

UNIVERSIDADE DO VALE DO RIO DOS SINOS — UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA
NÍVEL MESTRADO

LUCAS GABRIEL FERREIRA ALVES

**IDENTIFICAÇÃO DE FALHAS GEOLÓGICAS EM SÍSMICAS USANDO REDES
NEURAS CONVOLUCIONAIS**

São Leopoldo
2023

Lucas Gabriel Ferreira Alves

**IDENTIFICAÇÃO DE FALHAS GEOLÓGICAS EM SÍSMICAS USANDO REDES
NEURAS CONVOLUCIONAIS**

Dissertação apresentada como requisito parcial
para a obtenção do título de Mestre pelo
Programa de Pós-Graduação em Computação
Aplicada da Universidade do Vale do Rio dos
— UNISINOS

Orientador:
Prof. PhD. Sandro J. Rigo

São Leopoldo
2023

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)

Alves, Lucas Gabriel Ferreira

Identificação de falhas geológicas em sísmicas usando Redes Neurais Convolucionais / Lucas Gabriel Ferreira Alves — 2023.

69 f.: il.; 30 cm.

Dissertação (mestrado) — Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, São Leopoldo, 2023.

“Orientador: Prof. PhD. Sandro J. Rigo, Unidade Acadêmica de Pesquisa e Pós-Graduação”.

1. Falhas Geológicas. 2. Rede Neural Convolucional. 3. Geociências. I. Título.

CDU 004

Bibliotecária responsável: Silvana Dornelles Studzinski — CRB 10/2524

- "O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Brasil (CAPES) - Código de Financiamento 001 /"This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

Aos meus falecidos pais.

*If I have seen farther than others,
it is because I stood on the shoulders of giants.*
— SIR ISAAC NEWTON

AGRADECIMENTOS

Quero agradecer primeiramente a meu namorado Jonathas que é meu apoio, base e motivação, agradecer ao meu orientador que sempre esteve comigo durante todo o processo do mestrado se mostrando extremamente proativo e preocupado comigo. Também quero agradecer a minha família, especificamente aos meus tios, tia Roni e tio Ricardo que são meus segundos pais, tia Jacira, tia Bete, tia Nilda, minhas primas que estão sempre me ajudando em tudo, Renata, Roberta e Roselaine. Aos meus amigos Guilherme, Douglas, Felipe, Gefersom, Herbert, Tam, Tomás, entre outros amigos aqui não citados que me ajudaram com apoio ou outro meio. Por fim aos meus falecidos pais que me guiaram, por que se cheguei até aqui foi graças aos ensinamentos e educação dado por eles.

“Ninguém é tão grande que não possa aprender, nem tão pequeno que não possa ensinar.”.
(Anônimo)

ABSTRACT

Approaches using machine learning are being used to support activities in Geoscience. Among the possible applications, some are aimed at interpreting seismic data in tasks such as identifying features or identifying faults. In particular, this work assists the seismic interpretation and can bring gains by reducing manual work and the time spent studying the geological area. This dissertation describes how a tool capable of selecting points representing geometric sequences in seismic and discontinuities in these sequences can be developed. Thus, in this work, a study of types of deep neural networks in seismic geological data was done. From these works, we have the identification of 2D faults or fractures. Experiments with deep neural network training in seismic were also carried out to serve as the basis for the proposed work. With this study and these experiments, a new network architecture of the encoder-decoder type was proposed and evaluated, making image segmentation identify faults. This architecture is based on DNFS, StNet, and FaultNet networks. The work also generated contributions in producing and annotating a dataset with annotated seismic fault data available for access and used in experiments. Our future steps include fostering solutions to identify faults or critically stressed fractures according to the tension field.

Keywords: Geology Faults. Convolutional Neural Network. Geosciences.

RESUMO

Abordagens usando aprendizagem de máquina estão sendo cada vez mais utilizadas como apoio em atividades na Geociência. Dentre as aplicações possíveis, algumas são voltadas à interpretação de dados sísmicos em tarefas tais como identificação de feições ou falhas. Em particular, este trabalho auxilia na interpretação sísmica trazendo ganhos ao diminuir o trabalho manual e o tempo gasto ao se realizar o estudo da área geológica. Recursos de aprendizado supervisionado com uso de redes de aprendizado profundo têm sido identificados na literatura com bons resultados para este contexto, em atividades de segmentação. Este trabalho descreve o desenvolvimento de um estudo sobre métodos para apoio na detecção de fraturas em sísmica, a proposição de uma abordagem para esta detecção usando recursos de aprendizado supervisionado, bem como experimentos de avaliação. Com base nesse estudo e em experimentos preliminares, foi proposta e avaliada uma arquitetura de rede do tipo *encoder-decoder*, que atua na segmentação de imagens identificando as falhas. Esta arquitetura tem como base as redes DNFS, StNet e FaultNet. O trabalho também gerou contribuições na produção e anotação de um dataset com dados anotados de falhas em sísmica e sua disponibilização para experimentos. O estudo prevê como atividades futuras a identificação de falhas ou fraturas criticamente estressadas de acordo com o campo tensional.

Palavras-chave: Falhas Geológicas. Rede Neural Convolucional. Geociências.

LISTA DE FIGURAS

1	Amostras de rocha com destaque em preto para os poros. À esquerda, setas apontando para poros isolados; À direita, setas indicando poros conectados entre si, os quais permitem a passagem de fluídos. (adaptado de (LUQUOT; GOUZE, 2009)).	18
2	Perfil sísmico da área da Baía de Sepetiba, Rio de Janeiro. A imagem superior exhibe o perfil original e a imagem inferior exhibe o perfil após interpretação. (FRIEDERICHS et al., 2013).	19
3	Modelo de transmissão das rajadas de som através das múltiplas subcamadas rochosas, realizadas por um navio com fonte sísmica e geofones que captam estes resultados.	23
4	Uma falha (linha tracejada branca) em rochas intrusivas na Ilha Quadra, B.C. O dique rosa foi compensado pela falha e a extensão do desvio é mostrada pela seta branca (aproximadamente 10 centímetros). Como o lado mais distante da falha se moveu para a direita, esta é uma falha lateral direita.	23
5	Identificação dos principais tipos de falhas e seus respectivos movimentos de falha.	24
6	Exemplo de uma linha sísmica com uma discordância que põe em contato diferentes litologias. O horizonte que corresponde à discordância será positivo (pico), negativo (vale) ou terá uma amplitude muito baixa dependendo das litologias acima e abaixo.	25
7	Módulo de Young estimado a partir de aplicação de atributos sísmicos na sísmica geológica 3D, para visualização de diferentes características do modelo.	26
8	A figura ilustra : (a) Uma seção geológica; (b) Uma seção sísmica modelo correspondente à seção em "a"; (c) Detalhe do traço sísmico da extremidade esquerda em "a".	27
9	Identificação de diferentes ambientes sedimentares e suas respectivas interpretações.	27
10	Fluxo de uma arquitetura de rede neural convolucional mostrando cada etapa e suas características.	29
11	Diferença entre detecção de objetos e segmentação de instâncias - a esquerda temos detecção de objetos, a direita segmentação de instâncias.	30
12	Rotulagem de falhas - na esquerda temos rotulagem por segmentação e na direita temos por classificação binária, (falha ou não falha).	40
13	Comparação das arquiteturas de rede neural convolucional, a esquerda temos a arquitetura da rede StNet e a direita temos a arquitetura da rede DNFS respectivamente.	40
14	Fluxo da arquitetura de rede neural convolucional FaultNet, que tem foco em predição de falhas geológicas.	41
15	A nova arquitetura da rede neural convolucional proposta para predição de falhas geológicas.	42
16	Mapa da localização do cubo sísmico F3 Block, contendo a área mapeada, perfis sísmicos, seções geológicas e poços.	43
17	Volume sísmico Netherlands Offshore F3 Block sendo exibido da esquerda para direita em in-line, cross-line e z-slice no software OpendTect (EARTH SCIENCES, 2021).	43

18	Visualização do software OpendTect para geração da máscara de falhas - à esquerda temos a criação das falhas e à direita a criação da máscara.	44
19	Falha sendo exportada pelo software OpendTect para geração da máscara de falhas.	44
20	Sísmica 2D da inline 102 e sua respectiva máscara de falhas, geradas através cubo sísmico F3 Block utilizando o software OpendTect	45
21	Sísmica 2D sintética de (CUNHA et al., 2020), da seção 2600 com sua respectiva máscara de falhas sobreposta.	48
22	Imagem construída a partir de <i>patches</i> . A partir da sessão sísmica com corte real (na esquerda) é obtida a imagem com máscara (na direita), contendo os <i>Patches</i> das falhas (em vermelho) e máscara das falhas (em azul).	48
23	Imagens geradas com os testes para cada CNN com dados do projeto (CUNHA et al., 2020). (A) VGG; (B) FFT; (C) MLP; (D) SVM.	49
24	Imagens sísmicas 2D em cross-line e in-line, que foram utilizadas como entrada na rede neural.	50
25	Resultados de predição da rede neural Waldeland nos dados sísmicos do projeto de (CUNHA et al., 2020).	50
26	Resultados de predição da rede neural VGG16 nos dados sísmicos do projeto de (CUNHA et al., 2020).	50
27	Sísmica sintética da linha 1796 e sua respectiva máscara de falhas, geradas através do projeto de (CUNHA et al., 2020).	51
28	Resultado da Sísmica com sua respectiva máscara de falhas, geradas através do treinamento da nova arquitetura.	53
29	Análise detalhada da imagem na área de fratura.	54
30	Resultado de treinamento com o dataset sintético, gerado através do treinamento da nova arquitetura.	54
31	Resultado de precisão e perda do treinamento e teste da nova arquitetura. . .	54
32	Experimento 1- Arquitetura proposta utilizando conjunto de dados sísmicos de (CUNHA et al., 2020).	55
33	Experimento 2 - Arquitetura proposta utilizando o novo conjunto de dados sísmicos chamado F3 Faults.	56
34	Experimento 3 - Validação do conjunto de dados sísmicos F3 Faults com aplicação de atributos/filtros no cubo sísmico	56
35	Validação da arquitetura proposta com o conjunto de dados sísmicos F3 Faults aplicando atributos em arquitetura diferente da proposta (StNet). . . .	57
36	Fluxo da aplicação da GANs em sísmica para melhorar a identificação de falhas.	63
37	Classe assets description no software Protegé.	64
38	Classe assets examples no software Protegé.	65
39	Classe seismic 2D no software Protegé.	65
40	Classe Facies no software Protegé.	66
41	Classe Attribute no software Protegé.	66
42	Classe Seismic 3D no software Protegé.	67
43	Classe Well Log no software Protegé.	67
44	Classe Lithologies no software Protegé.	68

LISTA DE TABELAS

1	As diferentes arquiteturas de redes neurais utilizadas nos artigos de análise. . .	35
2	Relação de artigos/trabalhos com seu conjunto de dados utilizados e sua predição que serão analisados neste estudo.	35
3	As diversas funções de perda que os artigos utilizaram em seus trabalhos. . .	36
4	A relação dos artigos de análise que utilizaram a função de Ativação.	36
5	A relação dos artigos que aplicaram a função Pooling nos seus respectivos trabalhos.	36
6	Os otimizadores utilizados pelos artigos nos seus respectivos trabalhos. . . .	37
7	A relação de aplicação de Data Augmentation nos artigos.	37
8	A relação das diferentes técnicas utilizadas nos artigos de análise.	38
9	Comparação dos resultados de Acurácia, Sensibilidade, Especificidade, Es- core F1 e Curva AUC-ROC em cada rede neural.	48
10	Comparação dos tempos de processamento para cada rede neural aplicada. .	49

LISTA DE ABREVIATURAS

2D	Bi-Dimensional
3D	Three-Dimensional
etc.	Et cetera

LISTA DE SIGLAS

AI	Artificial Intelligence
API	Application Programming Interface
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CNN	Convolutional Neural Network
DL	Deep Learning
ML	Machine Learning
MLP	Multilayer Perceptron
RNN	Recurrent Neural Network
ROC	Receiver Operating Characteristic Curve
SVM	Support Vector Machine

LISTA DE SÍMBOLOS

Ω	Omega
ms	Milliseconds
Σ	Summation

SUMÁRIO

1 INTRODUÇÃO	17
1.1 Contexto e motivação	17
1.2 Problema	19
1.3 Questão de pesquisa e objetivos	20
1.3.1 Questão de pesquisa	20
1.3.2 Objetivo Geral	20
1.3.3 Objetivos Específicos	21
1.4 Metodologia	21
1.5 Estrutura do texto	21
2 FUNDAMENTAÇÃO TEÓRICA	22
2.1 Geofísica	22
2.1.1 Sísmica de reflexão	22
2.1.2 Falhas geológicas ou fraturas	22
2.1.3 Horizontes	25
2.1.4 Atributo Sísmico	25
2.1.5 Traço Sísmico	26
2.1.6 Fácies Sísmicas	26
2.2 Aprendizado de Máquina	28
2.2.1 Redes Neurais Convolucionais	28
2.2.2 Segmentação	29
2.2.3 Função de Ativação	29
2.2.4 Função de Perda	31
2.2.5 Medidas de Avaliação ou Métricas	31
3 REVISÃO DE LITERATURA	33
3.1 Trabalhos Relacionados	33
3.1.1 Métodos convencionais	33
3.1.2 Métodos baseados em aprendizado profundo	34
3.2 Avaliação e oportunidades de pesquisa	38
4 MATERIAIS E MÉTODOS	39
4.1 Arquitetura	39
4.2 Dados	42
4.3 Aspectos gerais adotados no treinamento	45
5 EXPERIMENTOS E RESULTADOS	47
5.1 Experimento com projeto Seismic fault detection	47
5.2 Experimento com Seismic Transfer Learning	49
5.3 Experimentos com arquitetura proposta	51
5.3.1 Coleção de Dados	51
5.3.2 Aumento de Dados	52
5.3.3 Treinamento	52
5.3.4 Métricas	52
5.3.5 Comparações e Resultados	52

6 CONCLUSÃO	58
6.1 Contribuição	58
6.2 Trabalhos futuros	59
REFERÊNCIAS	60
ANEXO A – ANEXOS COM EXPERIMENTOS COMPLEMENTARES	63
A.1 Experimento com aplicação de GANs para melhorar identificação de falhas	63
A.2 Seismic Ontology	64
A.2.1 2D seismic	65
A.2.2 Tipos de Fácies	65
A.2.3 Tipos de Atributos	66
A.2.4 3D Seismic	66
A.2.5 Well Log	67
A.2.6 Lithologies	68
A.3 F3 Faults	68

1 INTRODUÇÃO

Este trabalho tem como objetivo o estudo da temática geral de identificação de falhas em dados sísmicos com uso de recursos de Aprendizagem de Máquina, em especial com a aplicação de redes profundas. A identificação de falhas é uma necessidade em exploração de petróleo e gás em subsuperfície. A aquisição de dados sísmicos permite que sejam identificados com precisão os trechos de falhas, porém a sua identificação manual é custosa e demorada. Os avanços dos recursos de aprendizagem de máquina permitem vislumbrar recursos de apoio ao profissional nesta área.

1.1 Contexto e motivação


O Petróleo é um hidrocarboneto que constitui uma importante fonte de energia atualmente, pois a realização de grande número de atividades depende de seu uso. Ele é utilizado principalmente em combustíveis automotivos, como a gasolina e o óleo diesel, também sendo utilizado no funcionamento das usinas termoeletricas. Trata-se de uma substância oleosa, altamente inflamável e de coloração negra ou castanho escura, de origem fóssil e não renovável (EARLE, 2019),(SERRA; SERRA, 2004). Para a exploração de hidrocarbonetos é muito importante e essencial reconhecer os diferentes tipos de rochas presentes em subsuperfície e suas propriedades químicas e físicas. A correta identificação e principalmente a quantificação de tais propriedades está intrinsecamente associada na determinação da viabilidade da exploração desse recurso.

Dentre as propriedades de rocha importantes para a identificação destacam-se a porosidade e a permeabilidade. A porosidade é a quantidade de espaços vazios (poros) presentes na rocha. Matematicamente é a razão do volume de poros e o volume de sólidos nestes minerais. Em subsuperfície esses poros podem estar preenchidos por hidrocarbonetos, o que é de interesse para a indústria do petróleo. Esses poros podem estar isolados ou conectados entre si, conforme ilustra a Figura 1. Já a permeabilidade é uma propriedade da rocha que indica a capacidade deste meio permitir o escoamento de fluidos (Rosa, 2006).

No processo de exploração de poços, as informações sobre parâmetros físicos de formações rochosas são coletadas durante a perfuração dos poços, sendo medidos por uma sonda contendo sensores diversos (por exemplo, perfis de Raio Gama, Sônico ou Densidade) (SERRA; SERRA, 2004). Por meio da análise destes dados é possível inferir, com algum grau de precisão, porções do subsolo em que o óleo e/ou o gás podem estar presentes para serem extraídos. Além disso, existe outro método que permite a geração de uma imagem da subsuperfície para que posteriormente ela possa ser interpretada em termos de estruturas e estratigrafia (NICHOLS, 2013). Por meio do estudo das velocidades das ondas sísmicas, bem como seus padrões de reflexão e refração, é possível medir as espessuras de camadas subterrâneas com precisão (PRESS et al., 2006). A Figura 2 demonstra um exemplo do perfil original e de sua interpretação geológica.

O perfil sísmico permite o acesso, entre outras informações, à identificação de falhas na

Figura 1 – Amostras de rocha com destaque em preto para os poros. À esquerda, setas apontando para poros isolados; À direita, setas indicando poros conectados entre si, os quais permitem a passagem de fluídos. (adaptado de (LUQUOT; GOUZE, 2009)).




Fonte: Adaptado de Luquot and Gouze (2009)

subsuperfície. As falhas são estruturas geológicas criadas através de uma combinação de vários processos físicos, tais como pressões, efeito da gravidade, movimentos de placas tectônicas, entre outros. Constituem as fissuras ou os planos ao longo dos quais os blocos de rochas deslocam-se, através dos quais existe mais probabilidade de haver fluxo de líquidos. As falhas são muito diversas, tanto em tamanho como em formato, podendo ser observadas com poucos metros ou com muitos quilômetros (EARLE, 2019).

O mapeamento de falhas é um aspecto importante no contexto da exploração de petróleo e na análise de dados obtidos de sísmicas. Isso pois a análise do formato e da interrelação das falhas permite ampliar o entendimento sobre as probabilidades de localização de petróleo ou de reservatórios de gás no subsolo. O que determina esta importância é o fato das falhas atuarem como canais condutores para o deslocamento de hidrocarbonetos, permitindo também a acumulação de óleo em determinados locais. Além disso, o mapeamento de falhas permite a realização de análises sobre como estas influenciam a hidrodinâmica de um reservatório, o que pode significar alterações na permeabilidade do fluido. Isto influenciará diretamente a volumetria de óleo e gás como aspecto de engenharia mecânica de poços do desenvolvimento do campo petrolífero (EARLE, 2019).

É de especial interesse a identificação das falhas ou fraturas criticamente estressadas, ou seja, as fraturas orientadas em processo de cisalhamento. Isso porque em uma área de re-

Figura 2 – Perfil sísmico da área da Baía de Sepetiba, Rio de Janeiro. A imagem superior exibe o perfil original e a imagem inferior exibe o perfil após interpretação. (FRIEDERICHS et al., 2013).



Fonte: Autor Friederichs et al. (2013)

servatórios fraturados, em conjunto com a análise do campo de tensões, permite apoiar com elementos importantes a identificação de hidrocarbonetos. Levando-se em conta que o desempenho hidráulico ou permeabilidade das fraturas é influenciado pelo campo tensional, trata-se de um ponto importante de estudos.

1.2 Problema

De acordo com (OIKONOMOU et al., 2017), a exploração de óleo e gás é uma atividade cara, sendo que apenas um percentual dos poços perfurados resulta em possibilidade de utilização comercial. O aprendizado de máquina é amplamente utilizado em diversas indústrias para facilitar determinadas tarefas de análise de dados. No campo do óleo e gás, ele é aplicado para auxiliar geocientistas e engenheiros a localizar e desenvolver recursos econômicos de hidrocarbonetos (YUAN et al., 2020),(WU et al., 2021),(EARLE, 2019).

A área de pesquisa em redes neurais e redes neurais profundas para aprendizado de máquina vem desenvolvendo diversas soluções para apoiar a identificação de falhas em dados sísmicos. A literatura recente permite observar a aplicação de recursos de aprendizagem de máquina tradicional (GUITTON; WANG; TRAINOR-GUITTON, 2017) bem como abordagens derivadas de aprendizado profundo aplicado ao contexto de imagens (DI; GAO; ALREGIB, 2019), (ZHENG

et al., 2019), (WU et al., 2021). A seguir são comentados brevemente alguns aspectos nos trabalhos na área. No artigo de (DI; GAO; ALREGIB, 2019), é apresentado o desenvolvimento de uma rede neural chamada STNet, capaz de interpretar 12 tipos de padrões sísmicos simultaneamente, assim podendo gerar diferentes sismofácias da região a ser aplicada. Esta rede foi desenvolvida através da rede FaultNet (ZHENG et al., 2019). O trabalho de (ZHENG et al., 2019) também utiliza essa mesma rede neural para predição de falhas e além disso para identificar parâmetros elásticos da sísmica.

Uma das oportunidades de pesquisa observadas no contexto estudado é a integração de parâmetros de campo tensional à identificação das falhas. Estes parâmetros, caso associados com a identificação das falhas, possibilitariam adicionar uma camada de informação importante para a análise dos dados e do potencial de exploração (SERRA; SERRA, 2004),(NICHOLS, 2013),(GUITTON; WANG; TRAINOR-GUITTON, 2017). Neste contexto, a presente pesquisa prevê a utilização de padrões do estado da arte, como a rede FaultNet para desenvolver predições de falhas em sísmica e explorar a utilização de componentes de outras redes, como a rede StNet para analisar os resultados obtidos na predição de falhas geológicas (ZHENG et al., 2019).

1.3 Questão de pesquisa e objetivos

Levando em conta a análise do estado da arte realizada, bem como o potencial de contribuição para a área de exploração de petróleo, foi definida a seguinte questão de pesquisa, com os correspondentes objetivos.

1.3.1 Questão de pesquisa

O trabalho de pesquisa parte da hipótese de que é possível desenvolver um procedimento com uso de redes neurais artificiais e aprendizagem profunda que apoie a identificação de falhas e promova recursos para identificar suas características. A questão de pesquisa colocada é a seguinte: como deve ser organizado um procedimento envolvendo arquiteturas de redes neurais profundas para identificar falhas com dados sísmicos e posteriormente localizar fraturas com diferentes características.

1.3.2 Objetivo Geral

O presente trabalho, portanto, tem como objetivo gerar um procedimento que permite identificar falhas em dados sísmicos. Para isso será desenvolvida uma nova arquitetura de rede neural profunda que irá utilizar dados sísmicos para identificar as falhas.

1.3.3 Objetivos Específicos

Os objetivos específicos deste trabalho são listados a seguir:

- Verificar quais tipos de arquiteturas de redes neural artificial para aprendizado profundo estão sendo utilizadas com sucesso para esta identificação de falhas em dados sísmicos;
- Identificar quais atributos sísmicos proporcionam melhores visualizações das falhas criticamente estressadas;
- Apresentar uma nova arquitetura para identificação de falhas;
- Avaliar os resultados obtidos comparando com experimentos com outras arquiteturas de identificação de falhas geológicas.
- Contribuir com um novo *dataset* de sísmicas geológicas 2D.

1.4 Metodologia

Para a realização deste trabalho foi empregado o método de pesquisa experimental conforme Wazlawick (2009 p.42). Foi realizada a pesquisa do estado da arte de trabalhos com abordagens de detecção de falhas com recursos de aprendizado profundo. Foi realizada uma pesquisa bibliográfica para o desenvolvimento da fundamentação teórica com os principais conceitos relacionados ao tema. Após estas atividades foram analisadas oportunidades de implementação de redes neurais artificiais para identificação de falhas em dados de sísmica, bem como foram estudadas e analisadas possibilidades de acesso e uso a conjuntos de dados de sísmica disponíveis de forma aberta. Ao longo destas atividades foram realizadas consultas com especialistas, tendo como objetivo avaliar a qualidade dos recursos de conjuntos de dados a serem utilizados, bem como aprofundar o conhecimento sobre as demandas da área e também dos elementos presentes nos dados sísmicos que possuam potencial para apoiar a identificação de falhas e suas características. Foram realizados experimentos para testar a nova arquitetura proposta para identificação de falhas geológicas, além de comparar com diferentes arquiteturas de redes.

1.5 Estrutura do texto

O texto está estruturado da seguinte forma. No capítulo 2 são apresentados os conceitos utilizados para a realização deste trabalho. No capítulo 3 são destacados estudos que compõem o estado da arte sobre o tema. O capítulo 4 apresenta o contexto dos materiais e métodos deste trabalho. O capítulo 5 apresenta os resultados de experimentos da pesquisa e por fim, o capítulo 6 descreve a conclusão e trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta o embasamento teórico que fundamenta o presente trabalho. Na Seção 2.1 serão abordados conceitos de Geofísica relacionados à identificação de falhas geológicas e a Seção 2.2 apresenta os conceitos sobre redes neurais que são utilizados neste trabalho.

2.1 Geofísica

A Geofísica estuda as propriedades físicas da Terra (calor, magnetismo, radioatividade, gravidade, eletricidade, propagação de ondas elásticas etc.) para investigar seu interior, tanto nas camadas mais superficiais - onde se alojam os recursos minerais (petróleo, minérios, água) – quanto nas porções mais profundas de nosso planeta, que são conhecidas unicamente pelas informações geofísicas.

Quatro técnicas de levantamento geofísico são comumente usadas na exploração de petróleo: levantamentos gravimétricos, levantamentos aeromagnéticos, levantamentos eletromagnéticos e levantamentos sísmicos. De acordo com (ASHCROFT, 2011), "As pesquisas sísmicas têm uma longa história de uso na exploração de petróleo e são a ferramenta primária para delinear a estrutura de subsuperfície e detectar a presença de hidrocarbonetos antes da perfuração."

2.1.1 Sísmica de reflexão

A sísmica de reflexão envolve a transmissão de rajadas de som de alta energia e, em seguida, a medição dos ecos com uma série de geofones rebocados por um navio. A técnica está relacionada ao som. No entanto, muito mais energia é transmitida e a sofisticação do processamento de dados é muito maior. Conforme a técnica evoluiu e a quantidade de energia foi aumentada, tornou-se possível ver através dos sedimentos do fundo do mar e mapear a topografia rochosa e a espessura da crosta. Conforme (NICHOLS, 2013), a sísmica é "Uma imagem da subsuperfície para que posteriormente ela possa ser interpretada em termos de estruturas e estratigrafia".


A Figura 3 caracteriza de forma ilustrativa os principais elementos envolvidos nesta técnica.

No caso dos dados sísmicos 3D (volume sísmico), formados por várias linhas sísmicas, temos duas direções espaciais, que são chamadas de inline (direção das linhas sísmicas) e crossline (direção perpendicular às linhas sísmicas), além de uma direção temporal.

2.1.2 Falhas geológicas ou fraturas

Uma falha geológica é uma descontinuidade em um volume de rocha através do qual houve um deslocamento significativo como resultado do movimento do maciço rochoso. Segundo (EARLE, 2019) considera-se que "Uma falha é um limite entre dois corpos de rocha ao longo do qual houve movimento relativo", a Figura 4 apresenta um exemplo concreto desta ocorrência

Figura 3 – Modelo de transmissão das rajadas de som através das múltiplas subcamadas rochosas, realizadas por um navio com fonte sísmica e geofones que captam estes resultados.



Fonte: Adaptado de (L'IFREMER, 2021)

na natureza, já (SERRA; SERRA, 2004) diz que, "Uma falha é uma fratura ou uma zona de fraturas ao longo da qual houve deslocamentos dos lados em relação um ao outro. Os planos de falha resultam de tensões (tensionais, compressivas ou torcionais), geralmente de natureza descontínua, que são aplicadas às rochas".

Figura 4 – Uma falha (linha tracejada branca) em rochas intrusivas na Ilha Quadra, B.C. O dique rosa foi compensado pela falha e a extensão do desvio é mostrada pela seta branca (aproximadamente 10 centímetros). Como o lado mais distante da falha se moveu para a direita, esta é uma falha lateral direita.



Fonte: Autor (EARLE, 2019)

Grandes falhas dentro da crosta terrestre resultam da ação de forças das placas tectônicas,


com a maior formando os limites entre as placas, como zonas de subducção ou falhas de transformação. A liberação de energia associada ao movimento rápido em falhas ativas é a causa da maioria dos terremotos. As falhas também podem se deslocar lentamente, por fluência assísmica.

Um plano de falha é o plano que representa a superfície de fratura de uma falha. Um traço de falha ou linha de falha é um local onde a falha pode ser vista ou mapeada na superfície. Um traço de falha também é a linha comumente traçada em mapas geológicos para representar uma falha. Uma vez que as falhas geralmente não consistem em uma única fratura limpa, os geólogos usam o termo zona de falha ao se referir à zona de deformação complexa associada ao plano de falha.

2.1.2.1 Tipos de falhas

Falhas normais são aquelas produzidas pela distensão (e portanto por forças de extensão entre os blocos) causada devido à expansão da crosta terrestre. Falhas transcorrentes ou strike-slips são aquelas causadas igualmente por forças horizontais, sendo porém o plano de falha exclusivamente vertical. Falhas de empurrão ou reversas são aquelas que resultam das forças compressoras horizontais causadas pela contração da crosta terrestre, ou por encolhimento. Falhas criticamente estressadas são falhas hidraulicamente ativas, conforme mostra a Figura 5 a visão esquemática dos diferentes tipos de falhas citados acima.

Figura 5 – Identificação dos principais tipos de falhas e seus respectivos movimentos de falha.




Fonte: Adaptado de (SERRA; SERRA, 2004)

2.1.3 Horizontes

Um horizonte geológico é uma subsuperfície presente na localização geológica da região onde os dados foram adquiridos. Os horizontes se diferenciam por apresentarem características geológicas muito particulares, como a espessura da camada sedimentar que os define e as características físicas do material sedimentar que os compõem, além de sua vizinhança geológica.

O rastreamento de um horizonte sísmico consiste em identificar em qual dos voxels do volume sísmico está representado o horizonte desejado, identificando quais são as amostras pertencentes ao horizonte em questão. De acordo com (NICHOLS, 2013), "Na exploração de petróleo e gás e no desenvolvimento de campos para produção de hidrocarbonetos, os testemunhos são cortados através de 'horizontes-alvo', ou seja, partes da sucessão que foram identificadas a partir da interpretação da interpretação sísmica como prováveis rochas geradoras, ou, corpos reservatórios.", na Figura 6 é apresentada a interpretação destes elementos citados para um horizonte em dados sísmicos.

Figura 6 – Exemplo de uma linha sísmica com uma discordância que põe em contato diferentes litologias. O horizonte que corresponde à discordância será positivo (pico), negativo (vale) ou terá uma amplitude muito baixa dependendo das litologias acima e abaixo.



Fonte: Adaptado de (GEOEXPRO, 2022)


2.1.4 Atributo Sísmico

Os atributos sísmicos são quantidades de diferentes aspectos extraídos de dados sísmicos que fornecem informações confiáveis para a caracterização do subsolo, conforme (MISRA; MUKHERJEE, 2018), "Os atributos sísmicos atuam como filtros que removem uma característica dos dados sísmicos para revelar outra".

Os atributos sísmicos são quantidades derivadas dos dados sísmicos que descrevem a forma

ou outras características de um traço sísmico ao longo de um intervalo de tempo especificado, ou se os dados sísmicos foram convertidos para profundidade, ao longo de um intervalo de profundidade especificado. A Figura 7 exemplifica este contexto, com uma visualização destes aspectos dos atributos em um contexto de análise de dados.

Figura 7 – Módulo de Young estimado a partir de aplicação de atributos sísmicos na sísmica geológica 3D, para visualização de diferentes características do modelo.



Fonte: Autor (AMINZADEH; DASGUPTA, 2013)

2.1.5 Traço Sísmico

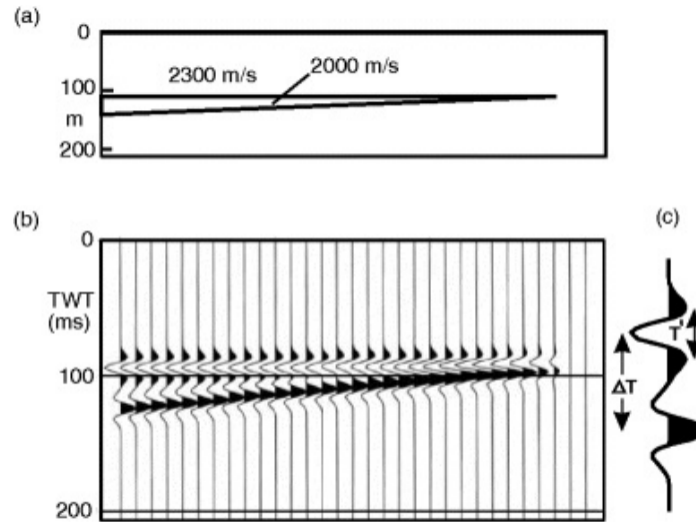
Um traço sísmico refere-se à curva registrada de um único sismógrafo ao medir o movimento do solo. O nome vem da curva traçada por um sismógrafo conforme o rolo de papel girava e a agulha deixava um traço do qual as informações sobre a subsuperfície podiam ser extraídas. Os instrumentos de hoje gravam os dados digitalmente, de acordo com (ASHCROFT, 2011), podem ser exibidos como um traçado oscilográfico – um sismograma ou gráfico de saída do receptor versus tempo.

O tempo é o tempo necessário para o som viajar até o refletor e voltar à superfície, por isso é chamado de tempo bidirecional (TWT) ou tempo de reflexão, a palavra trace passou a significar a curva digital. Na Figura 8 é descrito detalhes desta interpretação e do relacionamento destes aspectos.

2.1.6 Fácies Sísmicas

Uma fácies é um corpo de rocha com características especificadas, que pode ser qualquer atributo observável de rochas (como sua aparência geral, composição ou condição de formação) e as mudanças que podem ocorrer nesses atributos em uma área geográfica. É a soma total das

Figura 8 – A figura ilustra : (a) Uma seção geológica; (b) Uma seção sísmica modelo correspondente à seção em "a"; (c) Detalhe do traço sísmico da extremidade esquerda em "a".



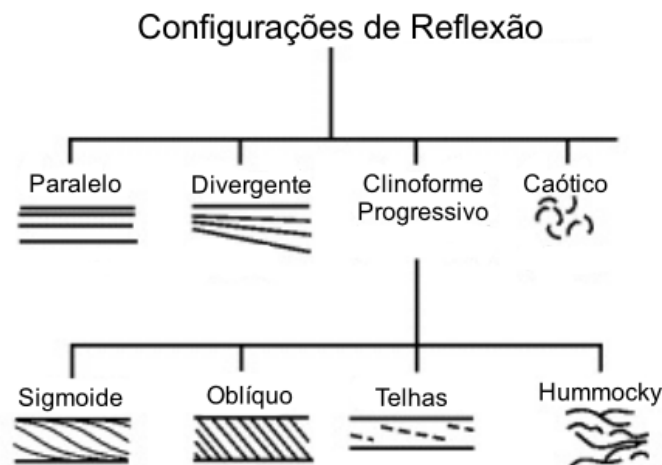
Fonte: Autor (ASHCROFT, 2011)

características de uma rocha, incluindo suas características químicas, físicas e biológicas que a distinguem de uma rocha adjacente.

De acordo com (ASHCROFT, 2011) foi reconhecido desde o início da estratigrafia sísmica que as características das reflexões dentro de uma sequência deposicional (amplitude, geometria) podem ser interpretadas em termos de fácies sedimentares.

A identificação das geometrias dos refletores sísmicos é o primeiro passo para a classificação das fácies e fornece informações sobre os processos deposicionais. Alguns exemplos são mostrados na Figura 9, juntamente com ambientes sedimentares interpretados.

Figura 9 – Identificação de diferentes ambientes sedimentares e suas respectivas interpretações.



Fonte: Adaptado de (ASHCROFT, 2011)

2.2 Aprendizado de Máquina

A Inteligência Artificial (IA) possui aplicações diretas em diversos campos, mas para o escopo deste trabalho serão abordados o Aprendizado de Máquina, Aprendizado Profundo e Redes Neurais Convolucionais voltadas para geologia (OIKONOMOU et al., 2017). A área de Inteligência Artificial desenvolve recursos para um sistema de computador que simula as funções cognitivas humanas, tais como o aprendizado e a solução de problemas.

O Aprendizado de Máquina, de acordo com (ZHANG, 2020) consiste, em uma de suas vertentes, na construção de modelos matemáticos com base em dados de amostra, a fim de efetuar previsões com uso destes modelos.

O Aprendizado Profundo é uma forma especializada do aprendizado de máquina e consiste em uma rede neural com diversas camadas intermediárias com um alto poder computacional de processamento, de acordo com (DENG; YU, 2014) “O Aprendizado Profundo se refere a muitas arquiteturas e técnicas de Aprendizado de Máquina, que usam um grande número de camadas de processamento de informações não-lineares de natureza hierárquica”.

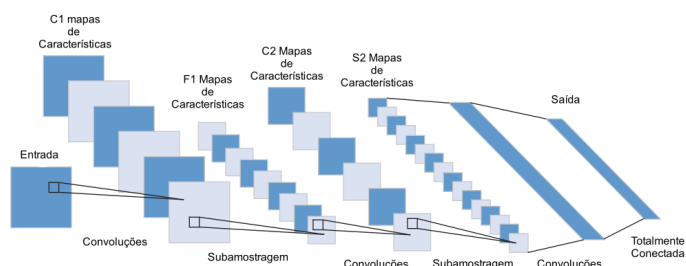
2.2.1 Redes Neurais Convolucionais

As redes neurais consistem de um subconjunto da área de aprendizado de máquina cuja abordagem possui como base o conhecimento atual sobre aspectos do funcionamento do cérebro humano. De acordo com (SCHMIDHUBER, 2015), "Uma rede neural consiste em muitos neurônios produzindo valores reais de ativação em sequência, com distintos tipos de neurônios (input ou outros) sendo ativados de formas diferentes (por exemplo, por meio de conexões de neurônios previamente ligados)”.

A rede neural convolucional é uma classe de rede neural artificial, classificada como feedforward, que tem como característica a tomada de decisão baseada apenas nas informações recebidas, repassando sua decisão aos neurônios da camada seguinte. A rede convolucional é amplamente aplicada ao processamento e análise de imagens digitais, projetada para reconhecer padrões diretamente de imagens de pixel 2D ou volumes de voxel 3D. Isso se deve à arquitetura de aprendizado profundo ser capaz de capturar informações contextuais semânticas, bem como recuperar informações espaciais. As redes convolucionais são inspiradas por processos biológicos, como a conectividade entre neurônios na organização do córtex visual. A convolução faz parte do processo de reconhecimento da rede convolucional, que é feita em 3 etapas: a convolução de cada camada de entrada; a aplicação de uma função de ativação não linear; subamostragem, denominado pooling (BISHOP, 2006). Cada uma das etapas da rede neural convolucional são visualizadas conforme a Figura 10.

Entre os métodos propostos, de acordo com (HASSABALLAH; AWAD, 2020) "as redes neurais convolucionais (CNNs) tornaram-se o padrão de fato, fornecendo grande precisão em muitas aplicações relacionadas à visão de máquina (por exemplo, classificação, detecção, seg-

Figura 10 – Fluxo de uma arquitetura de rede neural convolucional mostrando cada etapa e suas características.



Fonte: Adaptado de (XIE; ZHANG; BAI, 2017)

mentação) e reconhecimento de fala". Entre as muitas variantes de arquitetura de CNNs temos a LeNet, AlexNet, VGG, Inception ResNet e a arquitetura U-Net.


2.2.2 Segmentação

A Segmentação envolve a classificação de cada pixel da imagem, extraindo as partes do todo, diferente da classificação, como mostra a Figura 11. De acordo com (EL-AMIR; HAMDY, 2019), "Na visão computacional, a segmentação de imagens é o processo de particionar uma imagem digital em vários segmentos. O objetivo da segmentação é simplificar e/ou alterar a representação de uma imagem em algo mais significativo e mais fácil de analisar". Há 3 tipos de segmentação, a segmentação semântica, segmentação de instância e segmentação panóptica. A segmentação semântica não tem diferenciação de instâncias, já a segmentação de instância contém poucas classes, múltiplos objetos e regiões contendo objetos, sendo usada para detecção de objetos integrada a segmentação semântica. A segmentação panóptica tem múltiplos objetos junto com pixels das regiões contendo os objetos.

2.2.3 Função de Ativação

As funções de ativação da rede neural funcionam como um detector matemático, que possui como principal conceito o perceptron e são um componente crucial do aprendizado profundo. Estas funções determinam os valores de saída de um modelo de aprendizado profundo, determinando sua precisão bem como a eficiência computacional do modelo. Seu principal objetivo é converter um sinal de entrada de um nó de uma RNA em um sinal de saída.

Figura 11 – Diferença entre detecção de objetos e segmentação de instâncias - a esquerda temos detecção de objetos, a direita segmentação de instâncias.



Fonte: Adaptado de (EL-AMIR; HAMDY, 2019)

As funções de ativação são equações matemáticas que determinam os resultados de saída de uma rede neural. De acordo com (EL-AMIR; HAMDY, 2019), "A função é anexada a cada neurônio da rede e determina se ele deve ser acionado ou não. A função faz isso com base na verificação da entrada de cada neurônio e sua relevância para a previsão do modelo. As funções de ativação também ajudam a normalizar a saída de cada neurônio para um intervalo entre 1 e 0 ou entre -1 e 1".

Há diversos tipos de funções de ativação, como por exemplo a função de etapa binária, a função de ativação linear e a função de ativação não linear. A função de etapa binária é uma função de ativação baseada em limiar de valores. Isso significa que o resultado depende se está acima ou abaixo de um determinado valor limite. Se a saída do neurônio estiver acima do limite, o neurônio de ativação enviará exatamente o mesmo sinal para a próxima camada e vice-versa.

A função de ativação linear usa a equação $A = w * x$. Ele utiliza as entradas (x) multiplicadas pelos pesos de cada neurônio (w) e cria um sinal de saída proporcional à entrada. Em certo sentido, uma função linear é melhor do que uma função binária porque permite várias saídas, não apenas valores restritos.

A função de ativação não linear permite que o modelo crie mapeamentos complexos entre as entradas e saídas da rede, essenciais para aprender e modelar dados complexos, como imagens, vídeo, áudio e conjuntos de dados não lineares ou de alta dimensionalidade. Alguns dos tipos de funções de ativação não linear que são usados hoje em modelos de rede neural são sigmoid/logística, tanh/tangente hiperbólica, Rectified Linear Unit (RELU), leaky ReLU, softmax e swish.

2.2.4 Função de Perda

A função de perda é uma métrica de desempenho da rede neural para medir se esta consegue atingir seu objetivo de gerar saídas o mais próximo possível dos valores desejados. De acordo com (EL-AMIR; HAMDY, 2019), "A função de perda mais intuitiva é simplesmente a expressa pela equação perda = (saída real - saída do modelo)". Por exemplo, se 1,00 indicasse 100% de aprovação e 0 de 100% de reprovação, o modelo irá aprender com os dados e prevê um valor de 0,75 de perda, assim a perda real seria $1,00 - 0,75 = 0,25$. Se repetir o treinamento com algumas alterações de parâmetros e como resultado tivermos perdas acima de 0,25, o modelo irá entender que as alterações não ajudaram a rede a aprender adequadamente. Entretanto, caso a nova perda for menor que 0,25 isso indicaria que as mudanças são benéficas para o aprendizado.

Existem várias funções de perda padrão com base no tipo de resultado definidas em Aprendizado de Máquina e Aprendizado Profundo. Para casos de uso de regressão, estas são algumas funções de perda populares: Mean Squared Error, Mean Absolute Error, Binary cross-entropy e Categorical cross-entropy, também poderá ser utilizada a função de perda Jaccard Loss que tem por objetivo medir espacialmente o quanto as imagens preditas e reais estão correlacionadas.

2.2.5 Medidas de Avaliação ou Métricas

É nesse contexto de se encontrar o equilíbrio nos resultados do processamento que se faz uso de medidas de avaliação e análise da função de perda. A maioria das medidas de avaliação derivam de uma tabela chamada de Matriz de Confusão, que contém a quantidade de classificações corretas versus as classificações preditas para cada classe sobre um conjunto de exemplos, ou seja, ela indica os erros e acertos do modelo comparando com os resultados esperados. Para cada classe é realizada a extração de quatro variáveis: Verdadeiro positivo; Verdadeiro negativo; Falso positivo; Falso negativo.

A partir destas quatro variáveis definem-se várias métricas de avaliação. Algumas delas são comentadas brevemente a seguir.

A acurácia (Accuracy) representa a porcentagem de elementos classificados corretamente (positivos ou negativos), indica uma performance geral do modelo, de acordo com (ZAKI; MEIRA, 2020) "A acurácia fornece uma estimativa da probabilidade de uma previsão correta; assim, quanto maior o valor, melhor o classificador". A acurácia por classe indica a média das acurácias individuais para cada classe, minimizando o problema de desbalanceamento.

A precisão (Precision) define, dentre os exemplos classificados como positivos (pelo modelo), quantos eram realmente verdadeiros. Ela é utilizada onde os falsos positivos são considerados mais prejudiciais que os falsos negativos. Por exemplo: é pior classificar um investimento ruim como bom, do que classificar um investimento bom como ruim.

A revocação ou recall (Sensitivity) define, dentre todas as situações de classe positiva (dos valores esperados), quantas foram classificadas como verdadeiras. Ela é utilizada onde os falsos

negativos são considerados mais prejudiciais que os falsos positivos. Por exemplo: é bem pior classificar uma pessoa doente como saudável, do que classificar uma pessoa saudável como doente, considerando doente igual a positivo.

A especificidade (Specificity) é a porcentagem de amostras negativas identificadas corretamente sobre o total de amostras negativas. O F-Score ou F-Measure (F1 Score) representa a média ponderada de precisão e revocação.

A Intersecção por União ou Intersection Over Union (IoU) é utilizada na detecção de objetos como uma métrica para avaliar a precisão do modelo. A área não é necessariamente retangular. Pode ter qualquer forma regular ou irregular. Isso significa que as previsões são máscaras de segmentação e não caixas delimitadoras. Além disso, a definição de Verdadeiro Positivo, Verdadeiro Negativo, Falso Negativo é ligeiramente diferente, pois não é baseada em um limite predefinido.

3 REVISÃO DE LITERATURA

Este capítulo irá apresentar os principais artigos relacionados à temática desta pesquisa. Foi realizada uma revisão não sistemática de literatura, na qual os trabalhos foram revisados com o objetivo de identificar estudos sobre a utilização de Inteligência Artificial na identificação de falhas em sísmica. Levando em conta que a pesquisa atual busca projetar uma arquitetura que irá identificar as falhas geológicas, foram estudados trabalhos que apoiem estes objetivos.

Foi realizada uma busca de artigos pesquisando em recursos como o portal de periódicos da CAPES, Elsevier, IEEE Explore e ACM. Foram utilizadas palavras chaves como: deep learning; cnn; prediction; fracture, fault, seismic. Os critérios de avaliação utilizados foram o ano de publicação, o tipo de estudo, as técnicas de deep learning empregadas, os modelos de deep learning utilizados, bem como as métricas de avaliação e os datasets disponíveis nos experimentos. Com relação ao ano de publicação, foram filtrados os artigos com publicação de 2020 a 2022, mas foram encontrados trabalhos relevantes de anos anteriores como 2018 e 2019, que foram incluídos.

3.1 Trabalhos Relacionados

A seguir são descritos os trabalhos avaliados, organizados em categorias de métodos tradicionais e métodos automatizados envolvendo a utilização de aprendizado profundo.

3.1.1 Métodos convencionais

O conceito básico na interpretação de falhas sísmicas é identificar padrões em imagens sísmicas que se assemelham a feições de deformação frágil observadas em afloramentos, nos quais as camadas geológicas são deslocadas em relação umas às outras. Envolve o uso de modelos geológicos conceituais estabelecidos de geometrias de falha e deslocamentos para realizar e, em alguns casos, validar a interpretação. As falhas são normalmente interpretadas em cortes transversais 2D (ou seja, verticais) de um volume sísmico 3D pelo alinhamento das descontinuidades do refletor que têm sentido amplamente consistente e grande quantidade de deslocamento. Mesmo com dados sísmicos de boa qualidade, com altas taxas de sinal para ruído, a interpretação pode ser dificultada por uma escassez de refletores dentro de uma determinada sequência e aumento da complexidade estrutural. Como os fluxos de trabalho convencionais consomem muito tempo e são repetitivos manualmente, as falhas são frequentemente mapeadas seletivamente para economizar tempo e pouco esforço é feito para testar hipóteses alternativas. Na prática, as restrições de tempo na entrega de interpretações alternativas dentro de um ambiente de trabalho acelerado significam que pouca consideração é dedicada à incerteza de interpretação. Existem, portanto, benefícios potenciais significativos decorrentes do uso de técnicas que aumentam a qualidade e a velocidade de interpretação. Diferentes abordagens foram

adotadas e, nos últimos anos, os princípios da análise de imagens e inteligência artificial foram aplicadas a esta área (XIONG et al., 2018). No entanto, a maioria das pesquisas está em um estágio inicial, usando dados sintéticos para treinar um modelo de aprendizado profundo sem comparar modelos diferentes.

3.1.2 Métodos baseados em aprendizado profundo

Poucas publicações recentes descreveram abordagens para aplicar técnicas de aprendizado profundo em fluxos de trabalho de interpretação sísmica automática. A aplicação de aprendizado profundo tem melhor performance com computadores de alto desempenho, fornecendo uma excelente base para a aplicação de algoritmos de geração de superfície de falha e redução do tempo de interpretação significativamente, dependendo se uma rede neural treinada é usada (LU et al., 2018).

Alguns estudos desenvolveram métodos utilizando classificação de imagem para identificação de falhas (CUNHA et al., 2020). Outros estudos tratam a identificação de falhas como uma tarefa de segmentação de imagem (WU et al., 2019a), neste caso aplicando uma rede de segmentação de imagem clássica chamada UNet. A segmentação de imagens divide uma imagem em várias regiões (conjuntos de pixels) e associa padrões de falhas à alguns destes padrões.

Di (DI; GAO; ALREGIB, 2019) desenvolveu uma CNN que interpreta automaticamente 12 padrões sísmicos simultaneamente. Devido aos pixels de cada classe serem altamente desequilibrados, o modelo não tem um bom desempenho no reconhecimento de padrões associados a falhas. (WU et al., 2019a) treinam a UNet3D usando dados sintéticos e, posteriormente, testam em dados de campo sintéticos e reais. Seu modelo UNet3D tem um desempenho melhor do que os métodos convencionais em dados sintéticos e dados de campo com base em uma avaliação de especialista, mas devido à falta de conjuntos de dados de campo densamente rotulados, eles não foram capazes de quantificar o desempenho.

Neste estudo foi identificado o uso de diferentes arquiteturas utilizando Aprendizado de Máquina. A partir dos artigos estudados foi verificado um total de 12 arquiteturas diferentes. Dentre todos os trabalhos, um total de 6 estudos utilizou a rede neural convolucional chamada U-Net para treinamento dos dados geológicos em sísmica, conforme mostra na tabela 1.

Um resumo de aspectos de todos os artigos pesquisados é exibido na tabela 2, relacionando os estudos de acordo com dados utilizados e o tipo de predição observado como resultado do estudo.

Este trabalho pode observar uma tendência ao uso de alguns tipos de datasets. Em especial os conjuntos amplamente divulgados e de fácil acesso, tais como o Netherlands F3 Block, o que facilita os experimentos. Dos trabalhos estudados, apenas quatro deles disponibilizaram o dataset utilizado, tal como citado abaixo. Em todos os demais casos os dados originais não estavam disponíveis.

Os seguintes trabalhos e seus datasets abertos: (DI; GAO; ALREGIB, 2019) disponível em:

Tabela 1 – As diferentes arquiteturas de redes neurais utilizadas nos artigos de análise.

Arquiteturas	Artigos
FaultNet	A1, A2
StNet	A1
VGG16	A3
U-Net	A4, A5, A7, A12, A13, A14
FaultSeg3D	A5
FFT	A6
FE-MLP	A6
FE-SVM	A6, A10
Mobile DeepLabV3+	A7
RCF	A7
HED	A7
GANs	A11
Não Especificado	A8
Não Utilizado	A9

Fonte: Elaborada pelo autor.

Tabela 2 – Relação de artigos/trabalhos com seus conjunto de dados utilizados e sua predição que serão analisados neste estudo.

*	Autor	Dataset	Predição
A1	(DI; GAO; ALREGIB, 2019)	Netherlands F3 block	Falhas 3D
A2	(ZHENG et al., 2019)	Sísmica Sintética 3D	Falhas 3D
A3	(WU et al., 2021)	Sísmica Sintética 3D	Falhas 3D
A4	(LI et al., 2019)	Sísmica 2D	Falhas 2D
A5	(WU et al., 2019a)	Sísmica Sintética 3D	Falhas 3D
A6	(CUNHA et al., 2020)	Netherlands F3 block	Falhas 2D
A7	(AN et al., 2021)	Sísmica 2D e 3D	Falhas 2D
A8	(XIONG et al., 2018)	Sísmica Sintética 3D	Falhas 3D
A9	(COHEN; COULT; VASSILIOU, 2006)	Sísmica 3D	Falhas 3D
A10	(GUITTON, 2017)	Sísmica Sintética 3D	Falhas 3D
A11	(LU et al., 2018)	Sísmica Sintética 3D	Falhas 2D
A12	(GAO; HUANG; ZHENG, 2021)	Sísmica Sintética 2D e 3D	Falhas 2D e 3D
A13	(WEI et al., 2022)	Sísmica 2D e Sintética 2D	Falhas 2D
A14	(WU et al., 2019b)	Sísmica Sintética 2D	Falhas 2D

Fonte: Elaborada pelo autor.

haibindi.wixsite.com/haibin-di/software-tools; (WU et al., 2019a) disponível em: github.com/xinwucwp/faultSeg; (CUNHA et al., 2020) disponível em: github.com/augustoicaro/SFD-CNN-TL; (AN et al., 2021), disponível em: github.com/anyuzoey/CNNforFaultInterpretation.

Pode ser observado que diversos dos trabalhos recentes estudados utilizaram datasets com sísmica sintética, tanto 2D como 3D.

Os trabalhos em sua maioria, utilizaram treinamento supervisionado, o artigo A10 utilizou treinamento semi-supervisionado e os artigos A9 e A10 não especificam o tipo de treinamento utilizado para treinar a os dados geológicos.

A função de perda mais utilizada no treinamento dos dados geológicos, entre os artigos estudados, foi a função chamada Cross Entropy. Esta função foi utilizada em 6 dos 14 artigos estudados, conforme tabela 3.

Tabela 3 – As diversas funções de perda que os artigos utilizaram em seus trabalhos.

Função de Perda	Artigos
Cross Entropy	A1, A3, A4, A7, A8, A13
Log-Likelihood	A10
SVM	A10
Adversarial	A11
Mean Squared Error	A11
Smooth Dice	A12
Focal Loss	A14
Não Especificado	A2, A5, A6
Não Utilizado	A9

Fonte: Elaborada pelo autor.

A função de ativação que foi mais utilizada foi a RELU, esta que foi utilizada em 10 artigos, tendo a Softmax como segunda mais utilizada aplicando em 4 artigos que também utilizaram a RELU em seus treinamentos, dos 14 artigos 2 não especificaram qual função de ativação foi utilizada e 2 não utilizaram em seus trabalhos, conforme tabela 4.

Tabela 4 – A relação dos artigos de análise que utilizaram a função de Ativação.

Função de Ativação	Artigos
RELU	A2, A3, A4, A5, A6, A7, A8, A12, A13, A14
Softmax	A2, A5, A6, A8
Não Especificado	A1, A10
Não Utilizado	A9, A11

Fonte: Elaborada pelo autor.

Foi identificado que a função de Pooling mais utilizada entre os artigos estudados foi a função Max Pooling, sendo utilizada em 9 trabalhos, em segundo temos a função Global Average Pooling que foi utilizada pelo artigo A5. Os artigos A6 e A10 não especificaram qual foi a função de Pooling utilizada em seus treinamentos e os artigos A9 e A11 não utilizaram em seus treinamentos, conforme tabela 5.

Tabela 5 – A relação dos artigos que aplicaram a função Pooling nos seus respectivos trabalhos.

Função Pooling	Artigos
Max Pooling	A1, A2, A3, A4, A7, A8, A12, A13, A14
Global Average Pooling	A5
Não Especificado	A6, A10
Não Utilizado	A9, A11

Fonte: Elaborada pelo autor.

Para Otimizadores a função Adam foi a mais utilizando por 6 artigos para treinamento dos dados, a segunda função foi a Adadelta utilizada pelo artigo A5. Neste estudo 5 artigos não especificaram qual otimizador foi utilizado e os artigos A9 e A11 não utilizaram otimizadores, conforme tabela 6.

Tabela 6 – Os otimizadores utilizados pelos artigos nos seus respectivos trabalhos.

Otimizadores	Artigos
Adam	A1, A4, A7, A12, A13, A14
Adadelta	A5
Não Especificado	A2, A3, A6, A8, A10
Não Utilizado	A9, A11

Fonte: Elaborada pelo autor.

O Data Augmentation é utilizado para aumentar a quantidade de dados de treinamento da rede neural, assim foi identificado que o Data Augmentation mais utilizado foi o Horizontal Flipping, sendo utilizado em 6 artigos, outros 4 artigos utilizaram Rotation e Vertical Flipping, conforme tabela 7.

Tabela 7 – A relação de aplicação de Data Augmentation nos artigos.

Data Augmentation	Artigos
Horizontal Flipping	A1, A4, A6, A7, A11, A12
Rotation	A1, A3, A7, A14
Vertical Flipping	A1, A3, A7, A10
IAAEmboss	A7
GridDistortion	A7
OpticalDistortion	A7
RandomBrightnessContrast	A7
ElasticTransform	A7
Não Especificado	A2, A5, A10
Não Utilizado	A9, A13

Fonte: Elaborada pelo autor.

A técnica mais utilizada nos artigos foi a Dropout, esta que foi utilizada em 7 artigos para prevenir o sobre-ajustamento, também foi utilizada a técnica Batch Normalization em 5 artigos estudados, e 1 artigo utilizou a técnica Local Response Normalization. O artigo A3 e A10 não especificaram qual técnica utilizaram e os artigos A9 e A11 não utilizaram, conforme tabela 8.

Por fim, destaca-se uma tendência no uso de redes de aprendizado profundo de maior complexidade, esta análise servirá para aplicação destas características mais utilizadas na proposta da rede neural convolucional para identificação de falhas geológicas que será exibida no capítulo a seguir.

Tabela 8 – A relação das diferentes técnicas utilizadas nos artigos de análise.

Técnica	Artigos
Dropout	A1, A2, A4, A5, A6, A7, A13
Batch Normalization	A5, A12, A14
Local Response Normalization	A8
Não Especificado	A3, A10
Não Utilizado	A9, A11

Fonte: Elaborada pelo autor.

3.2 Avaliação e oportunidades de pesquisa

Métodos baseados em Redes Neurais Convolucionais tem mostrado resultados promissores em tarefas de interpretação de falhas geológicas. Com isso, foram identificados alguns desafios comuns.

O conjunto de dados geológicos de campo raramente tem código aberto, desta forma utilizam dados de sísmica sintética. Algumas interpretações acabam gerando ruídos ou desvios que influenciam o modelo treinado. Destaca-se a necessidade da geração de novos conjuntos de dados, gratuito, de sísmicas 2D reais com suas respectivas máscaras de falhas para treinamento de redes neurais.

Também destaca-se a necessidade de aplicação e classificação de diferentes atributos sísmicos para interpretação de falhas geológicas em Cubos sísmicos 3D, com o objetivo de identificar falhas em linhas sísmicas 2D.

De acordo com os estudos de trabalhos recentes, atualmente nenhuma métrica de identificação é especializada em diferenciar tipos diferentes de falhas, em trabalhos futuros será focado em como diferenciar de falhas criticamente estressadas, o que se constitui em uma oportunidade de pesquisa motivadora do trabalho atual.

4 MATERIAIS E MÉTODOS

Neste capítulo é descrito o procedimento de pesquisa proposto por este trabalho. De modo geral, serão utilizadas duas etapas de desenvolvimento e análise. Na primeira etapa, trata-se de utilizar uma rede neural do tipo codificador-decodificador para identificação de falhas sísmicas em dados de sísmica 2D. A partir desta etapa e destes resultados, busca-se elementos para aproximar a análise dos resultados de uma avaliação do campo tensional influenciando estas falhas. O motivador para este trabalho associa-se com uma lacuna de pesquisa observada nos trabalhos recentes da área, que não possuem suporte para apoiar os geólogos na análise de campo tensional afetando as falhas.

Pretende-se utilizar para os experimentos um conjunto de dados sísmicos disponível de forma aberta, o dataset Netherlands F3 Block. A partir deste dataset e de recursos de software serão desenvolvidos mecanismos de anotação de falhas para a geração de um novo dataset de sísmicas 2D com falhas anotadas.

A arquitetura a ser utilizada em experimentos será baseada em diversas redes neurais utilizadas neste contexto. A seguir são comentadas estas redes. A StNet é apresentada por (DI; GAO; ALREGIB, 2019), sendo aplicada sobre dados sísmicos para segmentação de fácies, classificando a sísmica 2D em 12 padrões diferentes de fácies. A DNFS é apresentada por (LIMA, 2021), sendo aplicada sobre dados sísmicos para segmentação de fácies. A rede FaultNet é apresentada por (ZHENG et al., 2019) e originalmente foi aplicada em dados sísmicos sintéticos para segmentação de falhas.

A arquitetura de rede proposta consiste em uma estrutura do tipo encoder-decoder que apoia a interpretação das falhas automaticamente nos dados sísmicos com menor tempo de treinamento e interpretação, comparado ao trabalho manual do geólogo.


4.1 Arquitetura

Esta seção apresenta a arquitetura de uma nova rede neural encoder-decoder desenvolvida como proposta neste trabalho. Esta rede neural pode ser considerada uma variante das redes StNet (DI; GAO; ALREGIB, 2019) e da DNFS (LIMA, 2021), ambas otimizadas para segmentação de fácies, além da FaultNet (ZHENG et al., 2019), otimizada para segmentação de falhas.

Conforme (ZHENG et al., 2019), as redes convolucionais podem ser utilizadas para identificar falhas em uma imagem sísmica, sendo necessário para isso considerar a identificação de falhas como um problema de segmentação de imagem. No caso de (WU et al., 2019a) observa-se um exemplo, onde a saída das redes neurais é uma imagem de máscara com o mesmo tamanho da imagem de entrada, sendo que cada pixel ou voxel na imagem de entrada é classificado por um rótulo binário como falha ou não. As arquiteturas de rede neural como SegNet (BADRINAYANAN; KENDALL; CIPOLLA, 2017) ou U-net (RONNEBERGER; FISCHER; BROX,

2015) podem ser usadas para este tipo de aplicação. A abordagem de segmentação indicada por (ZHENG et al., 2019), pode ser observada conforme ilustrado na Figura (12)."


Figura 12 – Rotulagem de falhas - na esquerda temos rotulagem por segmentação e na direita temos por classificação binária, (falha ou não falha).



Fonte: Adaptado de (ZHENG et al., 2019)

As três arquiteturas de redes, StNet, DNFS e FaultNet (ZHENG et al., 2019), possuem diferentes estruturas de filtro. A StNet, foi de 128 para 1024 filtros, uma transição de oito vezes na quantidade de filtros, como pode ser visto na Figura 13. A rede DNFS, transita de de 8Ω para 16Ω , com isto, (LIMA, 2021) observou que as previsões da StNet continham mais ruídos que as da DNFS, ou seja, as imagens compostas pelas previsões da StNet continham mais pixels pretos aleatórios que as advindas de DNFS. Estas arquiteturas abaixo serviram como base da nova arquitetura proposta.

Figura 13 – Comparação das arquiteturas de rede neural convolucional, a esquerda temos a arquitetura da rede StNet e a direita temos a arquitetura da rede DNFS respectivamente.



Fonte: Autor (LIMA, 2021)

A arquitetura da FaultNet não é encoder decoder e consiste em 12 camadas convolucionais 3D usando um tamanho de kernel uniforme $3 \times 3 \times 3$. O número do canal das camadas convolucionais começa em 16 e dobra após cada agrupamento máximo. Uma ativação ReLU é

aplicada após cada duas camadas convolucionais e um pooling máximo após cada quatro camadas convolucionais. Uma camada totalmente conectada (FC) com 256 neurônios conecta as camadas convolucionais e a camada de saída, onde um dropout de 50% é aplicado após FC para regularização, conforme mostra a Figura 14.

Figura 14 – Fluxo da arquitetura de rede neural convolucional FaultNet, que tem foco em previsão de falhas geológicas.




Fonte: Adaptado de (ZHENG et al., 2019)

A nova arquitetura possui como característica a arquitetura encoder-decoder, seguindo o exemplo da arquitetura das redes neurais DNFS e StNet, com o dobro de canais de camada convolucionais em cada agrupamento como na rede DNFS. Após cada camada convolucional serão aplicadas as funções de ativação ReLU e BatchNormalization, ao final de cada bloco de convolução, conforme mostra a Figura 15.

Esta nova arquitetura tem como entradas de tamanho de kernel 16 x 16, tendo todas as camadas funções de ativação ReLU, além de ser aplicado dropout entre estas entradas e realizado a função de maxpooling ao final, para então, a próxima camada ter um tamanho de kernel de 32 x 32, e assim sucessivamente até a quinta camada, que possui um tamanho de kernel de 256. Para as camadas deconvolucionais, todas tem a função ReLU, também são aplicados dropouts entre as entradas, com o tamanho de kernel sendo reduzido de 128 x 128 para 64 x 64 e assim sucessivamente até a última camada, na qual é aplicada uma função Sigmoid.

Desta forma a arquitetura proposta incorpora aspectos considerados relevantes nos trabalhos científicos analisados, o que permite que seja utilizado um ponto de partida com contextos já conhecidos. As principais contribuições sugeridas estão concentradas nos aspectos de otimização do tratamento de resultados ao longo das etapas de processamento dos dados, buscando uma otimização em parâmetros tratados.

Figura 15 – A nova arquitetura da rede neural convolucional proposta para predição de falhas geológicas.



Fonte: Elaborado pelo Autor.

4.2 Dados

Os dados de sísmicas possuem como característica de exportação o formato SEG-Y(.sgy). Para o tratamento dos dados de sísmica em python, será utilizada a biblioteca Segyo, que possibilita ler e escrever os cabeçalhos binários, cabeçalhos textuais, traços sísmicos, suas amostras e realizar sua visualização.

Os dados utilizados para treinamento das redes neurais do trabalhos (DI; GAO; ALREGIB, 2019) e (CUNHA et al., 2020) vieram do dataset StData-12. O StData-12 foi apresentado por (DI; GAO; ALREGIB, 2019) para o treinamento da StNet e também foi utilizado por (LIMA, 2021) para o desenvolvimento da DNFS.

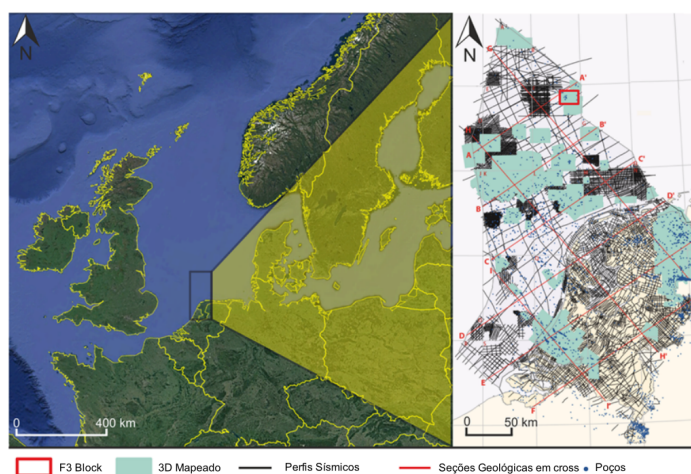
Este dataset StData-12 é composto por seções sísmicas de um volume sísmico. Este dataset é baseado no volume Netherlands Offshore F3 Block (TERRANUBIS, 2020), que é situado no Mar do Norte que é rico em depósitos de hidrocarbonetos.

A plataforma continental do Mar do Norte, localizada perto da costa da Holanda, é dividida em zonas geográficas descritas por diferentes letras do alfabeto; dentro dessas zonas, há áreas menores marcadas com números. Uma dessas áreas é um retângulo de dimensões 16 km x 24 km conhecido como F3 block, de acordo com a Figura 16.

Em 1987, a pesquisa sísmica 3D do F3 block foi realizada para identificar as estruturas geológicas desta área e a procura de reservatórios de hidrocarbonetos. Além disso, muitos furos foram perfurados dentro do F3 block ao longo dos anos. O F3 block tornou-se uma das mais conhecidas e estudadas pesquisas sísmicas após a dGB Earth Sciences ter feito os dados obtidos a partir da pesquisa disponível ao público.

O StData-12 possui diferentes interpretações dos dados sísmicos. Veja que a imagem 17


Figura 16 – Mapa da localização do cubo sísmico F3 Block, contendo a área mapeada, perfis sísmicos, seções geológicas e poços.



Fonte: Adaptado de (DUIN et al., 2006)

mostra o volume sísmico do F3 Block sendo exibido em in-line, cross-line e z-slice.

Figura 17 – Volume sísmico Netherlands Offshore F3 Block sendo exibido da esquerda para direita em in-line, cross-line e z-slice no software OpendTect (EARTH SCIENCES, 2021).

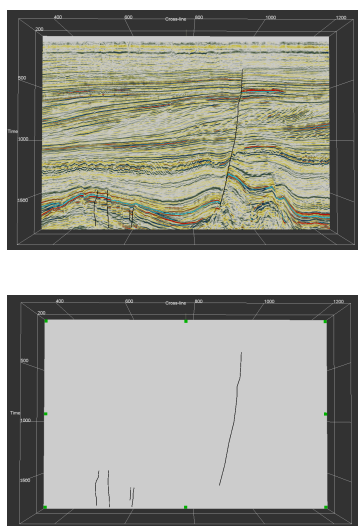


Fonte: Elaborada pelo autor

A geração das máscaras de falhas será feita através do software OpendTect, que através do botão new do menu faults do software, gera uma nova falha no menu, e habilita a definição de pontos através de indicação de pontos na seção sísmica. Estes pontos se interconectam e geram a linha que representa a falha na seção sísmica seja ela inline ou crossline. Após é gerada uma

nova máscara de atributo e é aplicado um atributo cinza na seção sísmica na qual estão sendo geradas as falhas, para ressaltar onde estão as falhas criadas, conforme mostra a Figura 18.

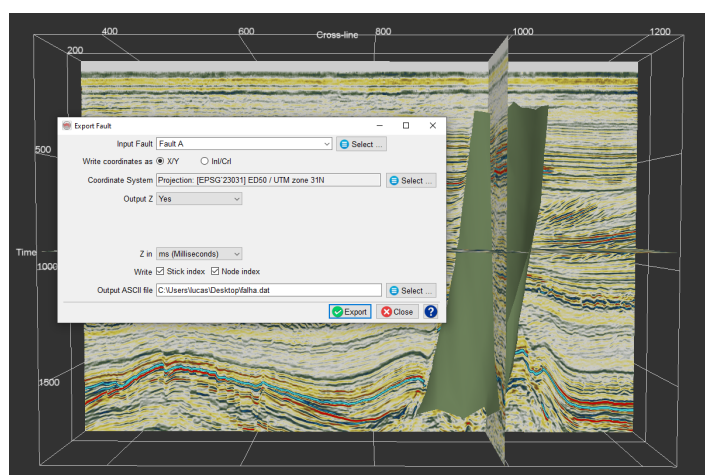
Figura 18 – Visualização do software OpendTect para geração da máscara de falhas - à esquerda temos a criação das falhas e à direita a criação da máscara.



Fonte: Elaborada pelo autor

Para exportação das máscaras de falhas que serão utilizadas para o treinamento da rede foi empregado o software OpendTect (EARTH SCIENCES, 2021), que gera arquivos com os dados de falhas geradas, como mostra a figura 19 em arquivos no formato ascii DAT (.dat).

Figura 19 – Falha sendo exportada pelo software OpendTect para geração da máscara de falhas.



Fonte: Elaborada pelo autor


Os procedimentos de anotação das imagens pretendem gerar um novo dataset, de acordo com a demanda destes experimentos. Além disso, considera-se avaliar esta disponibilização como uma contribuição adicional deste trabalho.

Também serão utilizados datasets já existentes para buscar comparações dos resultados da nova arquitetura de rede proposta com os resultados das arquiteturas de redes dos trabalhos que buscaram identificações de falhas.

O dataset anotado manualmente como contribuição deste trabalho foi gerado utilizando o F3 Block, no software OpendTect, gerando um novo projeto. Em seguida, foi utilizado o cubo sísmico 3D F3 Block e projetado da in-line 102 até a in-line 318, intercalando de 3 a 5, para gerar um conjunto de dados sísmicos com anotações de reconhecimento de falhas, ou seja, gerar anotações de falhas correspondentes para cada uma das seções, conforme mostra a imagem 20.

Estas anotações foram geradas utilizando diversos atributos sísmicos que identificam o local de falhas geológicas na sísmica. Neste fluxo foi utilizada a ferramenta de geração de linhas de falhas e depois exportadas estas capturas de dados sísmicos. Estas são pareadas e as anotações de falhas são feitas para cada falha vertical. No total, foram geradas 45 sísmicas com as respectivas falhas geológicas anotadas juntas em uma só imagem e também em diversas imagens separadas.

Figura 20 – Sísmica 2D da inline 102 e sua respectiva máscara de falhas, geradas através cubo sísmico F3 Block utilizando o software OpendTect



Fonte: Elaborada pelo autor

4.3 Aspectos gerais adotados no treinamento

Redes neurais artificiais com a arquitetura CNNs fazem uso de algoritmos de aprendizado para ajustar seus parâmetros livres, ou seja, bias e os pesos, de modo que se obtenham os valores de saída esperados. O algoritmo comumente usado para este propósito é o algoritmo de backpropagation. Tal algoritmo calcula o gradiente de uma função de erro (também conhecida como função custo/perda/desempenho) para determinar como ajustar os parâmetros da rede a fim de minimizar os erros que afetam o desempenho na tarefa de predição.

A função de perda cross entropy (tradução, entropia cruzada), é normalmente utilizada para tarefas de classificação, de acordo com (ZAKI; MEIRA, 2020), e será a função utilizada na arquitetura da nova rede. A cross-entropy atribui uma de duas classes para cada pixel: 0 (zero) ou 1 (um). A classe zero (0) representa geometria contínua e a classe (1) um representa a descontinuação entre as geometrias da sísmica.

O treinamento é o processo pelo qual os parâmetros livres de uma rede neural são adaptados

através de um mecanismo de apresentação de estímulos fornecidos pelo ambiente no qual a rede está inserida, de acordo com (HAYKIN, 1999). O tipo de treinamento é definido pela forma na qual os parâmetros são modificados.

Para implementação será utilizada a rede DNFS como base de conhecimento para gerar a nova rede. Com base nesta rede treinada será implementada a variação de filtros de camadas assim como foi desenvolvido a DNFS. O treinamento utilizará primeiramente os dados do F3 block para treinamento da rede. Os dados de validação e dados de teste serão descritos a partir do software OpendTect. O modelo da nova rede a ser implementada será descrito através do software jupiter do Anaconda.

Para avaliação do resultado será feita uma comparação entre os dados de saída da nova arquitetura e também uma imagem gerada a partir de uma aplicação de um atributo sísmico no volume sísmico 3D, gerando uma imagem sísmica 2D com contraste nas falhas ou fraturas.

5 EXPERIMENTOS E RESULTADOS

Neste capítulo são descritos os experimentos realizados com o propósito de entender e conhecer mais detalhes sobre a área de estudo da proposta. Os experimentos inicialmente realizados foram desenvolvidos a partir de uma análise de trabalhos relacionados e conjuntos de dados de entrada. Foram desenvolvidas aplicações que utilizam estes dados de entrada e permitam algum tipo de comparação dos seus resultados.

Na seção 5.1 é descrito o experimento de machine learning aplicando diferentes redes neurais em dados de sísmicas sintéticas, para identificar falhas e comparar os resultados de diferentes redes neurais. A seção 5.2 apresenta um experimento com transferência de aprendizagem de máquina, onde faz a transferência de aprendizado para cada rede e mostra os resultados em cada rede específica para identificação de diferentes sismo-fácies.

A seção 5.3 descreve o experimento realizado com a arquitetura de rede proposta, bem como analisa os seus resultados.

5.1 Experimento com projeto Seismic fault detection

No Projeto Seismic Fault Detection (CUNHA et al., 2020) é utilizado um conjunto de dados sintéticos de sísmica, sendo interpretada uma imagem de dados reais que serão classificados e por fim é gerada uma máscara da falha na sísmica. Com os dados de entrada são gerados três conjuntos de dados sintéticos.

Depois da geração das sísmicas, é feita a geração da máscara de falhas a partir de um arquivo de pontos para cada sísmica gerada. Este arquivo tem formato CSV e gera linhas correspondentes as falhas interpretadas, conforme Figura 21.

Terminado o processo de entrada dos dados, são feitos os *patches* de falha em uma sessão sísmica com corte real, conforme a Figura 22, e posteriormente se reconstrói uma imagem a partir destes *patches*.


Feita esta reconstrução, é realizada a classificação e são geradas as métricas para cada rede neural analisada (a VGG, a FFT, a MLP, e a SVM). Com isso, os resultados da detecção de falhas para cada rede neural testada são mostrados na Figura 23.

Após, são apresentados na Tabela 9, as comparações de acurácia, sensibilidade, especificidade, score F1 e curva AUC-ROC em cada rede neural para as redes VGG, FFT, MLP e SVM.

A Tabela 10 apresenta a comparação dos tempos de processamento de treinamento para cada diferente rede neural desenvolvida na ferramenta Google Colab, cada rede neural teve os mesmo dados de treinamento assim como mesma quantidade de épocas de treinamento.


Em uma interpretação dos resultados das imagens da sísmica geradas para a identificação de falhas com máscara, se observa que sem a aplicação de uma rede neural, a marcação das falhas fica restrita àquelas mais longas. A aplicação da rede VGG se mostrou pouco eficiente

Figura 21 – Sísmica 2D sintética de (CUNHA et al., 2020), da seção 2600 com sua respectiva máscara de falhas sobreposta.



Fonte: Elaborada pelo autor

Figura 22 – Imagem construída a partir de *patches*. A partir da sessão sísmica com corte real (na esquerda) é obtida a imagem com máscara (na direita), contendo os *Patches* das falhas (em vermelho) e máscara das falhas (em azul).



Fonte: Elaborada pelo autor

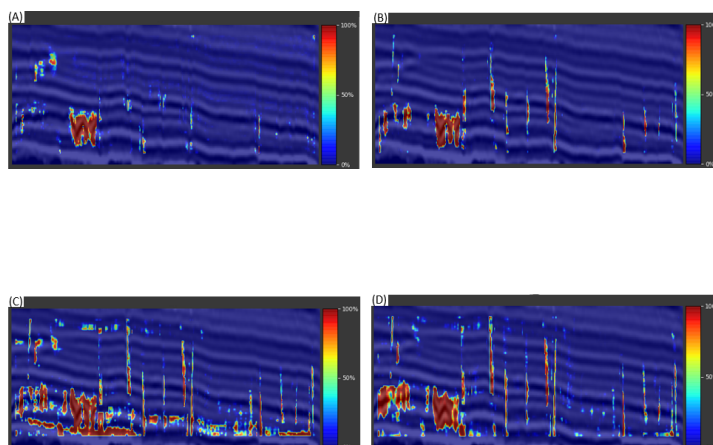
Tabela 9 – Comparação dos resultados de Acurácia, Sensibilidade, Especificidade, Escore F1 e Curva AUC-ROC em cada rede neural.

Arquitetura	Precisão	Sensibilidade	Especificidade	F1 Score	AUC
VGG	0.8675	0.0304	0.9679	0.0468	0.5972
FFT	0.8809	0.2054	0.9619	0.2698	0.7677
MLP	0.8229	0.2751	0.8885	0.2496	0.6582
SVM	0.8725	0.1627	0.9576	0.2146	0.7140

Fonte: Elaborada pela autor.

no mapeamento das falhas e, após a geração da máscara, exibiu grande incerteza apontada pela predominância de marcações em azul escuro, seguida pelo azul claro. A rede FFT teve um desempenho melhor, mapeando as principais falhas. Porém algumas delas não foram delimitadas por inteiro e as falhas pequenas na base da seção não estão representadas (assim como no caso da rede VGG). A imagem gerada pela rede MLP teve sucesso no mapeamento das falhas, mos-

Figura 23 – Imagens geradas com os testes para cada CNN com dados do projeto (CUNHA et al., 2020). (A) VGG; (B) FFT; (C) MLP; (D) SVM.



Fonte: Elaborada pelo autor

Tabela 10 – Comparação dos tempos de processamento para cada rede neural aplicada.

PU	VGG	FFT	MLP	SVM
CPU	60.3s	62.4s	64.2s	494s
GPU	11.0s	4.2s	7.4s	398s
TPU	65.0s	64.0s	66.0s	392s

Fonte: Elaborada pela autor.

trando maior nível de certeza nas marcações de um modo geral. Também foram representadas as falhas menores na base da seção sísmica, porém no lugar de serem marcadas por linhas retas, foram geradas "manchas" sobre as porções com falhas muito próximas entre si. Um diferencial desta rede com relação às duas anteriores é que ela permitiu a demarcação de pequenas falhas na parte superior da seção. Apesar disso, a imagem gerada com a máscara ficou bastante poluída.


A aplicação da rede SVM apresentou um resultado parecido com o anterior, entretanto não se gerou uma mancha na delimitação das falhas pequenas da base da seção e a imagem não ficou poluída, o que facilita sua posterior interpretação por um profissional. Apesar disso, em todas as redes houve uma mancha (em vermelho) na mesma região (inferior esquerda), em que parece haver algumas falhas curtas.

5.2 Experimento com Seismic Transfer Learning

No projeto Seismic Transfer Learning, (CUNHA et al., 2020) o dado de entrada é a sísmica que é dividida em duas imagens da sísmica em x-line e em i-line, conforme Figura 24.

A partir da leitura do arquivo, foram introduzidos dados para o treinamento da rede a ser aplicada. A primeira rede neural foi a Waldeland, que levou cerca de 53 minutos de proces-


Figura 24 – Imagens sísmicas 2D em cross-line e in-line, que foram utilizadas como entrada na rede neural.



Fonte: Elaborada pelo autor

samento para o treinamento, treinou 11 épocas de 20 e chegou a valores de loss: 0.011, mae: 0.002 e acc: 0.998. Temos como resultado a Figura 25.


Figura 25 – Resultados de predição da rede neural Waldeland nos dados sísmicos do projeto de (CUNHA et al., 2020).



Fonte: Elaborada pelo autor

A rede neural aplicada a seguir foi a VGG16. Esta teve um tempo de processamento de treinamento em torno de 35 horas e 30 minutos, treinou 19 épocas de 20 e chegou a valores de loss: 0.130, mae: 0.026, acc: 1.000, como resultado na Figura 26.

Figura 26 – Resultados de predição da rede neural VGG16 nos dados sísmicos do projeto de (CUNHA et al., 2020).



Fonte: Elaborada pelo autor

Com relação à utilização de redes neurais para o mapeamento de diferentes padrões na disposição das camadas rochosas, a aplicação da rede neural Waldeland demonstrou sucesso na diferenciação, por exemplo, entre feições plano-paralelas, sigmoidais, deformadas e falhadas.

Entretanto, algumas regiões marcadas em cinza não parecem se diferenciar das porções ao seu redor, então não deveriam ter sido marcadas com outra cor. No caso da rede VGG16, o resultado não foi muito eficiente nessa representação. Por exemplo, feições sigmoidais foram marcadas com a mesma cor das porções com geometria plano-paralela, como mostra a Figura 26.

5.3 Experimentos com arquitetura proposta

Nesta seção é descrito o experimento com a arquitetura de rede proposta comentados os resultados obtidos. São apresentados aspectos do conjunto de dados anotados que foi gerado através do F3 Block para treinar as redes neurais, o conjunto de dados sintéticos utilizados por (CUNHA et al., 2020), a indicação de quais métricas foram utilizadas para o treinamento e também são avaliados e comparados os resultados obtidos. Esta seção foi dividida em Coleção de Dados, Aumento de Dados, Treinamento, Métricas e por fim Comparações e Resultados.

5.3.1 Coleção de Dados

Nestes experimentos e em etapas iniciais, foram utilizados dois conjuntos de dados, sendo um relacionado com o projeto descrito em (CUNHA et al., 2020) e o outro a partir do material descrito em (TERRANUBIS, 2020).

A partir do projeto Seismic Fault Detection, utilizado pelo (CUNHA et al., 2020), foram geradas 5 sísmicas sintéticas com suas respectivas máscaras de falhas. Este dataset possui sísmicas e máscaras de falhas com tamanho variando de 484 a 500 pixels em largura por 76 pixels de altura, conforme mostra a figura 27. Nestas figuras foram aplicados recortes de tamanho para utilizar um tamanho de 484 pixels de largura em todo o dataset. Posteriormente é aplicado outro recorte para resultar em um dataset de tamanho de 64 por 64 pixels, utilizado para treinamento das redes.

Figura 27 – Sísmica sintética da linha 1796 e sua respectiva máscara de falhas, geradas através do projeto de (CUNHA et al., 2020).



Fonte: Elaborada pelo autor

O novo conjunto de dados sísmicos chamado de F3 Faults usado neste trabalho é gerado através do Cubo sísmico 3D F3 Block (TERRANUBIS, 2020), para manter os detalhes sísmicos e minimizar a perda de detalhes por ruídos que são gerados na sísmica 2D. Estes dados são

exportados com tamanho de 832 por 832 pixels. No total foram geradas 180 sísmicas 2D com anotações, sendo 45 originais sem aumento de dados e 135 com aumento de dados.

5.3.2 Aumento de Dados

O processo de aumento de dados pode ser dividido em duas partes. Um para dados sísmicos e o outro para as anotações de falhas. Nas duas partes são aplicadas rotação horizontal, rotação de 90 graus para esquerda e rotação de 90 graus para direita, assim como também é aplicado um espelhamento gerando uma sísmica inversa. Foi utilizado programas Python para ler estes dados. Então, estes dados são aplicados a um redimensionamento para o tamanho de entrada da arquitetura, que é 128 por 128 pixels. Considerando que este conjunto de dados foi criado principalmente para treinar e avaliar o reconhecimento automático de falhas geológicas em sísmicas, foi seguido o princípio de segmentação de conjuntos de dados de aprendizado de máquina e dividido o conjunto de dados em um conjunto de treinamento, um conjunto de validação e um conjunto de teste, conforme descrito na seção 4.2.

Para o dataset gerado através do projeto de (CUNHA et al., 2020), foi utilizado inversão vertical para gerar mais 5 imagens sísmicas com suas respectivas máscaras de falhas, posteriormente também é aplicado recortes as este dataset para resultar em um tamanho de 76 por 76 pixels.

5.3.3 Treinamento

Foram treinadas as redes U-net com arquitetura padrão e uma U-net com a arquitetura proposta. Nestes treinamentos houve variação de modo experimental dos tipos de funções de perda (Binary Cross-Entropy, Mean Absolute Error, Sigmoid Focal Cross-Entropy), valor do otimizador Adam (0,01 a 0,00001), valor do tamanho de batch (8 a 16), a quantidade de épocas de treinamento (50 a 100) e variação da função de callback Earlystopping.

5.3.4 Métricas

Foram utilizadas diversas métricas nos treinamentos preliminares, aplicando-se estas a cada época. Foram utilizadas métricas como Intersection Over Union, Accuracy e Coeficiente Dice para avaliar o desempenho dos modelos de predição gerados. A métrica que obteve melhor resultado foi o Coeficiente Dice, o qual será aplicado nas comparações e resultados a seguir.


5.3.5 Comparações e Resultados

A nova arquitetura de rede gerou um total de 1.941,105 parâmetros treináveis. Para o experimento foi aplicado o dataset sintético gerado pelo projeto do (CUNHA et al., 2020), compondo

um total 10 sísmicas sintéticas com suas respectivas máscaras, onde 5 eram máscaras do projeto e as outras 5 eram máscaras de data augmentation. Para a ampliação de dados foram aplicadas as operações de inversão vertical. No treinamento foi utilizado a função de perda Binary Cross-Entropy e como métrica foi utilizada a precisão. O processo de treinamento levou 51 segundos.

As imagens da figura 28 ilustram exemplos do dataset com a sísmica e as respectivas máscaras. Pode ser observado nas imagens desta figura que existe uma dificuldade na tarefa de segmentação, tendo em vista que as imagens da sísmica, na área de fratura, possuem pouco destaque em termos de elementos de imagem. As máscaras estão associadas com regiões sem uma clara delimitação de cores ou formato. Esta dificuldade originada no formato dos dados é um desafio que consta na literatura e que está relacionado com o estado atual dos resultados obtidos.

Figura 28 – Resultado da Sísmica com sua respectiva máscara de falhas, geradas através do treinamento da nova arquitetura.



Fonte: Elaborada pelo autor

A figura 29 destaca esta questão. A mesma corresponde à uma parte da sísmica que foi destacada e ampliada. A imagem original é a primeira imagem da figura 28. Na parte ampliada pode ser vista a região que corresponde à falha e também, traçado em vermelho, a linha que corresponde à anotação. A partir desta figura pode ser observado que as regiões anotadas possuem uma pequena diferenciação para com o restante da imagem, dificultando a geração da segmentação.


O resultados de predição são exibidos nas imagens da figura 30. Estas imagens são relacionadas com as imagens de sísmica mostrada anteriormente. Observa-se que existem ainda pontos de avanço possíveis e necessários, para que a tarefa seja realizada com melhores resultados.

Para este experimento realizado, obtivemos um aumento de precisão de 0,072 para 0,1823 em treinamento e para perda temos uma variação de 1,3016 até 0,9477, conforme mostra a figura 31.

A análise destes resultados indica que os resultados estão ainda muito defasados da máscara de falhas, pelo fato destas falhas geológicas estarem em pontos contrários das linhas horizontais muito bem evidentes na sísmica 2D e não terem uma representação mais evidente das falhas geológicas na sísmica 2D, resultando em predições de pontos de falhas e horizontes sísmicos.


Então foram realizados 4 experimentos com diversos treinamentos para comparação e validação da nova arquitetura com diferentes conjuntos de dados e com atributos sísmicos aplicados

Figura 29 – Análise detalhada da imagem na área de fratura.




Fonte: Elaborada pelo autor

Figura 30 – Resultado de treinamento com o dataset sintético, gerado através do treinamento da nova arquitetura.



Fonte: Elaborada pelo autor

Figura 31 – Resultado de precisão e perda do treinamento e teste da nova arquitetura.



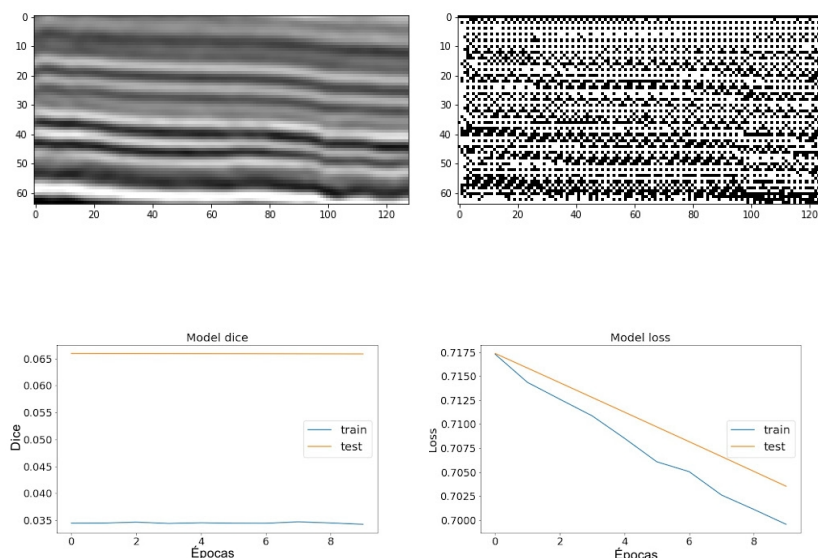
Fonte: Elaborada pelo autor

as sísmicas 2D, a fim de avaliar a identificação das falhas geológicas nas sísmicas 2D por redes neurais convolucionais.

O primeiro experimento foi realizado utilizando o conjunto de dados de (CUNHA et al., 2020) na nova arquitetura proposta. Nesta arquitetura foi aplicada a função de perda Binary Cross-Entropy junto com a métrica Coeficiente Dice, com treinamento de 10 épocas, como mostra a Figura 32.

O resultado do primeiro experimento apresenta resultados imprecisos pela falta de informa-

Figura 32 – Experimento 1- Arquitetura proposta utilizando conjunto de dados sísmicos de (CUNHA et al., 2020).



Fonte: Elaborada pelo autor

ção das imagens sísmicas utilizadas para treinamento da rede neural convolucional.

O segundo experimento utiliza o novo conjunto de dados F3 Faults na nova arquitetura proposta, aplicando a função de perda Binary Cross-Entropy junto com o coeficiente Dice. Este treinamento teve 100 épocas com imagens de 640 por 640 pixels, como mostra na Figura 33.

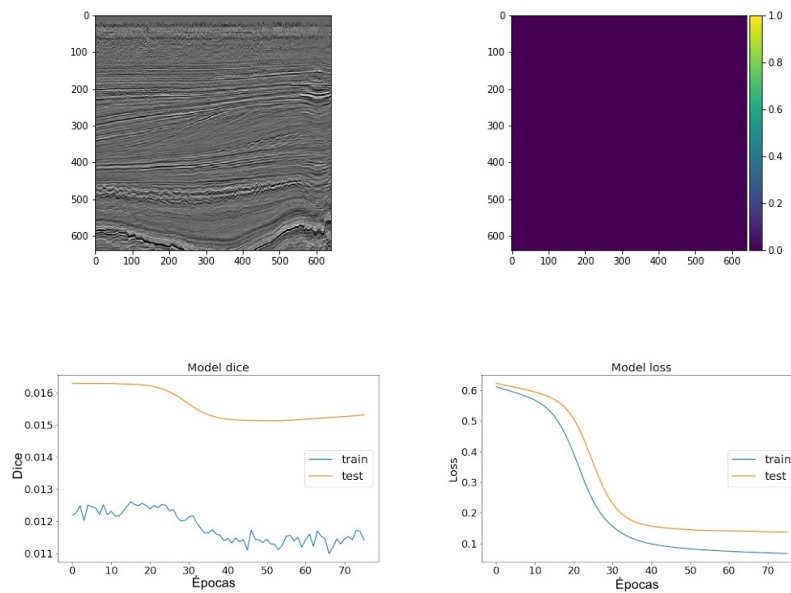
O resultado do segundo experimento possui imagens com maior resolução e quantidade de sísmicas 2D, junto com suas respectivas máscaras de falhas, utilizando o novo conjunto de dados F3 Faults. Porém os resultados continuaram imprecisos por falta de destaque nas informações de falhas geológicas nas imagens sísmica de treinamento.

O terceiro experimento é a validação do novo conjunto de dados F3 Faults com aplicação de atributos sísmicos para identificar as falhas geológicas na nova arquitetura proposta, aplicando a função de perda binary Cross-Entropy com a métrica coeficiente Dice. O treinamento teve 10 épocas com imagens de 832 por 832 pixels, como mostra a Figura 34.

O resultado do terceiro experimento também possui imagens com maior resolução e quantidade de sísmicas 2D, junto com suas respectivas máscaras de falhas, utilizando o novo conjunto de dados F3 Faults com aplicação de atributos sísmicos. Os resultados obtidos pela aplicação dos atributos sísmicos nas sísmicas 2D se mostraram satisfatórios para identificação e predição das falhas geológicas.

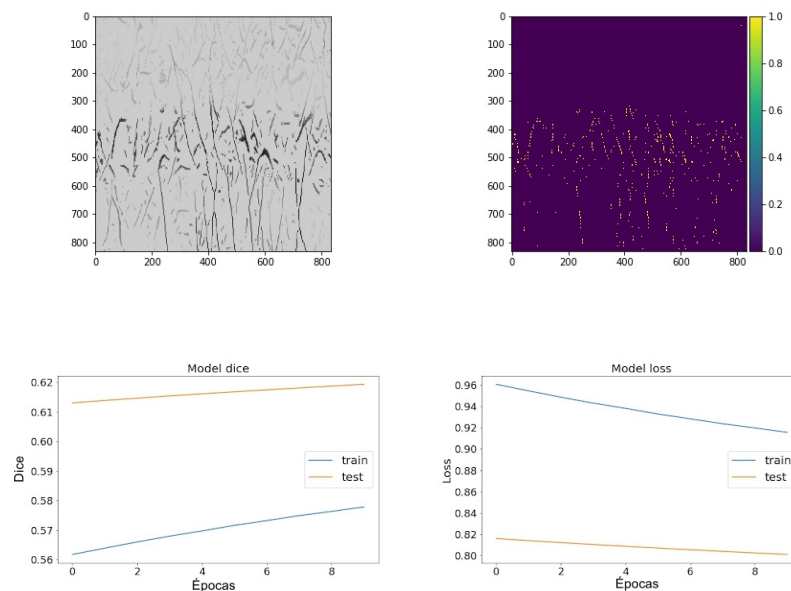
E por fim, o quarto experimento é a validação da nova arquitetura proposta, comparando com a arquitetura StNet, sendo utilizada a arquitetura da StNet para treinamento, utilizando também o novo conjunto de dados F3 Faults com aplicação de atributos sísmicos para destaque das falhas geológicas. Foi aplicado a função de perda Binary Cross-Entropy junto com a métrica

Figura 33 – Experimento 2 - Arquitetura proposta utilizando o novo conjunto de dados sísmicos chamado F3 Faults.



Fonte: Elaborada pelo autor

Figura 34 – Experimento 3 - Validação do conjunto de dados sísmicos F3 Faults com aplicação de atributos/filtros no cubo sísmico

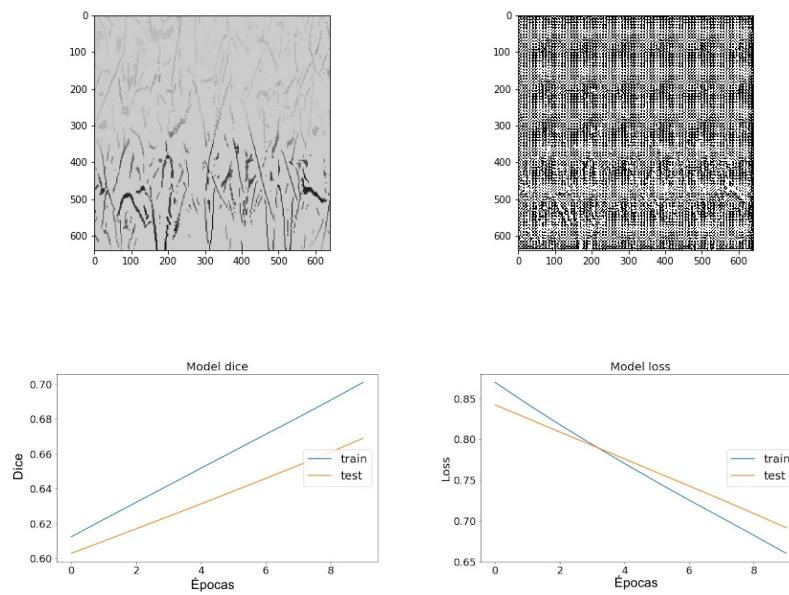


Fonte: Elaborada pelo autor

coeficiente Dice, em um treinamento de 10 épocas com imagens de tamanho 832 por 832 pixels, como mostra na Figura 35.

O resultado dessa comparação mostra um aumento linear do valor de Dice junto com uma

Figura 35 – Validação da arquitetura proposta com o conjunto de dados sísmicos F3 Faults aplicando atributos em arquitetura diferente da proposta (StNet).



Fonte: Elaborada pelo autor

diminuição linear do valor de perda, teve previsões corretas mas com grande quantidade de ruídos.

6 CONCLUSÃO

Predições implementadas por computador são recursos essenciais para ajudar os geólogos na interpretação da área de estudo, uma vez que conseguem detectar características que muitas vezes passam despercebidas até mesmo pelo olhar de especialistas. Entretanto, os métodos atuais estão fundamentados em extração de características baseadas em métodos de inspeção visual tradicionais.

Os métodos com redes neurais profundas conseguem extrair características otimizadas da distribuição relacionada à tarefa de classificação. As arquiteturas das redes neurais conseguem classificar com tanta habilidade de abstração que apenas com imagens e rótulos têm a capacidade de aprender por si mesmos as características que os permitem superar o desempenho humano em algumas tarefas altamente complexas. O método proposto neste trabalho tem por objetivo auxiliar na interpretação dos dados sísmicos podendo trazer ganhos ao diminuir o trabalho manual e o tempo gasto ao se realizar o estudo da área geológica, identificando as falhas e fazendo um estudo detalhado da falha de interesse.

Os resultados obtidos pela arquitetura proposta em redes neurais convolucionais aplicado a dados sísmicos 2D anotados de falhas do novo conjunto F3 Faults, junto com aplicação de atributos sísmicos nas sísmicas 3D, indicam a possibilidade de obtenção de predições satisfatórias de falhas geológicas. Entretanto cabe ressaltar que o estudo também permitiu identificar problemas no encaminhamento de respostas a este problema, em especial nos casos em que as imagens geradas a partir das sísmicas resultam em baixo destaque para as áreas associadas com as fraturas, ponto de atenção ainda a ser pesquisado e aprofundado.

6.1 Contribuição

Este trabalho contribui apresentando um estudo de artigos que identificam falhas ou fraturas 2D e 3D, que realizam a identificação de feições e texturas geológicas. Também contribuiu com os experimentos de treinamento de redes neurais profundas em sísmicas.

Além disso, proporcionou a criação de um novo conjunto de dados sísmicos com anotações de falhas a partir do conjunto chamado F3 Faults. Este dataset encontra-se disponível para utilização pelo público interessado. Os links de acesso ao material estão no anexo A3.

Foi desenvolvido e submetido um artigo chamado "An study of machine learning approaches to identify faults and seismic facies in seismic data" com comparativos entre projetos no estado da arte, voltados para a utilização de diferentes recursos de aprendizagem de máquina para apoio em atividades ligadas à Geociência.

6.2 Trabalhos futuros

Como possibilidades de trabalhos futuros, destacamos os seguintes pontos, a serem encaminhados em atividades colaborativas futuras.

- Avaliação de melhorias na arquitetura proposta a partir de reconfigurações de componentes;
- Avaliar resultados possíveis com distintos conjuntos de dados anotados;
- Implementação do algoritmo de destacamento de falhas cisalhantes.

REFERÊNCIAS

- AMINZADEH, F.; DASGUPTA, S. N. Chapter 9 - geophysics for unconventional resources. In: AMINZADEH, F.; DASGUPTA, S. N. (Ed.). **Geophysics for petroleum engineers**. [S.l.]: Elsevier, 2013. p. 247–271. (Developments in Petroleum Science, v. 60).
- AN, Y. et al. Deep convolutional neural network for automatic fault recognition from 3d seismic datasets. **Computers & Geosciences**, [S.l.], v. 153, p. 104776, 2021.
- ASHCROFT, W. **A petroleum geologist's guide to seismic reflection**. [S.l.]: John Wiley & Sons, 2011.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: a deep convolutional encoder-decoder architecture for image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S.l.], v. 39, n. 12, p. 2481–2495, 2017.
- BISHOP, C. M. Pattern recognition. **Machine learning**, [S.l.], v. 128, n. 9, 2006.
- COHEN, I.; COULT, N.; VASSILIOU, A. A. Detection and extraction of fault surfaces in 3d seismic data. **GEOPHYSICS**, [S.l.], v. 71, n. 4, p. P21–P27, 2006.
- CUNHA, A. et al. Seismic fault detection in real data using transfer learning from a convolutional neural network pre-trained with synthetic seismic data. **Computers & Geosciences**, [S.l.], v. 135, p. 104344, 2020.
- DENG, L.; YU, D. Deep learning: methods and applications. **Foundations and trends in signal processing**, [S.l.], v. 7, n. 3–4, p. 197–387, 2014.
- DI, H.; GAO, D.; ALREGIB, G. Developing a seismic texture analysis neural network for machine-aided seismic pattern recognition and classification. **Geophysical Journal International**, [S.l.], v. 218, n. 2, p. 1262–1275, 05 2019.
- DUIN, E. et al. Subsurface structure of the netherlands - results of recent onshore and offshore mapping. **Netherlands Journal of Geosciences - Geologie en Mijnbouw**, [S.l.], v. 85, n. 4, p. 245–276, 2006.
- EARLE, S. **Physical geology – 2nd edition**. [S.l.]: Edition. Victoria, B.C.: BCcampus, 2019.
- EARTH SCIENCES dGB. **Opendtect**. Accessed: 2021-07-18, <https://www.dgbes.com/index.php/software/opendtect>.
- EL-AMIR, H.; HAMDY, M. **Deep learning pipeline: building a deep learning model with tensorflow**. [S.l.]: Apress, 2019.
- FRIEDERICHS, Y. L. et al. Arquitetura sísmica do sistema fluvio-estuarino da baía de sepetiba preservado na estratigrafia rasa da plataforma adjacente, rio de janeiro, brasil: the seismic architecture of the sepetiba fluvio-estuarine system preserved on the shallow stratigraphic record on the offshore inner-mid shelf, rio de janeiro, brazil. **Brazilian Journal of Geology**, [S.l.], v. 43, n. 1, p. 124–138, 2013.
- GAO, K.; HUANG, L.; ZHENG, Y. Fault detection on seismic structural images using a nested residual u-net. **IEEE Transactions on Geoscience and Remote Sensing**, [S.l.], 2021.

GEOEXPRO. **A simple guide to seismic horizon interpretation**. Accessed: 2022-06-13, <https://www.geoexpro.com/articles/2020/12/a-simple-guide-to-seismic-horizon-interpretation>.

GUITTON, A. Statistical imaging of faults in 3d seismic volumes using a machine learning approach. In: **Seg technical program expanded abstracts 2017**. [S.l.]: Society of Exploration Geophysicists, 2017. p. 2045–2049.

GUITTON, A.; WANG, H.; TRAINOR-GUITTON, W. Statistical imaging of faults in 3d seismic volumes using a machine learning approach. In: **Seg technical program expanded abstracts 2017**. [S.l.]: Society of Exploration Geophysicists, 2017. p. 2045–2049.

HASSABALLAH, M.; AWAD, A. I. **Deep learning in computer vision: principles and applications**. [S.l.]: CRC Press, 2020.

HAYKIN, S. **Neural networks: a comprehensive foundation**. [S.l.]: Prentice Hall, 1999. (International edition).

LI, S. et al. Seismic fault detection using an encoder–decoder convolutional neural network with a small training set. **Journal of Geophysics and Engineering**, [S.l.], v. 16, n. 1, p. 175–189, 2019.

L'IFREMER, F. O. F. P. **Equipements sismiques**. Accessed: 2021-08-27, <https://www.flotteoceanographique.fr/Nos-moyens/Navires-engins-et-equipements-mobiles/Equipements-mobiles/Equipements-sismiques>.

LIMA, G. C. **Segmentação de fácies sísmicas com redes neurais**. 2021. Dissertação (Mestrado em Ciência da Computação) — Universidade do Vale do Rio dos Sinos, São Leopoldo, 2021.

LU, P. et al. Using generative adversarial networks to improve deep-learning fault interpretation networks. **The Leading Edge**, [S.l.], v. 37, n. 8, p. 578–583, 2018.

LUQUOT, L.; GOUZE, P. Experimental determination of porosity and permeability changes induced by injection of CO₂ into carbonate rocks. **Chemical Geology**, [S.l.], v. 265, n. 1, p. 148 – 159, 2009. CO₂ geological storage: Integrating geochemical, hydrodynamical, mechanical and biological processes from the pore to the reservoir scale.

MISRA, A. A.; MUKHERJEE, S. **Atlas of structural geological interpretation from seismic images**. [S.l.]: John Wiley & Sons, 2018.

NICHOLS, G. **Sedimentology and stratigraphy**. [S.l.]: Wiley, 2013. (Wiley Desktop Editions).

OIKONOMOU, D. et al. Machine learning in petroleum geoscience: constructing earthnet. In: NGF WINTER CONFERENCE 2017 - THE FUTURE OF GEOSCIENCE, 2017, Oslo, Noruega. **Anais...** [S.l.: s.n.], 2017.

PRESS, F. et al. Para entender a terra. **Porto alegre**, [S.l.], 2006.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: convolutional networks for biomedical image segmentation. **CoRR**, [S.l.], v. abs/1505.04597, 2015.

SCHMIDHUBER, J. Deep learning in neural networks: an overview. **Neural networks**, [S.l.], v. 61, p. 85–117, 2015.

SERRA, O.; SERRA, L. **Well logging: data acquisition and applications**. [S.l.]: Serralog Méry Corbon, France, 2004.

TERRANUBIS. **Project f3 demo 2020**. Accessed: 2021-07-15, <https://terranubis.com/datainfo/F3-Demo-2020>.

WEI, X.-L. et al. Seismic fault detection using convolutional neural networks with focal loss. **Computers Geosciences**, [S.l.], v. 158, p. 104968, 2022.

WU, J. et al. Fault detection based on fully convolutional networks (fcn). **Journal of Marine Science and Engineering**, [S.l.], v. 9, n. 3, p. 259, 2021.

WU, X. et al. Faultseg3d: using synthetic data sets to train an end-to-end convolutional neural network for 3d seismic fault segmentation. **GEOPHYSICS**, [S.l.], v. 84, n. 3, p. IM35–IM45, 2019.

WU, X. et al. Multitask learning for local seismic image processing: fault detection, structure-oriented smoothing with edge-preserving, and seismic normal estimation by using a single convolutional neural network. **Geophysical Journal International**, [S.l.], v. 219, n. 3, p. 2097–2109, 09 2019.

XIE, D.; ZHANG, L.; BAI, L. Deep learning in visual computing and signal processing. **Applied Computational Intelligence and Soft Computing**, [S.l.], v. 2017, p. 1–13, 02 2017.

XIONG, W. et al. Seismic fault detection with convolutional neural network. **GEOPHYSICS**, [S.l.], v. 83, n. 5, p. O97–O103, 2018.

YUAN, Z. et al. Hybrid-dnns: hybrid deep neural networks for mixed inputs. **arXiv preprint arXiv:2005.08419**, [S.l.], 2020.

ZAKI, M.; MEIRA, W. **Data mining and machine learning: fundamental concepts and algorithms**. [S.l.]: Cambridge University Press, 2020.

ZHANG, X.-D. Machine learning. In: _____. **A matrix algebra approach to artificial intelligence**. Singapore: Springer Singapore, 2020. p. 223–440.

ZHENG, Y. et al. Applications of supervised deep learning for seismic interpretation and inversion. **The Leading Edge**, [S.l.], v. 38, n. 7, p. 526–533, 2019.

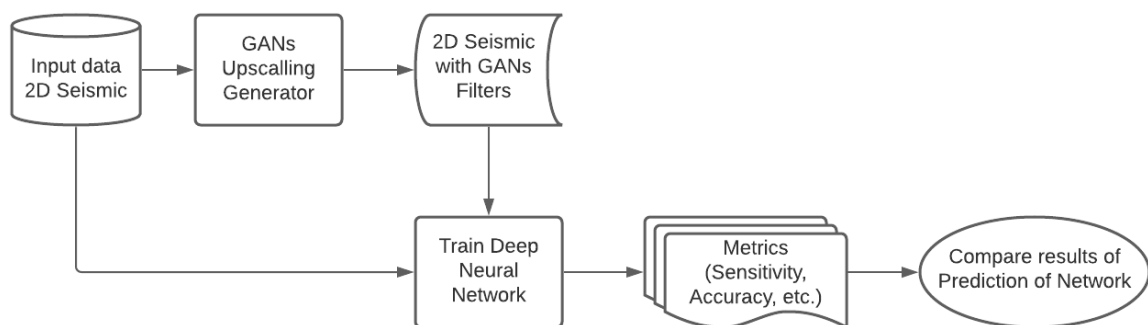
ANEXO A – ANEXOS COM EXPERIMENTOS COMPLEMENTARES

A seguir são descritas três atividades, duas complementares desenvolvidas ao longo da pesquisa realizada, e um conjunto de dados sísmico com máscaras de falhas. As duas atividades complementares são realizadas de forma exploratória e que não possuem contribuição direta na composição final do trabalho, tal como aqui apresentado. Entretanto foram atividades que exploram possibilidade de ampliação e relacionamento do trabalho a partir de tecnologias de redes Adversárias Generativas e de representação de conhecimento a partir de ontologias. Por este motivo, são descritas nestas seções.

A.1 Experimento com aplicação de GANs para melhorar identificação de falhas

A aplicação tem como objetivo melhorar a identificação de falhas em sísmicas 2D, pois estas possuem ruídos que alteram a visualização e futura implementação na interpretação do dado sísmico, logo utilizando supersampling de uma rede GAN, é possível melhorar esta resolução da sísmica 2D, que será utilizada para futuros trabalhos com redes neurais para identificação de falhas, utilizando dados geofísicos de sísmicas 2D e GANs, como mostra a Figura 36. Posteriormente estes dados gerados pela implementação serão comparados com sísmicas 2D gerados a partir de sísmicas 3D que não possuem ruídos.

Figura 36 – Fluxo da aplicação da GANs em sísmica para melhorar a identificação de falhas.



Fonte: Elaborada pelo autor

Foi utilizado a GAN, inicialmente para entender o funcionamento, onde temos, definidos os dados iniciais como arrays com valores de 1 e 0 com padrões, os ruídos são esses arrays sem padrões, posteriormente é definido a função de ativação, e então temos a classe discriminator e generator com funções derivadas.

O treinamento teve 1000 etapas, onde cada etapa, temos: Atualização do peso do discriminator; Geração de uma face falsa como ruído; Cálculo do erro do discriminator e posteriormente do generator; E por último atualização dos pesos do discriminator e do generator com as faces falsas.

Para visualização dos resultados desta GAN é utilizado a biblioteca matplotlib para gerar imagens com as faces reconhecidas pelo array generator.

Posteriormente para aplicar uma GAN que aumente a resolução da imagem foi utilizado como base a SRGAN, mas por motivos de erro gerado pelo colab esta implementação não foi concluída, ainda que, precisa ser feito testes futuros como trocar de ambiente, do colab para uma máquina local, ou criar um código em python para utilização desta biblioteca.

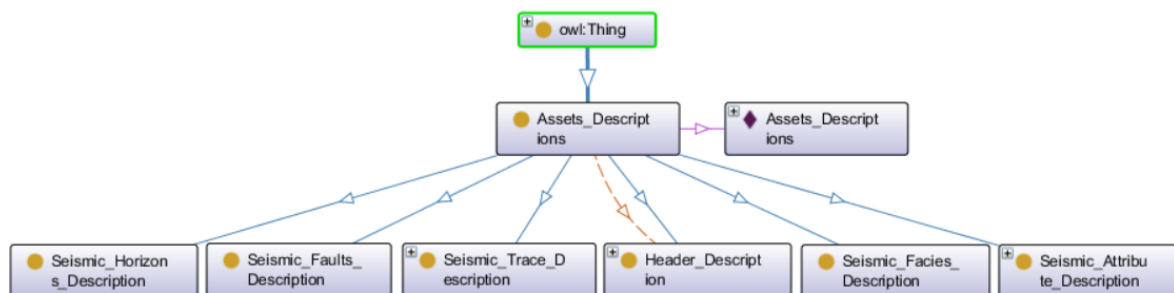
A.2 Seismic Ontology

Neste trabalho foram utilizados os dados para investigação da área de interesse, assim integrando abordagens de modelagem da área, interpretação dos dados adquiridos, e desenvolvimento de software para predição de dados. Esta ontologia desenvolvida servirá como introdução das características dos diferentes tipos de dados utilizados em softwares do domínio de Geologia do Petróleo, assim viabilizando o desenvolvimento de diversos sistemas baseados em conhecimento, que operem sobre uma mesma conceitualização deste domínio. A correlação dos dados geológicos permite determinar a ordem estrutural destes dados além de suas características geológicas.

Essas informações, aplicadas de forma estrutural, permitem a introdução destes dados no desenvolvimento de software, com rápida e fácil aprendizagem. Além disso, considerando que a ontologia específica a conceitualização, o seu uso para descrição dos objetos permite que os sistemas processem as informações acerca desses objetos de um modo que se aproxime da forma como os desenvolvedores de software geológicos os concebem. Assim, tem-se a hipótese de que abordagens automáticas para correlação podem se beneficiar do uso de ontologias, oferecendo resultados geologicamente mais significativos.

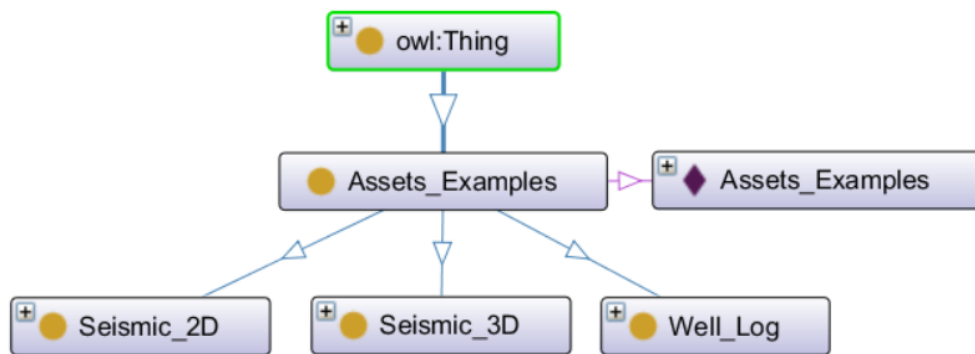
Na ontologia utilizada, a estrutura faz correlação das descrições dos dados com os exemplos de dados, assim foi gerado uma classe chamada Assets Descriptions que descreve o conceito de dados sísmicos como, falhas, horizontes, atributos, traços e fácies, onde cada um destes conceitos são relacionados com seu específico asset e este asset contém seu cabeçalho (header), Figura 37.

Figura 37 – Classe assets description no software Protegé.



Foi também gerada uma classe chamada Assets Examples, que divide em 3 partes os dados geológico de sísmica 2D (2D seismic), sísmica 3D (3D seismic) e dados geológicos de poços (Well Logs), Figura 38.

Figura 38 – Classe assets examples no software Protegé.

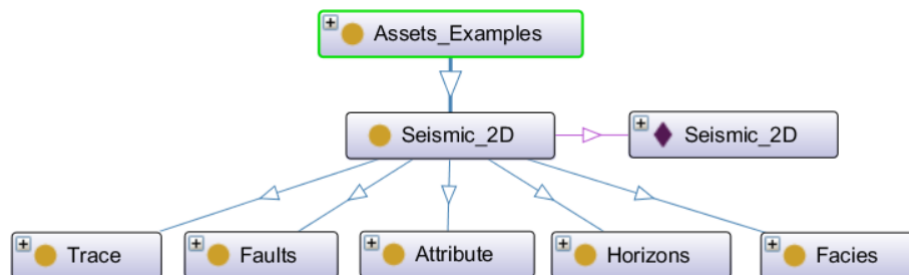


Fonte: Elaborada pelo autor

A.2.1 2D seismic

Na classe chamada seismic 2D foram gerados 5 classes, estas são, fácies, atributos, falhas, horizontes e traços, Figura 39.

Figura 39 – Classe seismic 2D no software Protegé.

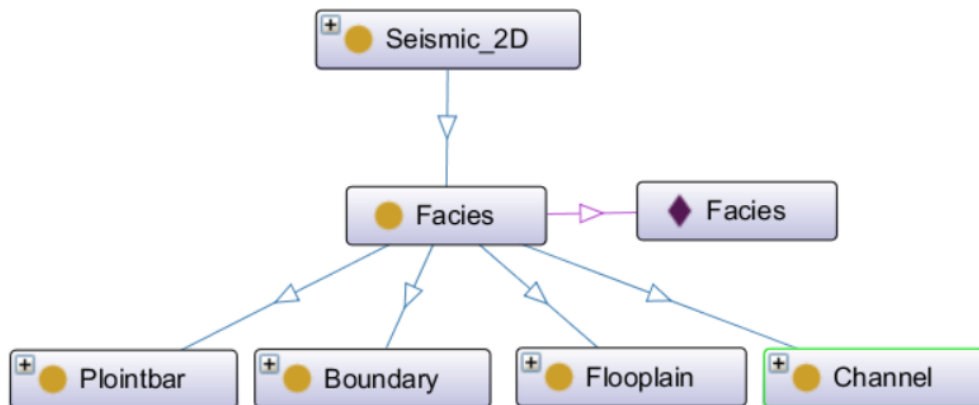


Fonte: Elaborada pelo autor

A.2.2 Tipos de Fácies

Na classe Fácies (Facies) foi atribuído 4 tipos diferentes de fácies, estas são Plointbar, Boundary, Flooplain, Channel, Figura 40.

Figura 40 – Classe Facies no software Protegé.

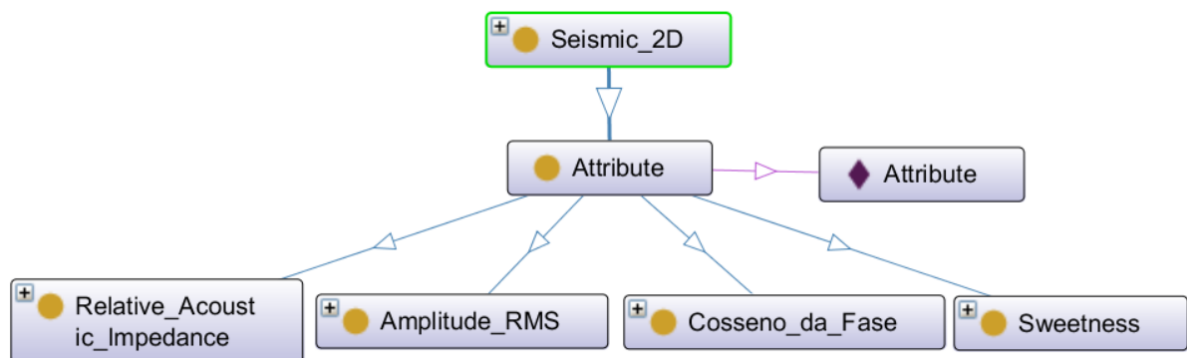


Fonte: Elaborada pelo autor

A.2.3 Tipos de Atributos

Na classe Atributo (Attributes) foi atribuído 4 tipos diferentes, estes são aplicados em sísmicas para expor diferentes características da mesma, Figura 41.

Figura 41 – Classe Attribute no software Protegé.

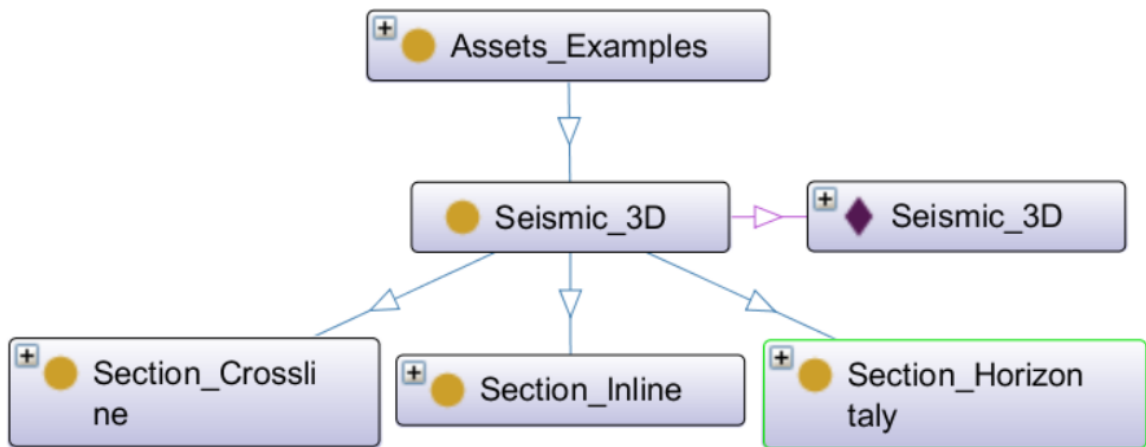


Fonte: Elaborada pelo autor

A.2.4 3D Seismic

A sísmica 3D é composta por 3 classes que compõem os diferentes tipos de cortes utilizados para visualização desta sísmica, que é o corte em crossline, inline e horizontal representando o eixo z ou o tempo, Figura 42.

Figura 42 – Classe Seismic 3D no software Protegé.

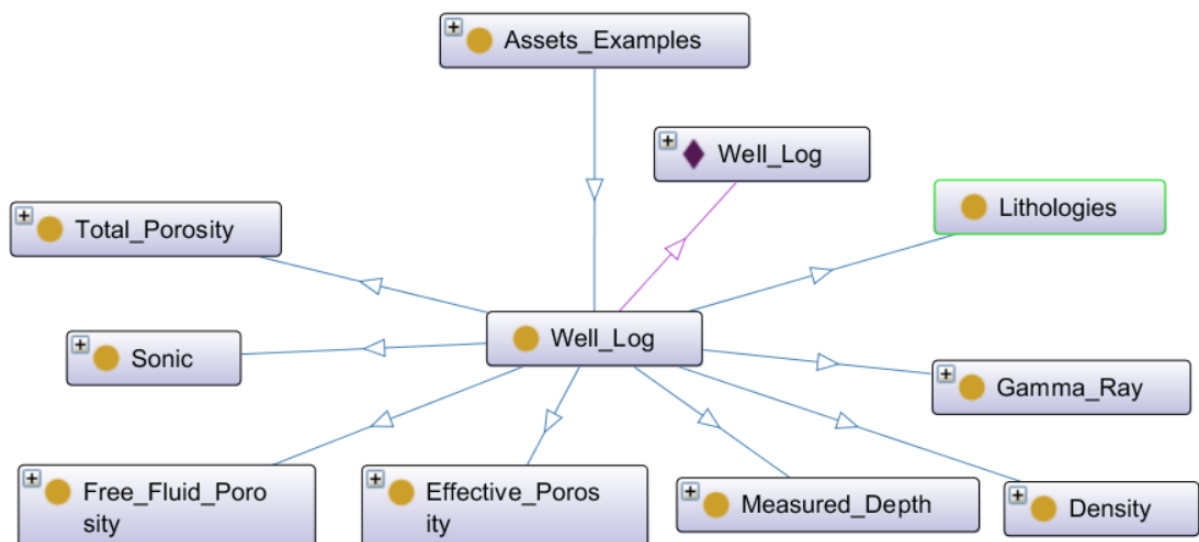


Fonte: Elaborada pelo autor

A.2.5 Well Log

A classe poço (Well Log) contém 8 classes atribuídas que descrevem as informações de um poço, estas são, Total Porosity, Sonic, Free Fluid Porosity, Effective Porosity, Measure Depth, Density, Gamma Ray e Lithologies, Figura 43.

Figura 43 – Classe Well Log no software Protegé.

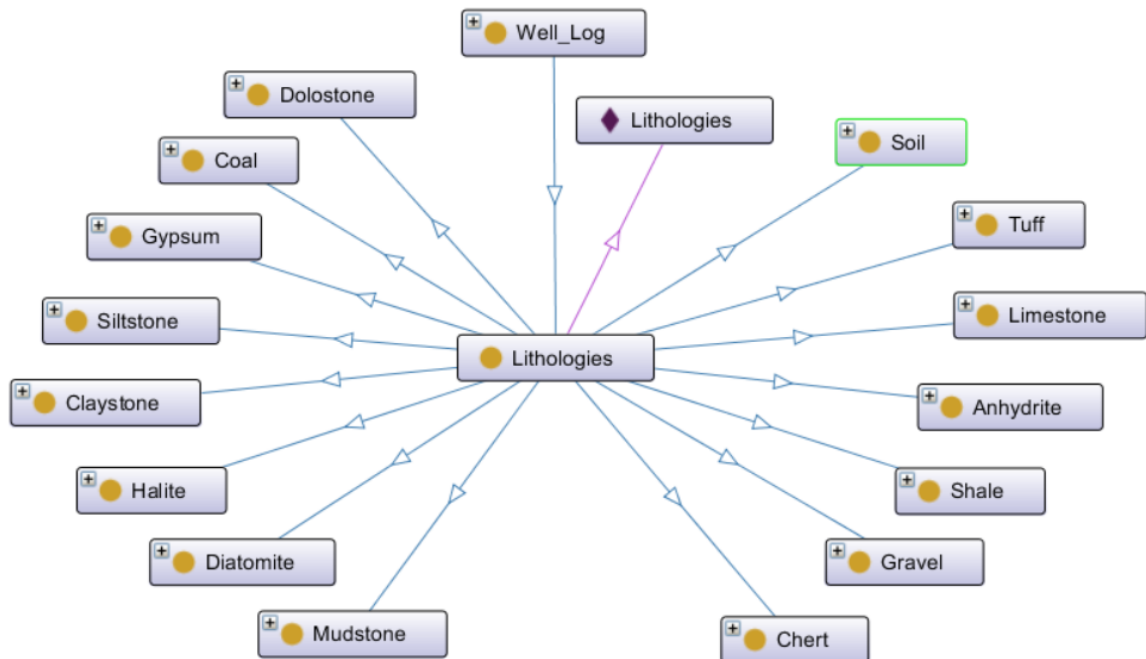


Fonte: Elaborada pelo autor

A.2.6 Lithologies

A classe lithologies contém 15 tipos de litologias que definem os diferentes tipos de rochas, Figura 44.

Figura 44 – Classe Lithologies no software Protegé.



Fonte: Elaborada pelo autor

A.3 F3 Faults

Este conjunto de dados sísmicos foi anotado manualmente como contribuição deste trabalho, gerado utilizando o F3 Block, no software OpendTect, gerando um novo projeto. Em seguida, foi utilizado o cubo sísmico 3D F3 Block e projetado da in-line 102 até a in-line 318, intercalando de 3 a 5, para gerar um conjunto de dados sísmicos com anotações de reconhecimento de falhas, ou seja, gerar anotações de falhas correspondentes para cada uma das seções.

Estas anotações foram geradas utilizando diversos atributos sísmicos que identificam o local de falhas geológicas na sísmica. Neste fluxo foi utilizada a ferramenta de geração de linhas de falhas e depois exportadas estas capturas de dados sísmicos. Estas são pareadas e as anotações de falhas são feitas para cada falha vertical. No total, foram geradas 45 sísmicas com as respectivas falhas geológicas anotadas juntas em uma só imagem e também em diversas imagens separadas, também foram geradas 180 imagens sísmicas e suas respectivas máscaras de falhas com data augmentation, aplicando horizontal flipping e rotação.

O conjunto original com 45 dados sísmicos e suas respectivas máscaras de falhas ficam disponibilizados no link a seguir:

<https://tinyurl.com/3a6f2pt6>.

O conjunto com Data Augmentation e suas respectivas máscaras de falhas ficam disponibilizados no link a seguir:

<https://tinyurl.com/2phabhv2>