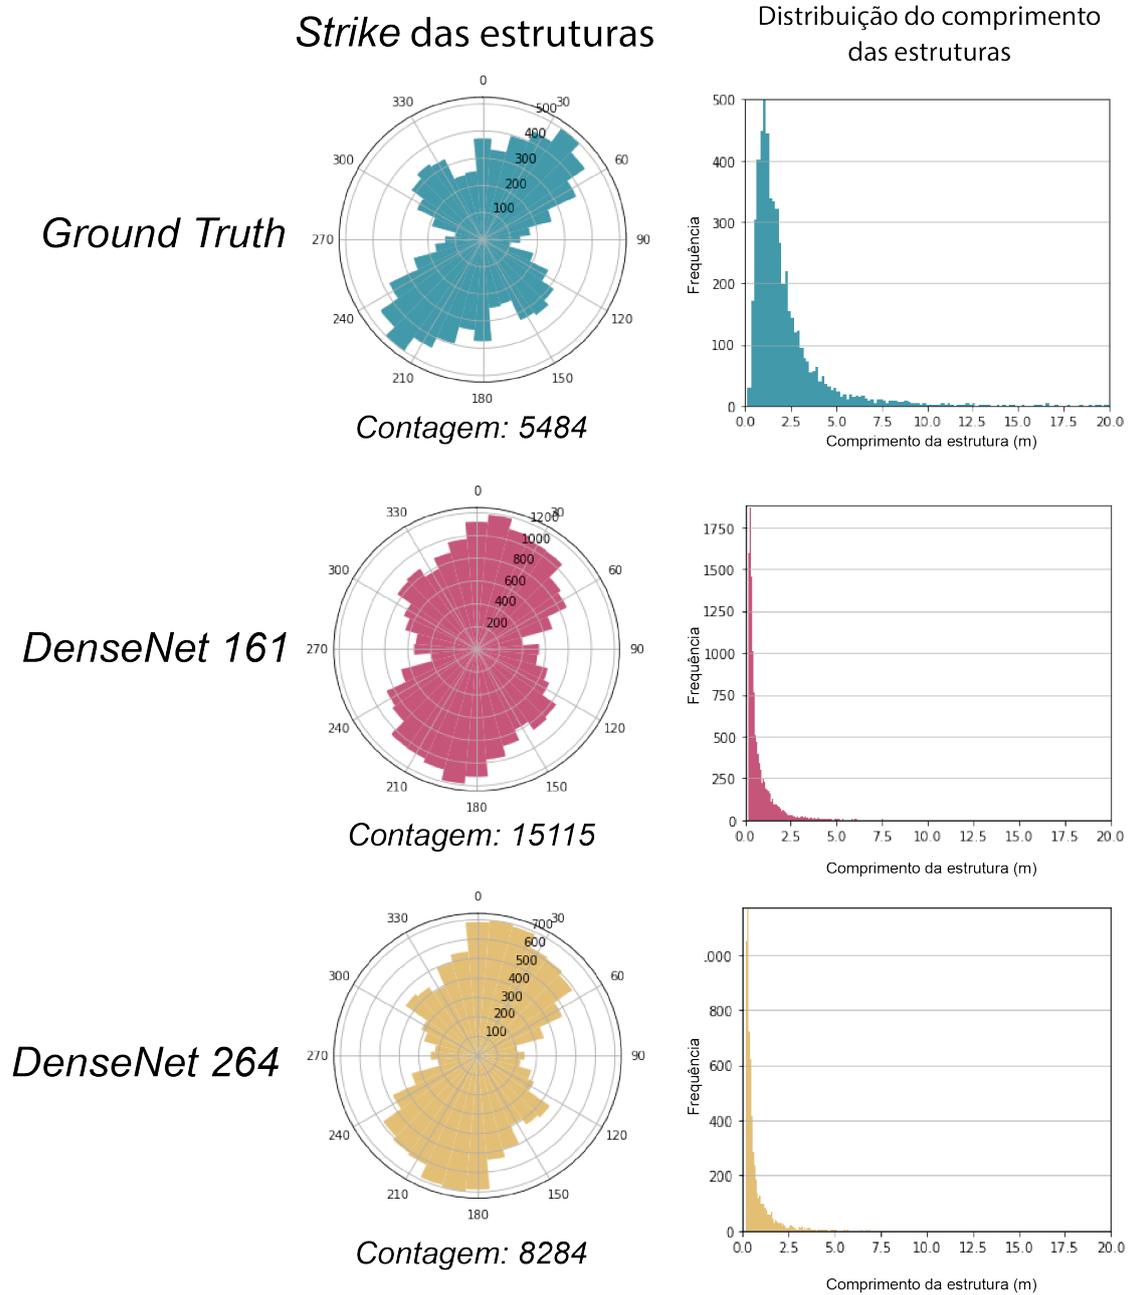


Figura 23 – Diagramas de roseta, à esquerda, exibindo direções de *strike* das estruturas oriundas do conjunto de avaliação e das previsões dos modelos de segmentação semântica, e os histogramas, à direita, de suas distribuições de comprimentos.

6- Conclusões

Este trabalho propôs uma combinação de segmentação semântica aplicando (), e, mais especificamente, (), e algoritmos de visão computacional para interpretação automática de estruturas geológicas para agilizar o trabalho de campo geológico, por exemplo, na exploração e produção de campos petrolíferos. As imagens foram obtidas usando VANTs em vez do imageamento de satélite para supera o problema de cobertura de nuvens.

Este trabalho construiu um conjunto de dados de imagens de VANT contendo dados de fraturas geológicas anotados por um especialista, os quais foram transformados em um dado de referência para treino de modelos de segmentação semântica. Para criar o dado de referência, *ground truth*, a metodologia aplicou análise de morfologia em uma interpretação geológica vetorizada.

Os dois modelos de segmentação construídos, DenseNet 161 e DenseNet 264, obtiveram resultados de 74% e 65% IoU médio, respectivamente, antes do pós-processamento. Em seguida, a segmentação resultante foi usada como uma máscara para binarização nas imagens originais, e uma série de etapas de pós-processamento foram aplicadas para extração de fraturas com precisão, aumentando o IoU para 78%, no caso da DenseNet 161, e 70%, no caso da DenseNet 264.

Comparativamente a outras duas técnicas de segmentação - uma aplicando o algoritmo de Canny e a outra binarização por limiarização adaptativa - aplicadas diretamente às imagens brutas, os resultados dos modelos de redes convolucionais foram mais precisos, com ou sem pós-processamento. Dentre as vantagens sobre os métodos clássicos, está a geração de predições pelo modelo somente em áreas rochosas contendo fraturas, ignorando a vegetação, oceano e construções artificiais, como telhados, casas, etc.

Note que converter as máscaras resultantes para vetores lineares novamente permitiu a comparação das direções azimutais das estruturas extraídas, o que exibiu tendências de direção muito similares às interpretadas manualmente naquele contexto geológico, embora exacerbando um grupo de fraturas N-S. Outra conclusão obtida foi que os modelos propostos geram um número de fraturas mais elevado que o anotado pelo geocientista, com comprimentos geralmente menores devido ao efeito de quebra das estruturas em vários segmentos pelos algoritmos de visão computacional

A automatização da interpretação das estruturas evita o trabalho manual árduo pelo geocientista, principalmente em áreas muito extensas, onde seria necessário a análise de um número muito grande de imagens. Estas técnicas, então, permitem a análise de grandes volumes de dados, gerando estatísticas importantes, como densidade de fraturas, relações entre comprimento e espessura, conjuntos de fraturas com direções distintas, dentre outros.

Os dados gerados por esta metodologia podem ser utilizados na construção de modelos preditivos numéricos para simulação de reservatórios, como de água e hidrocarbonetos, ou mesmo para outras tarefas, como avaliação de jazidas minerais, aplicação na engenharia civil e na geotecnia.

A partir destas constatações, conclui-se de grande importância a construção de uma metodologia como a proposta, usando imagens de VANTs para extração de estruturas geológicas, exibindo o potencial de segmentação e redes neurais convolucionais profundas para interpretação estrutural.

Os resultados oriundos deste trabalho deram origem a um artigo científico, ainda em fase de submissão para a revista *Computers and Geosciences*, sob o título *Semantic Segmentation for Automatic Extraction of Linear Geological Structures from UAV Imagery*.

6.1- Trabalhos Futuros

O uso de outros conjuntos de dados de imagens de VANTs, podendo conter distintos tipos de rocha e outras condições de iluminação, pode ajudar a aprimorar a generalização das predições do modelo, criando modelos passíveis de serem aplicados a áreas distintas. Também se propõe que se utilize outras arquiteturas de redes neurais para executar a segmentação semântica, e até, possivelmente, modelos de segmentação de instâncias, separando cada fratura em uma entidade distinta.

Outro ponto importante a ser trabalhado é a aprimoração da conversão das máscaras de segmentação em vetores, etapa que pode ter causado algumas distorções no resultado final e nas comparações azimutais, e que definitivamente traria problemas no uso das estatísticas geométricas das fraturas geológicas.

Referências Bibliográficas

- Aabø, T. M., Dramsch, J. S., Würtzen, C. L., Seyum, S., and Welch, M. (2020). An integrated workflow for fracture characterization in chalk reservoirs, applied to the Kraka Field. *Marine and Petroleum Geology*, 112(October 2019):104065.
- Adiri, Z., El Harti, A., Jellouli, A., Lhissou, R., Maacha, L., Azmi, M., Zouhair, M., and Bachaoui, E. M. (2017). Comparison of Landsat-8, ASTER and Sentinel 1 satellite remote sensing data in automatic lineaments extraction: A case study of Sidi Flah-Bouskour inlier, Moroccan Anti Atlas. *Advances in Space Research*, 60(11):2355–2367.
- Ahmadirouhani, R., Rahimi, B., and Hassan, M. (2017). Journal of African Earth Sciences Fracture mapping of lineaments and recognizing their tectonic significance using SPOT-5 satellite data : A case study from the Bajestan area , Lut Block , east of Iran. 134:600–612.
- Aslett, Z., Taranik, J. V., and Riley, D. N. (2018). Mapping rock forming minerals at Boundary Canyon, Death Valey National Park, California, using aerial SEBASS thermal infrared hyperspectral image data. *International Journal of Applied Earth Observation and Geoinformation*, 64(October 2017):326–339.
- Barki, H., Denis, F., and Dupont, F. (2009). Contributing vertices-based minkowski sum computation of convex polyhedra. *Computer-Aided Design*, 41(7):525–538.
- Batista, D. (2021). Automatic extraction methodology for linear geological structures from uavs. *Repositório GitHub*. <https://github.com/davibortolotti/saelgs>.
- Bay, H., Ferrari, V., and Van Gool, L. (2005). Wide-baseline stereo matching with line segments. *Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005*, 1(c):329–336.
- Biundini, I. Z., Pinto, M. F., Melo, A. G., Marcato, A. L., Honório, L. M., and Aguiar, M. J. (2021a). A framework for coverage path planning optimization based on point cloud for structural inspection. *Sensors*, 21(2):570.
- Biundini, I. Z., Pinto, M. F., Melo, A. G., Marcato, A. L. M., Honório, L. M., and Aguiar, M.

- J. R. (2021b). A framework for coverage path planning optimization based on point cloud for structural inspection. *Sensors*, 21(2).
- Bozinovski, S. (2020). Reminder of the first paper on transfer learning in neural networks, 1976. *Informatica (Slovenia)*, 44(3):291–302.
- Canny, J. (1986). A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6):679–698.
- Chiang, W.-C., Li, Y., Shang, J., and Urban, T. L. (2019). Impact of drone delivery on sustainability and cost: Realizing the uav potential through vehicle routing optimization. *Applied energy*, 242:1164–1175.
- Ciampalini, A., Solari, L., Giannecchini, R., Galanti, Y., and Moretti, S. (2019). Evaluation of subsidence induced by long-lasting buildings load using InSAR technique and geotechnical data: The case study of a Freight Terminal (Tuscany, Italy). *International Journal of Applied Earth Observation and Geoinformation*, 82(February):101925.
- de Alcantara Andrade, F. A., Reinier Hovenburg, A., Netto de Lima, L., Dahlin Rodin, C., Johansen, T. A., Storvold, R., Moraes Correia, C. A., and Barreto Haddad, D. (2019). Autonomous unmanned aerial vehicles in search and rescue missions using real-time cooperative model predictive control. *Sensors*, 19(19).
- Deffontaines, B., Chang, K. J., Lee, C. T., Magalhaes, S., and Serries, G. (2019). Neotectonics of the Southern Hengchun Peninsula (Taiwan): Inputs from high resolution UAS Digital Terrain Model, updated geological mapping and PSInSAR techniques. *Tectonophysics*, 767(February):128149.
- Del Sole, L., Antonellini, M., and Calafato, A. (2020). Characterization of sub-seismic resolution structural diagenetic heterogeneities in porous sandstones: Combining ground-penetrating radar profiles with geomechanical and petrophysical in situ measurements (Northern Apennines, Italy). *Marine and Petroleum Geology*, 117(April):104375.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In *2009 IEEE conference on computer vision and pattern recognition*, pages 248–255. Ieee.
- Epuh, E. E., Okolie, C. J., Daramola, O. E., Ogunlade, F. S., Oyatayo, F. J., Akinnusi, S. A., and Emmanuel, E. O. I. (2020). An integrated lineament extraction from satellite imagery

- and gravity anomaly maps for groundwater exploration in the Gongola Basin. *Remote Sensing Applications: Society and Environment*, 20(October 2019):100346.
- Fagbohun, B. J., Adeoti, B., and Aladejana, O. O. (2017). Litho-structural analysis of eastern part of Ilesha schist belt, Southwestern Nigeria. *Journal of African Earth Sciences*, 133:123–137.
- Fossen, H. (2010). *Structural Geology*. Cambridge University Press.
- Giuffrida, A., La Bruna, V., Castelluccio, P., Panza, E., Rustichelli, A., Tondi, E., Giorgioni, M., and Agosta, F. (2019). Fracture simulation parameters of fractured reservoirs: Analogy with outcropping carbonates of the Inner Apulian Platform, southern Italy. *Journal of Structural Geology*, 123(June 2018):18–41.
- Gobashy, M. M., EldougDoug, A., Abdelazeem, M., and Abdelhalim, A. (2021). Future development of gold mineralization utilizing integrated geology and aeromagnetic techniques: A case study in the barramiya mining district, central eastern desert of egypt. *Natural Resources Research*, pages 1–22.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. Adaptive computation and machine learning. MIT Press.
- Guo, Y., Liu, Y., Georgiou, T., and Lew, M. S. (2018). A review of semantic segmentation using deep neural networks. *International Journal of Multimedia Information Retrieval*, 7(2):87–93.
- Han, L., Liu, Z., Ning, Y., and Zhao, Z. (2018). Extraction and analysis of geological lineaments combining a DEM and remote sensing images from the northern Baoji loess area. *Advances in Space Research*, 62(9):2480–2493.
- Han, S., Li, H., Li, M., and Luo, X. (2019). Measuring rock surface strength based on spectrograms with deep convolutional networks. *Computers and Geosciences*, 133(August):104312.
- Hashim, M., Ahmad, S., Johari, M. A. M., and Pour, A. B. (2013). Automatic lineament extraction in a heavily vegetated region using Landsat Enhanced Thematic Mapper (ETM+) imagery. *Advances in Space Research*, 51(5):874–890.
- Heathfield, D. K. and Walker, I. J. (2015). Evolution of a foredune and backshore river complex on a high-energy, drift-aligned beach. *Geomorphology*, 248:440–451.

- Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*.
- Imamverdiyev, Y. and Sukhostat, L. (2019). Lithological facies classification using deep convolutional neural network. *Journal of Petroleum Science and Engineering*, 174(November 2018):216–228.
- Jan, B., Farman, H., Khan, M., Imran, M., Islam, I. U., Ahmad, A., Ali, S., and Jeon, G. (2019). Deep learning in big data analytics: A comparative study. *Computers Electrical Engineering*, 75:275–287.
- Khan, A., Sohail, A., Zahoor, U., and Qureshi, A. S. (2020). *A survey of the recent architectures of deep convolutional neural networks*. Number 0123456789. Springer Netherlands.
- Koike, K., Nagano, S., and Ohmi, M. (1995). Lineament analysis of satellite images using a Segment Tracing Algorithm (STA). *Computers and Geosciences*, 21(9):1091–1104.
- Lai, J., Chen, K., Xin, Y., Wu, X., Chen, X., Yang, K., and Song, Q. (2020). Fracture characterization and detection in the deep Cambrian dolostones in the Tarim Basin , China : insights from borehole image and sonic logs. *Journal of Petroleum Science and Engineering*, page 107659.
- Lary, D. J., Alavi, A. H., Gandomi, A. H., and Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1):3–10.
- Lee, J. H., Lee, S., Zhang, G., Lim, J., Chung, W. K., and Suh, I. H. (2014). Outdoor Place Recognition in Urban Environments Using Straight Lines. pages 5550–5557.
- Lei, Q., Latham, J. P., and Tsang, C. F. (2017). The use of discrete fracture networks for modelling coupled geomechanical and hydrological behaviour of fractured rocks. *Computers and Geotechnics*, 85:151–176.
- Luo, M., Glover, P. W., and Pan, H. (2019). A reassessment of the stress and natural fracture orientations from analysis of image logs in the Chinese Continental Scientific Drilling Program borehole at Donghai county, Jiangsu province, China. *Journal of Asian Earth Sciences*, 169(May 2018):11–20.

- Masoud, A. A. and Koike, K. (2011). Auto-detection and integration of tectonically significant lineaments from SRTM DEM and remotely-sensed geophysical data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6):818–832.
- Menegoni, N., Giordan, D., Perotti, C., and Tannant, D. D. (2019). Detection and geometric characterization of rock mass discontinuities using a 3D high-resolution digital outcrop model generated from RPAS imagery – Ormea rock slope, Italy. *Engineering Geology*, 252(March):145–163.
- Mercuri, M., Carminati, E., Tartarello, M. C., Brandano, M., Mazzanti, P., Brunetti, A., McCaffrey, K. J., and Collettini, C. (2020). Lithological and structural control on fracture frequency distribution within a carbonate-hosted relay ramp. *Journal of Structural Geology*, 137(December 2019):104085.
- Momeni, A., Rostami, S., Hashemi, S., Mosalman-Nejad, H., and Ahmadi, A. (2019). Fracture and fluid flow paths analysis of an offshore carbonate reservoir using oil-based mud images and petrophysical logs. *Marine and Petroleum Geology*, 109(June):349–360.
- Nash, C. R., Rankin, L. R., Leeming, P. M., and Harris, L. B. (1996). Delineation of lithostructural domains in northern Orissa (India) from Landsat Thematic Mapper imagery. *Tectonophysics*, 260(4):245–257.
- Nguemhe Fils, S. C., Bekele Mongo, C. H., Nkouathio, D. G., Mimba, M. E., Etouna, J., Njandjock Nouck, P., and Nyeck, B. (2018). Radarsat-1 image processing for regional-scale geological mapping with mining vocation under dense vegetation and equatorial climate environment, Southwestern Cameroon. *Egyptian Journal of Remote Sensing and Space Science*, 21:S43–S54.
- Oliveira, M. J. R., Savastano, V., Matos, G., Schmitt, R. S., Valente, V. C., Araújo, M. N., and Inocêncio, L. C. (2020). The use of drones and deep learning to identify igneous rocks and fractures. *Offshore Technology Conference Brasil 2019, OTCB 2019*.
- Olivia, L., Bom, C. R., Faria, E. L., Blanco, M., and Coelho, J. M. (2020). Journal of Petroleum Science and Engineering Automatic detection of fractures and breakouts patterns in acoustic borehole image logs using fast-region convolutional neural networks. *Journal of Petroleum Science and Engineering*, 191(June 2019):107099.

- Pinto, M. F., Honorio, L. M., Melo, A., and Marcato, A. L. (2020). A robotic cognitive architecture for slope and dam inspections. *Sensors*, 20(16):4579.
- Pleiss, G., Chen, D., Huang, G., Li, T., van der Maaten, L., and Weinberger, K. Q. (2017). Memory-efficient implementation of densenets. *arXiv preprint arXiv:1707.06990*.
- Price, N. and Cosgrove, J. (1990). *Analysis of Geological Structures*. Cambridge University Press.
- Raghavan, V., Masumoto, S., Koike, K., and Nagano, S. (1995). Automatic lineament extraction from digital images using a segment tracing and rotation transformation approach. *Computers and Geosciences*, 21(4):555–591.
- Raghavan, V., Wadatsumi, K., and Masumoto, S. (1993). Automatic extraction of lineament information from satellite images using digital elevation data. *Nonrenewable Resources*, 2(2):148–155.
- Saepuloh, A., Haeruddin, H., Heriawan, M. N., Kubo, T., Koike, K., and Malik, D. (2018). Application of lineament density extracted from dual orbit of synthetic aperture radar (sar) images to detecting fluids paths in the wayang windu geothermal field (west java, indonesia). *Geothermics*, 72:145–155.
- Saint Jean Patrick Coulibaly, H., Talnan Jean Honoré, C., Naga, C., Claude Alain Kouadio, K., Régis Mailly DIDI, S., Diedhiou, A., and Savane, I. (2020). Groundwater exploration using extraction of lineaments from SRTM DEM and water flows in Béré region. *Egyptian Journal of Remote Sensing and Space Science*, (xxxx).
- Salvini, R., Mastroiocco, G., Seddaiu, M., Rossi, D., and Vanneschi, C. (2017). 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*, 8(1):34–52.
- Savastano, V. L. M. and Batista, D. B. (2021). Fractures in uav imagery for segmentation. <https://dx.doi.org/10.21227/5939-y446>.
- Savastano, V. L. M., Schmitt, R. d. S., de Araújo, M. N. C., and Inocêncio, L. C. (2017). Rift brittle deformation of SE-Brazilian continental margin: Kinematic analysis of onshore structures relative to the transfer and accommodation zones of southern Campos Basin. *Journal of Structural Geology*, 94:136–153.

- Schultz, R. A. and Fossen, H. (2008). Terminology for structural discontinuities. *American Association of Petroleum Geologists Bulletin*, 92(7):853–867.
- Shelhamer, E., Long, J., and Darrell, T. (2017). Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4):640–651.
- Siddiqui, N. A., Ramkumar, M., Rahman, A. H. A., Mathew, M. J., Santosh, M., Sum, C. W., and Menier, D. (2019). High resolution facies architecture and digital outcrop modeling of the Sandakan formation sandstone reservoir, Borneo: Implications for reservoir characterization and flow simulation. *Geoscience Frontiers*, 10(3):957–971.
- Sohail, G. M., Hawkes, C. D., and Yasin, Q. (2020). An integrated petrophysical and geomechanical characterization of Sembar Shale in the Lower Indus Basin, Pakistan, using well logs and seismic data. *Journal of Natural Gas Science and Engineering*, 78(December 2019):103327.
- Soto-Pinto, C., Arellano-Baeza, A., and Sánchez, G. (2013). A new code for automatic detection and analysis of the lineament patterns for geophysical and geological purposes (ADALGEO). *Computers and Geosciences*, 57:93–103.
- Srisha, R. and Khan, A. (2013). Morphological Operations for Image Processing : Understanding and its Applications. *NCVSComs-13*, (December):17–19.
- Stead, D. and Wolter, A. (2015). A critical review of rock slope failure mechanisms: The importance of structural geology. *Journal of Structural Geology*, 74(October):1–23.
- Valentín, M. B., Bom, C. R., Coelho, J. M., Correia, M. D., de Albuquerque, M. P., de Albuquerque, M. P., and Faria, E. L. (2019). A deep residual convolutional neural network for automatic lithological facies identification in Brazilian pre-salt oilfield wellbore image logs. *Journal of Petroleum Science and Engineering*, 179(August 2018):474–503.
- Vasuki, Y., Holden, E. J., Kovesi, P., and Micklethwaite, S. (2014). Semi-automatic mapping of geological Structures using UAV-based photogrammetric data: An image analysis approach. *Computers and Geosciences*, 69:22–32.
- Wang, Z., Wu, F., and Hu, Z. (2009). MSLD: A robust descriptor for line matching. *Pattern Recognition*, 42(5):941–953.

- Weixing, W., Haijun, L., and Ying, H. (2007). Rock fracture tracing based on image processing and SVM. *Proceedings - Third International Conference on Natural Computation, ICNC 2007*, 1(Icnc):632–635.
- Wellner, P. D. (1993). Adaptive thresholding for the DigitalDesk. *Xerox, EPC1993-110*.
- Xu, J., Wen, X., Zhang, H., Luo, D., Li, J., Xu, L., and Yu, M. (2020). Automatic extraction of lineaments based on wavelet edge detection and aided tracking by hillshade. *Advances in Space Research*, 65(1):506–517.
- Zhou, Q., Yang, W., Gao, G., Ou, W., Lu, H., Chen, J., and Latecki, L. J. (2019). Multi-scale deep context convolutional neural networks for semantic segmentation. *World Wide Web*, 22.