



Nelia Cantanhede Reis

**Classificação de fácies sísmicas utilizando
multiatributos sísmicos**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-graduação em Informática da PUC-Rio.

Orientador: Prof. Marcelo Gattass

Rio de Janeiro
Setembro de 2022



Nelia Cantanhede Reis

**Classificação de fácies sísmicas utilizando
multiatributos sísmicos**

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-graduação em Informática da PUC-Rio. Aprovada pela Comissão Examinadora abaixo:

Prof. Marcelo Gattass

Orientador

Departamento de Informática – PUC-Rio

Prof. Alberto Barbosa Raposo

PUC-Rio

Prof. Jan Jose Hurtado Jauregui

PUC-Rio

Prof. Aristófanês Corrêa Silva

UFMA

Rio de Janeiro, 02 de Setembro de 2022

Todos os direitos reservados. A reprodução, total ou parcial do trabalho, é proibida sem a autorização da universidade, do autor e do orientador.

Nelia Cantanhede Reis

Graduada em ciência da computação pela Universidade Federal do Maranhão - UFMA.

Ficha Catalográfica

Reis, Nelia Cantanhede

Classificação de fácies sísmicas utilizando multiatributos sísmicos / Nelia Cantanhede Reis; orientador: Marcelo Gattass. – 2022.

45 f: il. color. ; 30 cm

Dissertação (mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Informática, 2022.

Inclui bibliografia

1. Informática – Teses. 2. Sísmica. 3. Atributos sísmicos. 4. Rede neural. I. Gattass, Marcelo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

Aos meus pais, irmãs e amigos
pelo apoio e encorajamento.

Agradecimentos

Em primeiro lugar agradeço a Deus, pelo dom da vida, em segundo aos meus pais Benedito e Benedita Reis, que sempre me apoiaram com amor, motivação, carinho e tudo que foi necessário para eu chegar até aqui.

As minhas irmãs Nádia e Núbia, que cresceram comigo e sempre estão ao meu lado para o que der e vier, me dando conselhos e me incentivando a crescer cada vez mais.

A Anderson Silva, que topou vir comigo para o Rio se aventurar no mestrado e agora estamos juntos novamente, dessa vez no Doutorado, sempre me incentivando, me dando forças, cuidando de mim e por todos os momentos que compartilhamos nesses últimos anos.

Ao meu orientador Professor Marcelo Gattass, pelos ensinamentos durante esses anos. Sempre atencioso, paciente e prestativo.

Ao meu coorientador Luiz Fernando por todo apoio, paciência e compreensão.

Aos meus amigos, Mayara e Eduardo com quem dividi Apto no Rio, por terem aguentado minhas chatices com bom humor e paciência.

Aos meus amigos do Void Update_Carol que estão comigo desde a graduação, sempre me divertindo e fazendo promessas quando eu voltar para São Luís. Nem mesmo a distância conseguiu separar a gente, juntos até o fim.

Em especial a Carolzinha, por ser uma grande amiga e sempre me ajudar nas dificuldades, me dando forças e palavras de incentivo.

Aos meus colegas do Tecgraf, em especial ao v3o2. Lugar esse onde foi muito importante para meu crescimento acadêmico, pessoal e profissional.

Ao CNPq, o Tecgraf e a PUC-Rio, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

Você, por ter gastado um tempo do seu dia para ler isso.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Resumo

Reis, Nelia Cantanhede; Gattass, Marcelo. **Classificação de fácies sísmicas utilizando multiatributos sísmicos**. Rio de Janeiro, 2022. 45p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

A interpretação sísmica é um processo fundamental para a exploração de hidrocarbonetos. Essa atividade consiste na identificação de informação geológica através do processamento e análise de dados sísmicos. Com o crescimento acentuado e a complexidade dos dados sísmicos, a análise manual de fácies sísmicas tornou-se um desafio significativo. O mapeamento de fácies sísmicas é um processo demorado e que requer profissionais especializados. O objetivo deste trabalho visa aplicar a classificação multiatributos usando uma rede neural *encoder-decoder* para mapear as fácies sísmicas e auxiliar no processo de interpretação. Um conjunto de atributos sísmicos, foram calculados utilizando o *software* Opendtect versão 6.6 a partir dos dados de amplitude contidos no *Dataset Facies-Mark*. Sendo eles: Energia, Pseudo Relevo, Fase instantânea e Textura, todos foram selecionados por um intérprete. A função de perda utilizada pela rede foi *weighted categorical crossentropy*, pelo fato das classes serem consideravelmente desbalanceadas. O treinamento foi realizado nas direções *inlines* e *crosslines* para as respectivas combinações: atributos, atributo + amplitude, e somente a amplitude. Os resultados baseado na métrica *frequency weighted intersection over union* (FWIU), mostraram que os atributos junto com a amplitude obtiveram o melhor resultado, 85,73%, em comparação com as outras combinações citadas. Em comparação direta com o trabalho que inspirou essa dissertação, o multiatributos performou melhor.

Palavras-chave

Sísmica; Atributos sísmicos; Rede neural.

Abstract

Reis, Nelia Cantanhede; Gattass, Marcelo (Advisor). **Classification of seismic facies using seismic multi-attribute**. Rio de Janeiro, 2022. 45p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Seismic interpretation is a fundamental process for hydrocarbon exploration. This activity consists of identifying geological information through the processing and analysis of seismic data. With seismic data's rapid growth and complexity, manual seismic facies analysis has become a significant challenge. Mapping seismic facies is a time-consuming process that requires specialized professionals. The objective of this work is to apply multi-attribute classification using an encoder-decoder neural network to map the seismic facies and assist in the interpretation process. A set of seismic attributes were calculated using Opendtect version 6.6 software from the amplitude data contained in the Facies-Mark Dataset. These being: Energy, Pseudo Relief, Instant Phase, and Texture were all selected by an interpreter. The loss function used by the network was weighted categorical cross-entropy, because the classes are considerably unbalanced. The training was performed in the inlines and crosslines directions for the respective combinations: attributes, attribute + amplitude, and only the amplitude. The results based on the frequency weighted intersection over union (FWIU) metric showed that the attributes along with the amplitude obtained the best result, 85.73%, compared to the other combinations mentioned. In direct comparison with the work that inspired this dissertation, multi-attribute performed better.

Keywords

Seismic; Seismic attributes; Neural network.

Sumário

1	Introdução	13
2	Trabalhos relacionados	15
3	Fundamentação Teórica	17
3.1	Método sísmico	17
3.2	Aquisição	18
3.3	Processamento	19
3.4	Interpretação	21
3.5	Atributos sísmicos	21
3.6	Software Opendtect	23
3.7	Redes Neurais Convolucionais	26
3.8	Redes de Deconvolução	28
4	Metodologia	30
4.1	Dataset	30
4.2	Extração e agregação dos atributos	32
4.3	Arquitetura	34
4.4	Função de <i>loss</i>	35
4.5	Métricas de avaliação	35
5	Resultados e discussão	37
5.1	Experimentos	37
5.2	Comparação com o trabalho de referência	38
5.3	Resultados Qualitativos	40
6	Conclusão e trabalhos futuros	42
7	Referências bibliográficas	43

Lista de figuras

Figura 3.1	Processos de aquisição, terrestre e marítima. Fonte: Gerhardt (1998).	18
Figura 3.2	Traço sísmico (esquerda), linha sísmica (centro) e volume sísmico (direita). Fonte: Figueiredo (2007).	20
Figura 3.3	Modelo de convolução. Fonte: Figueiredo (2007).	20
Figura 3.4	Modelo geológico. Fonte: Figueiredo (2007).	21
Figura 3.5	O plano x, y e z que representa a superfície horizontal, vertical e de profundidade, respectivamente. Fonte: Aziz, Jaafar e Gilal (2017).	24
Figura 3.6	Atributos sísmicos selecionados. Fonte: dGB (2018).	25
Figura 3.7	Ilustração de uma CNN. Fonte: Silva et al. (2017).	27
Figura 3.8	Rede de deconvolução. A CNN é “espelhada” para aprender a deconvolução. Fonte: Maggiori et al. (2016).	29
Figura 4.1	Etapas da metodologia proposta.	30
Figura 4.2	Modelo geológico 3D do bloco F3. Fonte: Alaudah et al. (2019).	31
Figura 4.3	Dados contidos no <i>Dataset</i> . Fonte: Alaudah et al. (2019).	31
Figura 4.4	Distribuição de frequência dos dados de treinamento.	32
Figura 4.5	Partições do conjunto de dados. Fonte: Alaudah et al. (2019).	32
Figura 4.6	Processo de agregação dos atributos para a entrada da rede.	33
Figura 4.7	Exemplo da imagem de entrada na rede.	34
Figura 4.8	Arquitetura da rede de deconvolução. Fonte: Alaudah et al. (2019).	35
Figura 5.1	Comparação entre o trabalho de referência e o nosso modelo em uma <i>inline</i> .	39
Figura 5.2	Caso de acerto em uma <i>inline</i> do <i>dataset</i> de teste.	40
Figura 5.3	Caso de acerto em uma <i>crossline</i> . Sísmica (esquerda), Ground Truth (centro) e Predição (direita).	40
Figura 5.4	Caso de erro em uma <i>inline</i> do <i>dataset</i> de teste.	41
Figura 5.5	Caso de erro em uma <i>crossline</i> . Sísmica (esquerda), Ground Truth (centro) e Predição (direita).	41

Lista de tabelas

Tabela 5.1	Configurações de treinamento de rede.	37
Tabela 5.2	Resultado das métricas de avaliação para Cenário 1.	37
Tabela 5.3	Resultado das métricas de avaliação para os Cenários 2 e 3.	38
Tabela 5.4	Comparação com o trabalho de referência.	39

Lista de Abreviaturas

AC – Acurácia por classe

ADDCNN – Attention-Based Deep Dilated Convolutional Neural Network

AP – Acurácia por pixel

CMP – Common Mid-Point

CNN – Convolutional Neural Network

DA – Data Augmentation

FWIU – Frequency Weighted Intersection over Union

GAN – Generative Adversarial Network

GLCM – Grey-Level Co-occurrence Matrix

GUI – Graphical User Interface

IoU – Intersection over Union

MAC – Média da acurácia por classe

MB – Mega Bytes

MLP – Multilayer Perceptron

ReLU – Rectified Linear Unit

SCE – Sismocamada Elementar

SCSE – Concurrent Spatial and Channel "Squeeze Excitation"

WCE – Weighted Cross-entropy

“Ao infinito e além!”

Buzz Lightyear, *Toy Story*.

1

Introdução

Na exploração de petróleo, o primeiro passo para uma descoberta bem-sucedida de hidrocarbonetos é uma boa imagem da subsuperfície dos dados sísmicos (AL-MOQBEL, 2002). As imagens sísmicas da subsuperfície da Terra são essenciais em todos os aspectos do processo de exploração e produção de petróleo e gás - desde a localização dos campos até sua avaliação, desenvolvimento e monitoramento subsequente. A geofísica divide-se em quatro principais grupos também chamados de métodos: sísmicos, geoeletricos, gravimétrico e magnetométrico. O método sísmico é responsável por mais de 90% dos investimentos em prospecção na indústria do petróleo (THOMAS et al., 2001) pois, a sísmica de exploração de hidrocarbonetos visa modelar as condições da formação e acumulação de hidrocarbonetos na área de estudo.

No contexto da exploração de hidrocarboneto a ferramenta geofísica mais utilizada é o método sísmico de reflexão, que utiliza os princípios da sismologia para estimar as propriedades da subsuperfície da Terra com base na reflexão de ondas sísmicas. Após a aquisição e processamento, é chegada a etapa da interpretação dos dados sísmicos, que serve para conseguir informações acerca da localização aproximada das camadas geológicas de interesse possibilitando assim o estudo mais concreto dos sistemas petrolíferos para posterior exploração (FONTES; BAHIA, 2018).

A interpretação sísmica é um dos procedimentos essenciais na tarefa de localização de hidrocarbonetos. Na área de exploração de petróleo, a discriminação litológica se torna uma tarefa importante uma vez que esta descreve as características físicas das rochas e suas respectivas camadas. Com base nessa descrição e conhecendo a localização de cada tipo de rocha, é possível inferir onde se encontram as formações geradoras de concentração de hidrocarboneto e principalmente reservatórios. A partir da análise desses dados, os especialistas podem identificar características estruturais e estratigráficas. No entanto, a interpretação e análise sísmica é uma tarefa árdua e demorada que pode sobrecarregar os intérpretes, pois a quantidade de informações geofísicas está continuamente aumentando (RANDEN et al., 2000).

Os atributos sísmicos surgiram na tentativa de transformar o processo de interpretação sísmica em algo menos subjetivo e baseado na experiência, num processo mais rápido e objetivo, particularmente quando se está trabalhando com volumes de dados sísmicos 3D. Eles são uma excelente ferramenta de análise dos dados que complementam a experiência do intérprete realçando,

identificando e correlacionando os eventos dos dados da sísmica automaticamente com as estruturas geológicas reais (CHOPRA; MARFURT, 2005).

Este trabalho apresenta uma metodologia para classificação automática de fácies sísmicas utilizando multiatributos sísmicos. A vantagem dessa estratégia é integrar as informações de vários atributos em um único processo de classificação, e assim fornecer um resultado integrado contendo as melhores informações que cada um pode oferecer. O processo de classificação de fácies sísmicas multiatributos consiste em identificar padrões levando em consideração a variabilidade dos mesmos e, assim, revelar detalhes sobre as feições geológicas.

Este trabalho está organizado em mais 5 capítulos, sendo que o Capítulo 2 apresenta alguns trabalhos da literatura que também tem o intuito de classificar fácies sísmicas. O Capítulo 3 contém a fundamentação teórica utilizada como base para o desenvolvimento deste trabalho. O Capítulo 4 inicialmente apresenta a base utilizada no desenvolvimento deste trabalho, e logo após discorre sobre os passos do método proposto. Os resultados obtidos são apresentados e discutidos no capítulo 5, bem como a comparação do nosso trabalho com um trabalho da literatura, utilizado como base. Por fim, o Capítulo 6 conclui este trabalho com as considerações finais e trabalhos futuros.

2

Trabalhos relacionados

Em Liu et al. (2020) foram propostas duas redes para classificação de fácies sísmica, uma foi rede neural convolucional (CNN) e a outra foi rede adversária geradora (GAN). Três testes foram realizados, o primeiro com uma CNN supervisionada usando dados sintéticos rotulados. O segundo, foi com a GAN semi-supervisionada usando os mesmos dados sintéticos da CNN, só que poucas amostras rotuladas e por fim a GAN semi-supervisionada nos dados sísmico F3 do setor holandês do Mar do Norte. O melhor resultado foi da GAN em comparação a CNN, usando poucos dados rotulados, o que mostrou que essa estratégia pode ser bastante útil quando não se tem um grande número de dados anotados.

Alaudah et al. (2019) propuseram uma arquitetura de rede de deconvolução para a classificação de fácies sísmicas. O trabalho compara o modelo em duas estratégias: com o uso de patches e o outro baseado na seção sísmica inteira. Além disso, foram usadas técnicas de data augmentation e skip connections. O melhor resultado encontrado foi o modelo baseado em seção usando augmentation e skip connections.

Já Li et al. (2020) propuseram uma rede neural convolucional de dilatação profunda baseada em mecanismo de atenção suave treinável (ADDCNN) para melhorar a análise automática de fácies sísmicas. O modelo ADDCNN proposto inclui três estruturas inovadoras principais: engenharia de recursos, convoluções dilatadas e mapeamento de atenção espacial-espectral. Eles utilizaram os dados do F3 *Block* para realizar os experimentos, um especialista independente rotulou as amostras do *Dataset*, a interseção sobre união (IoU) foi adotada como métrica de avaliação. Os resultados foram comparados com outras redes da literatura com o mesmo objetivo, a ADDCNN se mostrou bem eficiente e superando as adversárias.

Zini, Rizk e Awad (2020) implementaram a SeisNet, uma rede neural convolucional com uma arquitetura “borboleta” que superou o desafio limitado de dados, implementando técnicas de *Data Augmentation* e *Transfer Learning*. Inicialmente eles usaram a rede para detecção de *bright spots* em dados sísmicos. Depois testaram a mesma rede para classificação de facies sísmicas, em ambos os experimentos os resultados foram satisfatórios.

No trabalho de Zhao (2018) utilizaram uma rede do tipo *encoder-decoder* para classificação de fácies. Essa rede foi treinada no levantamento sísmico F3 adquirida no Mar do Norte. Esse modelo alcançou 94,1% de precisão.

Zhang et al. (2021) construíram uma CNN 3D e outra com uma arquitetura *encoder-decoder*, em seguida, aplicaram um codificador-decodificador aprimorado. Fizeram uso de aumento de dados de forma automática e diversificada, usando seções sísmicas 2D rotuladas nas quais as fácies são divididas em nove classes. Realizaram experimentos no conjunto de dados F3 da Holanda. Os resultados dos testes dos codificador-decodificador foram mais precisos e eficientes do que os da CNN. Os valores médios da interseção sobre união (IoU) para os codificadores-decodificadores foi 87,8% (convencional) e 92,4% (aprimorado), respectivamente, já para a CNN, o valor foi de 67,8%.

Em Trinidad et al. (2021) implementaram dois modelos de CNN baseados na LSTM para classificação de fácies sísmicas. O *Dataset* utilizado foi o bloco F3 da Holanda, os resultados obtidos foram promissores chegando bem próximos de outras arquiteturas utilizadas por outros trabalhos da literatura para essa mesma tarefa de classificação.

Tolstaya e Egorov (2022) Usaram uma arquitetura de codificador-decodificador bem conhecida, UNet, com EfficientNetB1 como backbone e quatro níveis de *encoder* com SCSE (Concurrent Spatial and Channel "Squeeze Excitation") na camada de atenção, no *Dataset* totalmente anotado de código aberto do Bloco F3 da Holanda. O modelo recebe *patches* de tamanho 256x256 *pixels* como entrada e prevê os rótulos para esses *patches*. Canal adicional com gradiente de profundidade é introduzido nas imagens sísmicas, para que o modelo não misture estruturas geológicas profundas e rasas. Eles utilizaram *Data Augmentation* em alguns modelos. Um modelo é treinado, depois disso uma parte dos rótulos é prevista e adicionada ao conjunto de treinamento. Em seguida, o modelo é retreinado no conjunto de dados expandido. Os resultados foram bastante satisfatórios, seu melhor modelo usando pseudo-rótulos obteve 85% baseado na média IoU.

3 Fundamentação Teórica

Neste capítulo é apresentado um dos principais métodos sísmico na exploração de hidrocarbonetos, os atributos sísmicos e técnicas computacionais aplicadas no trabalho.

3.1 Método sísmico

O trabalho atual aproveita particularidades de diversas áreas de atuação, assim é vital introduzir algumas das ideias fundamentais relacionadas com a investigação sísmica devido à sua natureza interdisciplinar. Então, veremos brevemente o processo de aquisição, processamento e interpretação sísmica em três dimensões nas partes a seguir.

As próximas seções são fortemente baseadas no capítulo correlato das Dissertações de Mestrado de José Marcos Pilato Jr. (JR., 2009), André Luís Barreto Gerhardt (GERHARDT, 1998) e Aurélio Moraes Figueiredo (FIGUEIREDO, 2007).

A descoberta de uma nova jazida de petróleo é uma tarefa que envolve um longo tempo de estudos e análises. Somente após exaustivo prognóstico do comportamento de diversas camadas do subsolo, os geólogos e geofísicos decidem propor a perfuração de um poço, que é a etapa no qual mais investimentos exige em todo o processo de prospecção. Um programa de prospecção tem basicamente dois objetivos: o primeiro é localizar dentro de uma bacia sedimentar situações geológicas que tenham condição para a acumulação de petróleo; e o segundo verificar, entre as situações encontradas, qual possui mais chance de conter petróleo. A identificação de uma área favorável a acumulação de petróleo é realizada através de métodos geológicos e geofísicos que, atuando em conjunto, conseguem indicar o local mais propício para a perfuração.

O método sísmico de reflexão é o método mais utilizado atualmente na indústria de petróleo, pois fornece alta definição das características geológicas em subsuperfície propícia à acumulação de hidrocarbonetos, a um custo relativamente baixo. Mais de 90% dos investimentos em prospecção são aplicados em sísmica de reflexão (THOMAS et al., 2001). Os produtos finais são, entre outros, imagens das estruturas e camadas geológicas em subsuperfície, apresentadas sob as mais diversas formas, que são disponibilizadas para o trabalho dos intérpretes. Segundo Robinson e Treitel (2000) a exploração de hidrocarbône-

tos, óleo e gás baseada em sísmica pode ser dividida em três etapas: aquisição, processamento e interpretação. Veremos a seguir um breve resumo de cada etapa.

3.2 Aquisição

Existem diversas técnicas de aquisição sísmica. Este trabalho se limita aos procedimentos envolvidos no método de aquisição CMP (Common Mid-Point). Uma ilustração do esquema de aquisição bidimensional em terra e no mar é apresentada na Figura 3.1. No caso da aquisição tridimensional são empregadas mais linhas de receptores em paralelo.

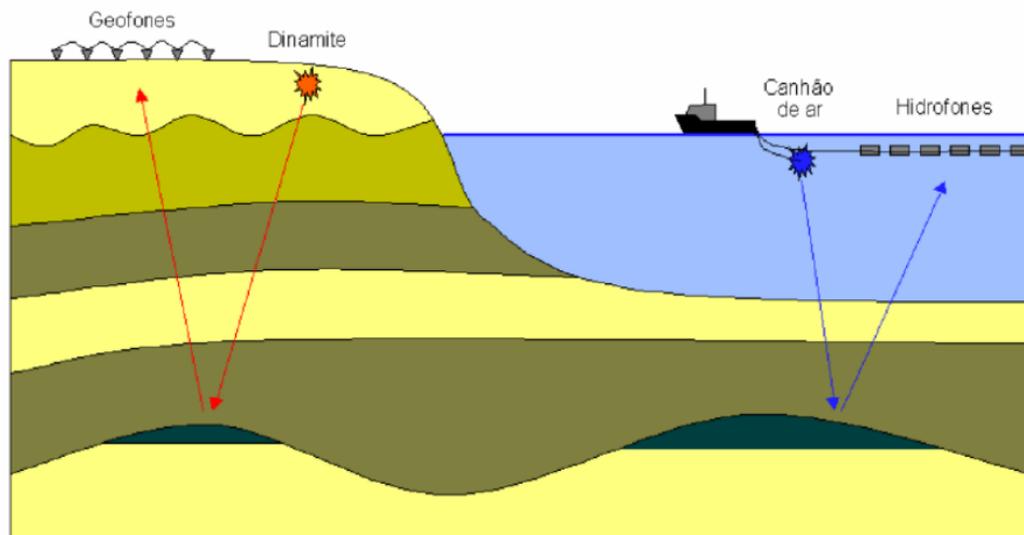


Figura 3.1: Processos de aquisição, terrestre e marítima. Fonte: Gerhardt (1998).

As fontes sísmicas convencionais podem ser explosões de dinamite, canhões pneumáticos de ar, vibradores possantes, etc. Os receptores são geofones, que medem a velocidade da passagem do pulso sísmico pelo terreno, ou hidrofones, que medem a variação de pressão por ele gerada na água. Ambos são transdutores que convertem as variações das ondas sísmicas em valores de tensão. Estes são genericamente denominados amplitudes sísmicas e variam de negativo a positivo, sendo armazenados como números em representação digital de ponto flutuante. Cada fonte é composta por um grupo de diversos elementos, distribuídos segundo um arranjo com o intuito de melhorar o acoplamento com o solo (no caso da aquisição terrestre) ou modelar um pulso desejado através de interferência (na aquisição marítima). Da mesma forma, cada estação de receptores é formada por um arranjo de diversos elementos, com o objetivo de discriminar os comprimentos de onda dos ruídos coerentes

e atenuar o ruído ambiental em relação ao sinal. A cada fonte corresponde um grande número de receptores, podendo chegar facilmente a mil em levantamentos tridimensionais. Os receptores são conectados ao equipamento de controle e registro denominado sismógrafo, que executa a conversão analógico-digital dos valores de amplitude e armazena os dados em meio magnético. Em geral os dados são registrados entre quatro e oito segundos, com um intervalo de amostragem de dois milisegundos, o que pode gerar uma massa de dados de até 16 MB por registro.

Após adquirir os dados em uma determinada posição de tiro, o dispositivo de registro (fontes e receptores) é movido para a posição seguinte e o processo é repetido até que a cobertura total da área seja atingida. Esta movimentação é feita segundo critérios (e.g., intervalo de tiros, receptores, número de canais [receptores] ativos por tiro, etc.) que determinam o custo do levantamento.

3.3

Processamento

No processamento dos dados sísmicos, alguns erros inerentes ao levantamento sísmico são corrigidos, e os dados são reorganizados para formarem uma grade tridimensional com uma amostra de amplitude sísmica em cada vértice da grade (voxel). Duas das dimensões do conjunto de dados são direções espaciais e estão relacionadas com as posições das fontes e dos receptores. Uma das transformações realizadas nos dados durante o processamento faz com que as posições da fonte e do receptor sejam a mesma, formando uma linha vertical. Uma vez encontrada essa linha, as amostras são obtidas medindo o tempo que a onda leva para ir e voltar por cada intervalo de profundidade.

A organização das amostras em um dado sísmico é mostrada na Figura 3.2. Do lado esquerdo temos a função de amplitudes sísmicas do traço sísmico, na qual a única dimensão é a temporal (1D). Nesse caso, o traço de amplitudes é representado através de um sinal ondulante. No centro temos uma seção vertical do conjunto de dados formada por um conjunto de traços sísmicos, que é chamada de linha sísmica (2D), com uma dimensão espacial e a outra temporal. 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. Vale notar que, ao mostrarmos dados em 2D e 3D a forma de representação do sinal de cada um dos traços sísmicos deixa de ser feita a partir de um sinal ondulante, passando a ser feita através de uma escada de cores onde cada cor representa a amplitude da onda em cada ponto.

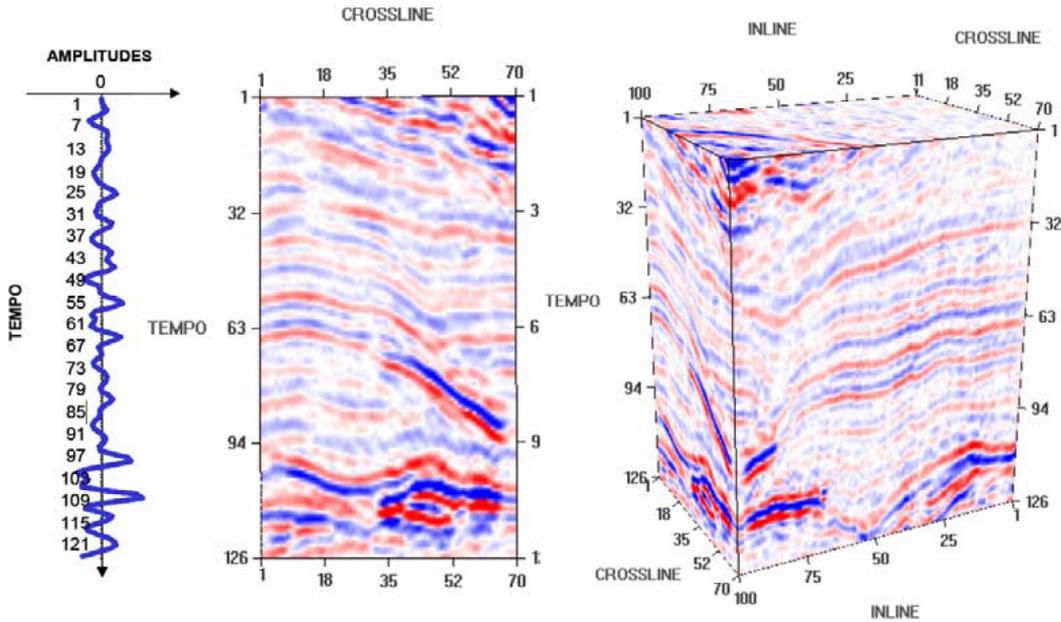


Figura 3.2: Traço sísmico (esquerda), linha sísmica (centro) e volume sísmico (direita). Fonte: Figueiredo (2007).

Um modelo matemático interessante que descreve bem o efeito do processamento sísmico realizado sobre o dado é o modelo de convolução, ilustrado na Figura 3.3. Neste modelo consideramos a função de amplitude sísmica de cada traço do conjunto de dados como sendo o resultado da convolução de um impulso sísmico com uma função refletividade, essa função é uma distribuição de coeficientes de reflexão. Os coeficientes de reflexão são proporcionais à diferença de impedância acústica entre camadas geológicas adjacentes.

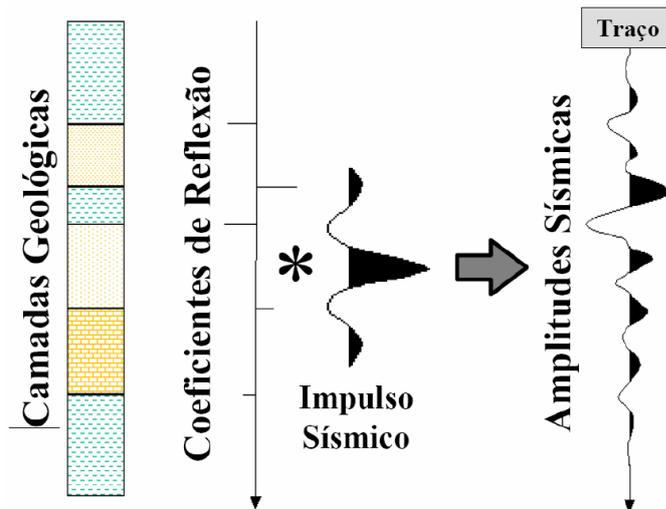


Figura 3.3: Modelo de convolução. Fonte: Figueiredo (2007).

3.4 Interpretação

Na etapa de interpretação, o intérprete, em geral um geólogo ou geofísico, analisa os dados sísmicos e tenta criar um modelo que represente a geologia contida na área do levantamento, normalmente envolvendo a integração de diversos métodos de investigação diretos e indiretos. A determinação do modelo é um problema de solução indeterminada, uma vez que diversas configurações geológicas podem produzir as mesmas medidas observadas. Portanto, a interpretação é um processo subjetivo baseado em medidas indiretas (métodos geofísicos) e balizado por informações diretas pontuais (adquiridas nos poços).

O objetivo principal da interpretação dos dados sísmicos é determinar a posição e atitude dos refletores a partir das medidas de tempo de percurso e inferir a estrutura geológica e a estratigrafia. O modelo da subsuperfície pode então ser reconstruído com base no tempo de percurso, na velocidade média e na amplitude das ondas refletidas.

A Figura 3.4 mostra um modelo geológico que poderia ser resultante da interpretação de uma linha sísmica. A interpretação sísmica pode ser classificada, de acordo com o foco, em dois tipos: estrutural e estratigráfica. A interpretação estrutural basicamente tenta identificar as camadas geológicas ou, de forma equivalente, as interfaces entre as camadas, bem como as falhas geológicas que recortam as camadas. Na interpretação estratigráfica o foco do trabalho está em entender a maneira como as camadas foram se formando ao longo do tempo.

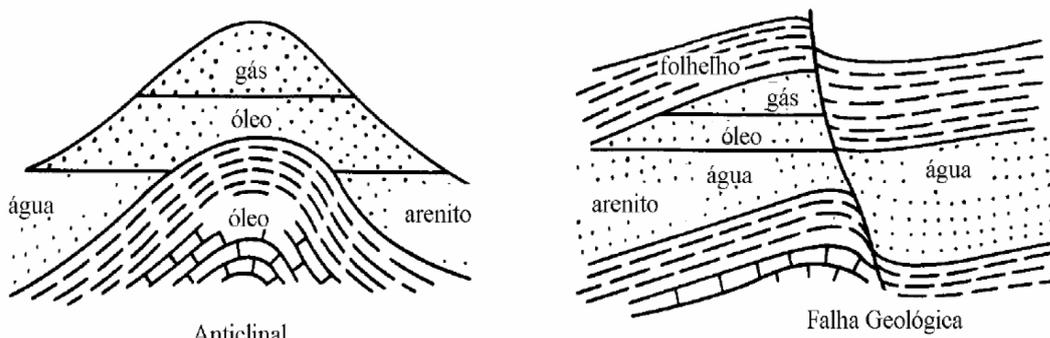


Figura 3.4: Modelo geológico. Fonte: Figueiredo (2007).

3.5 Atributos sísmicos

Variados conceitos sobre a real definição dos atributos estão presentes na vida de diversos intérpretes sísmicos. Segundo Taner (2001), eles são representados por toda e qualquer informação extraída do dado sísmico, seja

por medições diretas, lógicas ou por análise empírica baseada em experiência. Já na visão de Barnes (2001), eles são um subconjunto ou um componente do dado sísmico, tal que esse dado pode ser visto como uma soma de seus componentes ou até mesmo, um filtro, que pode remover algumas informações e destacar outras. No entanto, é consenso entre a comunidade científica que os atributos sísmicos existem em vários tipos, qualidades e funcionalidades para melhor identificar um determinado material e auxiliar o intérprete a gerar um modelo geológico de uma determinada área sísmica, para que um melhor detalhamento da região de interesse seja viabilizado, extraíndo informações geológicas, estruturais e físicas da subsuperfície (JANNUZZI, 2020).

Os atributos provocam uma decomposição do dado sísmico de forma informal, sem haver nenhuma regulamentação para tal atividade segundo Barnes (2001) e seu desenvolvimento segundo Taner (2001) colabora para a compreensão da subsuperfície e reduz as incertezas e riscos, embora possua falhas intrínsecas ao método. No entanto, a interpretação de um dado sísmico a partir da visão dada por um atributo pode tornar o dado muito mais proveitoso revelando informações “escondidas” antes da aplicação de um atributo. Assim, essa revelação proporcionada pelos atributos é feita por meio da análise do sinal sísmico e técnicas de extração de informações dele.

Após anos de uso e desenvolvimento dos atributos sísmicos, sendo cada um deles utilizado para diversas aplicações, tornou-se cada vez mais difícil a filtragem deles para cada função. Por esse motivo, fez-se necessária a classificação desses atributos em categorias para auxiliar o intérprete na decisão sobre qual deles deve ser utilizado de acordo com as necessidades do dado sísmico que estão trabalhando e do que se deseja enxergar nesse dado (JANNUZZI, 2020).

Visando promover uma melhor organização dos atributos, uma classificação foi proposta por Chen e Sidney (1997) e modificada mais tarde por Brown (2011) e por Barnes (2016). Na classificação mais recente, os atributos foram separados em três grandes grupos, definidos como geológicos, geofísicos e matemáticos. Segundo Barnes (2016), os geológicos seriam os mais notórios nos estudos de interpretação sísmica para exploração de hidrocarbonetos e caracterização de reservatórios além de serem mais fáceis de entender, apesar de apresentarem maior dificuldade em sua quantificação. Os geofísicos foram considerados de utilidade intermediária e os atributos matemáticos de menor utilidade, dentre os estudos realizados.

Os atributos geológicos gravam as propriedades estruturais, estratigráficas e litológicas do dado sísmico. Os atributos geofísicos, por sua vez, gravam informações relativas às ondas e *wavelets*, eles incluem amplitude, fase, frequên-

cia e banda larga. Para o uso destes, é necessária a inversão, feita automaticamente em softwares específicos, ou interpretação para obter as informações geológicas. Contém, ainda, informações diretas e relativamente exatas diferentemente dos geológicos, no entanto podem ser mais difíceis de compreender e relacionar com a geologia. Os atributos matemáticos são relativos as médias, variâncias, raio e outras estatísticas relacionadas aos dados sísmicos. Representam a maior parcela entre os três tipos, pois são os mais simples de serem criados. No entanto, devido a sua natureza pouco interpretativa e mais exata, apresenta a mais baixa relação com a geologia dentre os métodos (BARNES, 2016).

Dessa forma, apesar de diversos, é importante ressaltar que a escolha do modelo de classificação e do grupo de atributo que será usado, é diretamente sensível às características geológicas desejadas ou propriedades do reservatório de interesse, ou nos permite definir o ambiente estrutural ou deposicional e, assim, permite a influência de algumas características ou propriedades de interesse (CHOPRA; MARFURT, 2007).

3.6 Software *Opendtect*

O software *Opendtect* da dGB Earth Sciences oferece uma grande variedade de ferramentas, por exemplo a possibilidade de fazer avaliação sísmica 3D, análise de planos de corte em qualquer direção, poços correlacionados, estudar fraturas e falhas, traçar poços, perfilar, aplicar atributos sísmicos e filtros, entre outros. As principais características do *Opendtect* são o recurso Rastreamento de horizontes, Visualização e Atributos Sísmicos. É uma interface gráfica de usuário ou software baseado em GUI (Graphical User Interface) que suporta três plataformas que são versões do Windows, Mac OS/X e distribuições Linux. Instalamos o *Opendtect* versão 6.6 para fazer a extração dos atributos. A subseção 3.6.1 descreve o termo horizonte e explica a técnica do *Horizon Tracking*. A subseção 3.6.2 descreve a funcionalidade de Visualização Sísmica e a subseção 3.6.3 define os atributos sísmicos.

3.6.1 Rastreamento de Horizonte Sísmico

Horizonte Sísmico significa um nível estratigráfico ou uma camada do subsolo da Terra. Horizonte em sísmica também corresponde à superfície de um meio terrestre em um sistema de coordenadas 3D de um plano x, y e z (HART, 1999). A Terra é composta de muitas camadas, onde cada camada tem uma superfície horizontal. O *OpenDtect* é capaz de construir uma imagem

tridimensional (3D) para cada camada da Terra a partir de dados sísmicos processados. O processo de construção de uma representação visual de um horizonte sísmico a partir de registros sísmicos é conhecido como *Seismic Horizon Tracking*.

3.6.2 Interpretação e Visualização Sísmica

A capacidade de visualizar dados sísmicos é importante para auxiliar o geofísico na determinação das composições do subsolo da Terra. Interpretar as estruturas e composições da Terra tais como sedimentos rochosos; granito, sal, água e porosidade é essencial para determinar possíveis armadilhas de hidrocarbonetos. O hidrocarboneto acumula-se frequentemente perto de meios permeáveis, como sal e areia. Os atributos porosos de um meio, como sal e areia, permitem que fluidos de hidrocarbonetos se infiltrem na superfície da intensa pressão ascendente do manto terrestre. O movimento dos fluidos de hidrocarbonetos geralmente para quando obstruído por uma camada sólida da Terra, como a rocha. O fluido de hidrocarboneto acumulado conhecido como reservatório de hidrocarboneto é comumente aprisionado em uma estrutura previsível semelhante à da Terra.

A tecnologia gráfica recente possibilitou a construção de uma imagem sísmica 3D a partir dos dados processados. A imagem 3D subsiste em um sistema de 3 coordenadas; que é o plano x; representando superfície horizontal; o plano y; representando a superfície vertical e o plano z; que representa a profundidade mostrada na Figura 3.5.

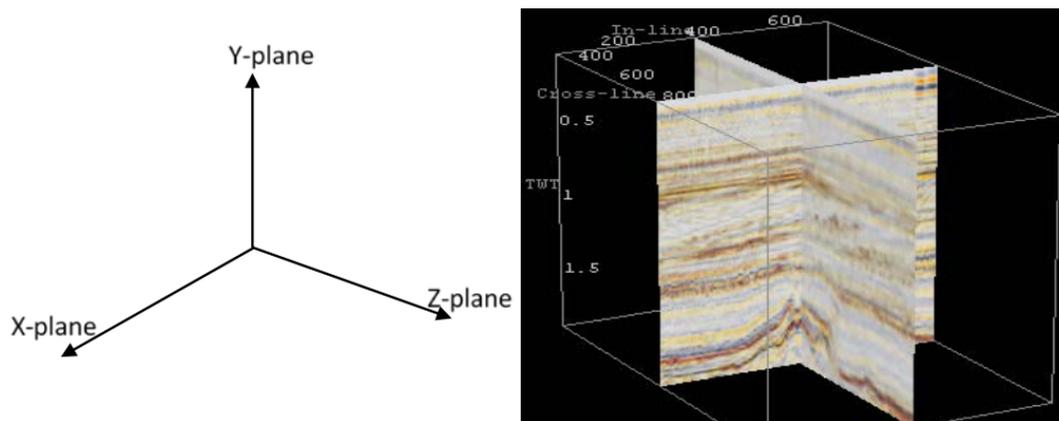


Figura 3.5: O plano x, y e z que representa a superfície horizontal, vertical e de profundidade, respectivamente. Fonte: Aziz, Jaafar e Gilal (2017).

A Figura 3.5 representa dados sísmicos visualizados em 3D que existem em um sistema de coordenadas 3D. A estrutura geológica e a subestrutura da Terra são aparentes. O sucesso da interpretação do conjunto de dados

sísmicos muitas vezes reside na riqueza das informações manifestadas nos dados visualizados. Melhorar as propriedades gráficas como renderização, intensidades de cor e representações de alta dimensão são capazes de aprimorar as informações ou atributos de litologia sutis que existem originalmente em um conjunto de dados sísmicos.

3.6.3

Atributos Sísmicos Seleccionados

Uma das funcionalidades do *Opendtect* é a extração de atributos. O *software* possui uma variedade de atributos disponíveis de forma gratuita para serem extraídos. A interface facilita o manuseio e com apenas alguns cliques são gerados volumes de atributos a partir do dado de amplitude escolhido. Neste trabalho, os atributos utilizados foram escolhidos por um especialista, sendo eles: Energia, Pseudo Relevo, Fase Instantânea e Textura. A Figura 3.6 mostra os atributos seleccionados para extração através do *software*.

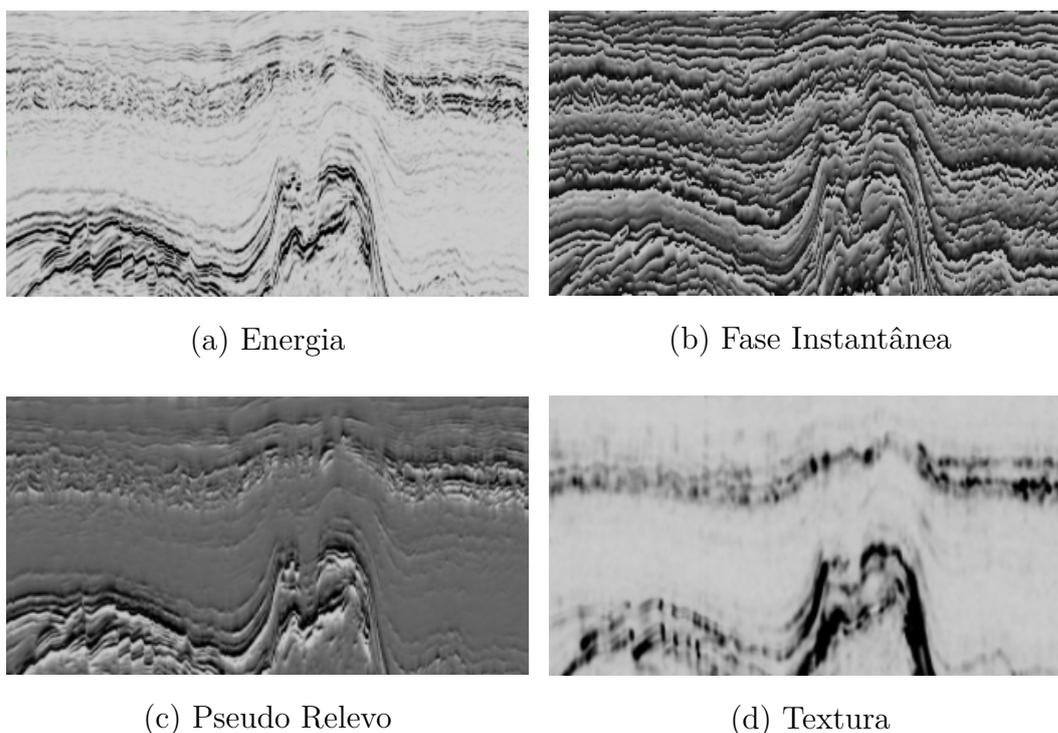


Figura 3.6: Atributos sísmicos seleccionados. Fonte: dGB (2018).

As informações a seguir sobre os atributos seleccionados foram retiradas do dGB (2018).

O atributo de Energia calcula a soma quadrada dos valores de amostra no *time-gate* especificado dividido pelo número de amostras no gate. A Energia é uma medida de refletividade no intervalo de tempo especificado. Quanto maior a energia, maior a amplitude. Este atributo aumenta, entre outras, variações

laterais dentro de eventos sísmicos e é, portanto, útil para detecção de objetos sísmicos. A energia de resposta também caracteriza as propriedades acústicas da rocha e a espessura do leito.

A Fase Instantânea calcula a fase instantânea no local da amostra, enfatiza a continuidade/descontinuidade espacial das reflexões, fornecendo uma maneira de eventos fracos e fortes aparecerem com a mesma força. Esse atributo é de importância central, pois descreve a localização dos eventos no traçado sísmico e permite o cálculo de outras grandezas instantâneas. A fase instantânea torna os eventos fortes mais claros e é eficaz em destacar descontinuidades de refletores, falhas, *pinch-outs*, angularidades e interfaces de leito. Limites de sequências sísmicas, padrões de camadas sedimentares e regiões de padrões *onlap/offlap* geralmente exibem clareza extra. A fase instantânea refere-se ao componente de fase da propagação da onda, também é usada para calcular a velocidade da fase.

Pseudo Relevância é um atributo desenvolvido por Bulhões e Amorim (2005) ele calcula a média quadrática em uma janela deslizante no tempo. Para obter este atributo é utilizado o princípio da sismocamada elementar (SCE), que é a camada de rocha com menor espessura que o dado sísmico consegue registrar. Definido o topo (t_1) e base (t_2) da SCE, tem-se uma janela de tempo, a qual dará o número de amostras a ser utilizado no cálculo da média móvel ao longo do traço (ALMEIDA, 2019).

Textura são um grupo de atributos que retornam propriedades estatísticas de uma *Grey-Level Co-occurrence Matrix* (GLCM). Para mais detalhes sobre como são implementados no OpendTect consulte (HALL-BEYER, 2017) Os atributos de textura do GLCM são provenientes do processamento de imagens e foram desenvolvidos para capturar a rugosidade/suavidade de uma imagem. A resposta do atributo é calculada em duas etapas: Primeiro o GLCM é calculado para uma área (volume) ao redor do ponto de avaliação. Em segundo lugar, uma propriedade estatística do GLCM é retornada. O GLCM é uma matriz 2D que captura a frequência com que os valores vizinhos A e B ocorrem em uma imagem. O atributo de textura usando neste trabalho foi o baseado em contraste.

3.7

Redes Neurais Convolucionais

As redes neurais convolucionais (CNN, do inglês *Convolutional Neural Networks*) são modelos de aprendizagem profunda biologicamente inspirados que buscam reproduzir os mecanismos de percepção visual com o objetivo de aprender os padrões locais e espaciais de objetos de interesse (HUA et al.,

2015). Uma CNN é tipicamente composta de várias camadas de convoluções e subamostragem (que são responsáveis pelo processo implícito de extração de características), seguidas por uma rede *Multilayer Perceptron* (MLP) completamente conectada (responsável pela classificação dos padrões de entrada). A Figura 3.7 mostra a arquitetura de uma CNN.

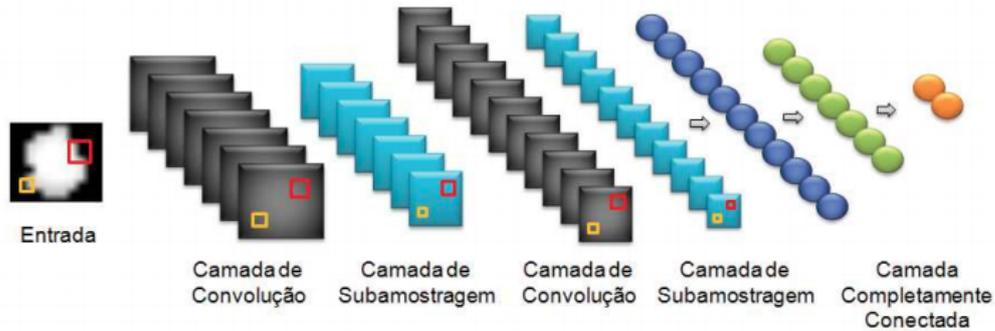


Figura 3.7: Ilustração de uma CNN. Fonte: Silva et al. (2017).

As características extraídas em cada camada são combinadas através de seus campos receptivos locais, que conectam uma camada com sua anterior. Isso permite que características de mais alto nível sejam extraídas a partir das características combinadas da camada anterior, como bordas ou cantos (FERNANDES, 2013).

Uma camada de convolução é composta por filtros treináveis que são aplicados individualmente em toda a extensão da imagem de entrada, gerando vários mapas de características (LECUN; KAVUKCUOGLU; FARABET, 2010). Cada filtro será responsável pela detecção de uma característica que ocorre em qualquer parte da imagem após a rede ser treinada (SILVA et al., 2017). A Equação 3-1 mostra uma definição do cálculo do mapa de características, onde: k é o índice do neurônio; h_k é o mapa de características com saída k ; w_k é o filtro treinável k ; x é o mapa de características de entrada do neurônio; b_k é o valor de *bias* k ; e o operador $*$ representa o processo de convolução espacial bi-dimensional (LECUN; KAVUKCUOGLU; FARABET, 2010).

$$(h_k)_{ij} = (w_k * x)_{ij} + b_k \quad (3-1)$$

Uma convolução espacial é a aplicação de uma janela $N \times M$ (onde normalmente $N = M$) em uma imagem, de tal maneira que essa janela percorre a imagem inteira, sempre sobrepondo uma região da imagem. Essa aplicação gera uma nova imagem onde cada valor de *pixel* Z_{ij} é calculado pela Equação 3-2:

$$(Z)_{ij} = \sum_{k=1}^{N \cdot M} Z_k W_k \quad (3-2)$$

onde W_k são os valores da janela de convolução, e Z_k são os valores de *pixel* da imagem original que estão sendo sobrepostos por W_k . A janela percorrerá a imagem original, desde o seu canto superior esquerdo até seu canto inferior direito (FILHO; NETO, 1999).

As camadas de subamostragem são responsáveis por reduzir a resolução espacial dos mapas de características e selecionar as características invariantes a translações e distorções (LECUN et al., 1998). Um dos tipos de subamostragem mais comuns é a ativação máxima (*Max Pooling*), onde apenas o *pixel* de maior intensidade do campo receptivo anterior é mantido.

Por fim, as características extraídas pelas camadas de convolução e subamostragem (os *pixels* de todos os mapas de características da camada anterior) são apresentadas a rede MLP completamente conectada, que é responsável por classificar os padrões de entrada (FERNANDES, 2013).

3.8

Redes de Deconvolução

As redes deconvolucionais são redes neurais convolucionais que funcionam em um processo reverso. As redes deconvolucionais, também conhecidas como redes neurais deconvolucionais, são de natureza muito semelhante às CNNs executadas ao contrário, mas são uma aplicação distinta da inteligência artificial.

As redes deconvolucionais se esforçam para encontrar recursos ou sinais perdidos que podem não ter sido considerados importantes para a tarefa de uma CNN. Um sinal pode ser perdido devido a ter sido enrolado com outros sinais. A deconvolução de sinais pode ser usada tanto na síntese quanto na análise de imagens.

Na convolução é feita a soma das informações espalhadas em vários *pixels* para um *pixels*, enquanto a deconvolução espalha as informações presentes em um *pixels* para vários *pixels*. A Figura 3.8 apresenta o exemplo de uma arquitetura convolucional/deconvolucional. Assim, a camada de deconvolução é uma operação matemática que reverte o processo de uma camada convolucional.

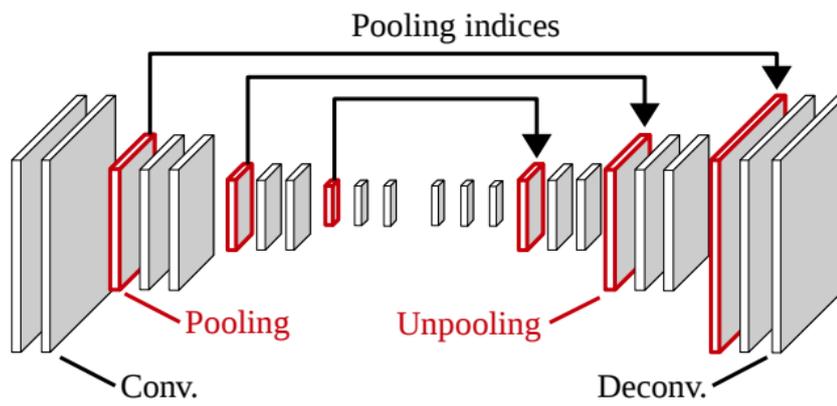


Figura 3.8: Rede de deconvolução. A CNN é “espelhada” para aprender a deconvolução. Fonte: Maggiori et al. (2016).

4 Metodologia

Este Capítulo descreve as etapas que foram realizadas no desenvolvimento do trabalho. A Figura 4.1 apresenta, de forma resumida, as sequência de etapas que foram empregadas nesse trabalho.

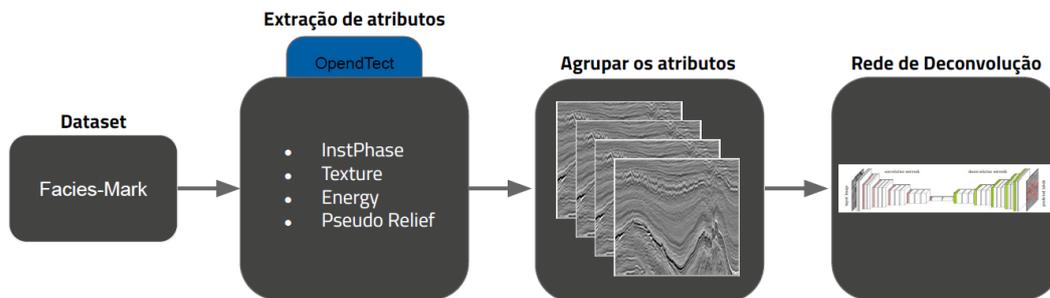


Figura 4.1: Etapas da metodologia proposta.

4.1 Dataset

Para avaliar a metodologia deste trabalho, foi empregado o *Dataset Facies-Mark* gerado a partir do *F3 Block* por Alaudah et al. (2019). Os autores criaram um modelo geológico 3D do *F3 block*, utilizando registros de poços e dados sísmicos 3D. Dentro desse modelo geológico, foram identificados sete grupos de unidades litoestratigráficas, sendo eles: *Upper North Sea*, *Middle North Sea*, *Lower North Sea*, *Chalk*, *Rijnland*, *Scruff* e *Zechstein*. A Figura 4.2 mostra o modelo geológico 3D criado. Os autores resolveram unificar os grupos *Rijnland* e *Chalk*, porque acharam difícil definir um limiar entre eles. Assim, os sete grupos se tornaram seis, onde cada grupo representa uma classe. Cada uma das seis classes representam uma facie sísmica. Os dados disponíveis já se encontram divididos em três blocos, um para treinamento e os outros dois para teste.

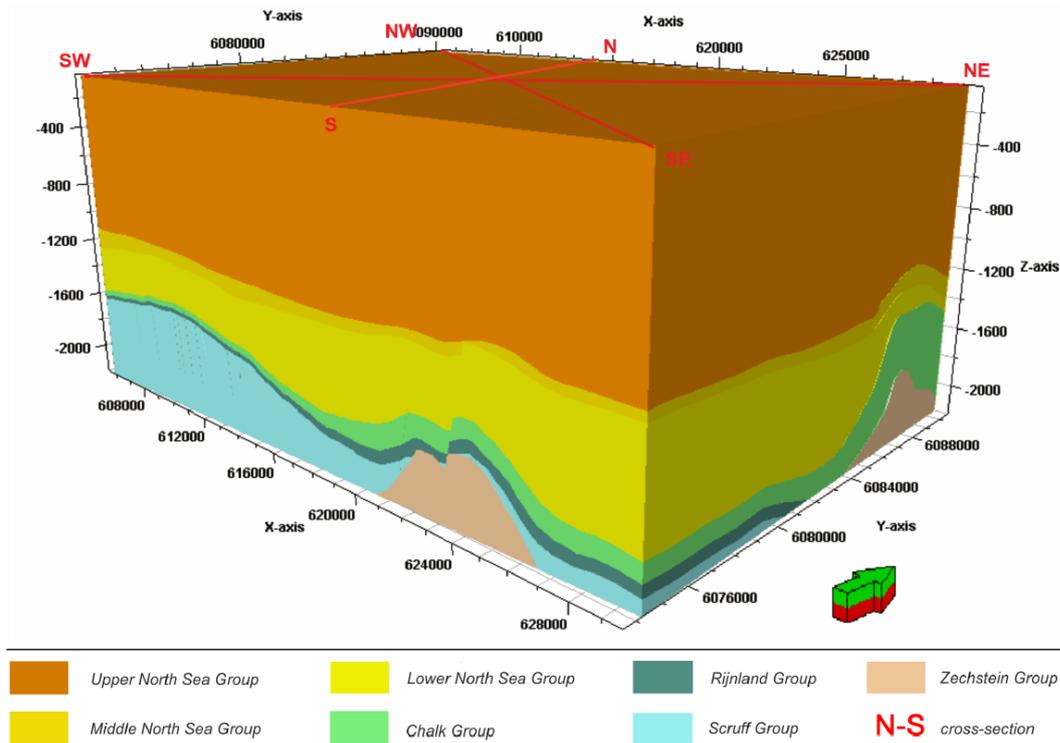


Figura 4.2: Modelo geológico 3D do bloco F3. Fonte: Alaudah et al. (2019).

A Figura 4.3 mostra uma seção *inline* e sua respectiva label, ambos os dados são amostras que fazem parte do *Dataset* utilizado. Para facilitar o entendimento, neste trabalho modificamos os nomes das classes por números, ficando da seguinte maneira: Zechstein, classe 1; Scruff, classe 2; Rijnland/Chalk, classe 3; Lower North Sea, classe 4; Middle North Sea, classe 5; e Upper North Sea, classe 6.

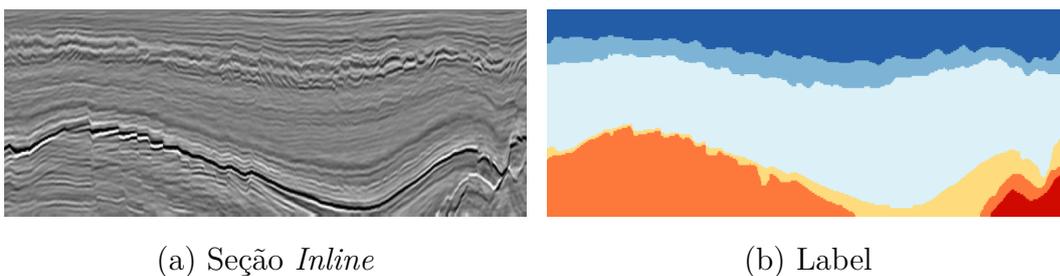


Figura 4.3: Dados contidos no *Dataset*. Fonte: Alaudah et al. (2019).

O *Dataset* é bastante desbalanceado como mostra a Figura 4.4, nela contém as classe e suas cores correspondentes exibida na Figura 4.3 (b) assim, como suas porcentagens de *pixels* no conjunto de treinamento.

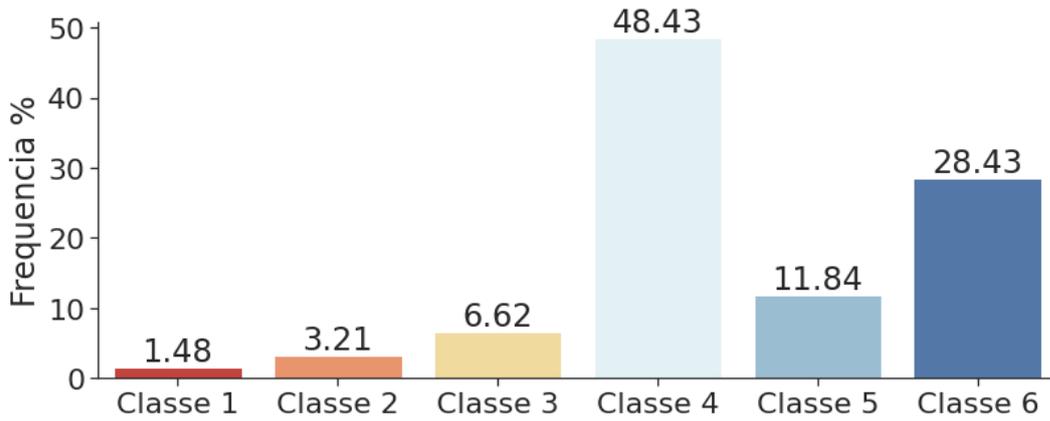


Figura 4.4: Distribuição de frequência dos dados de treinamento.

Como mencionado os dados são divididos em três blocos, as três partições desse conjunto de dados podem ser vista na Figura 4.5. O conjunto de treinamento é formado pelas *inlines* [300, 700] e *crosslines* [300, 1000], o conjunto de teste 1 contém as *inlines* [100, 299] e *crosslines* [300, 1000], já o conjunto de teste 2 das *inlines* [100, 700] e *crosslines* [1001, 1200].

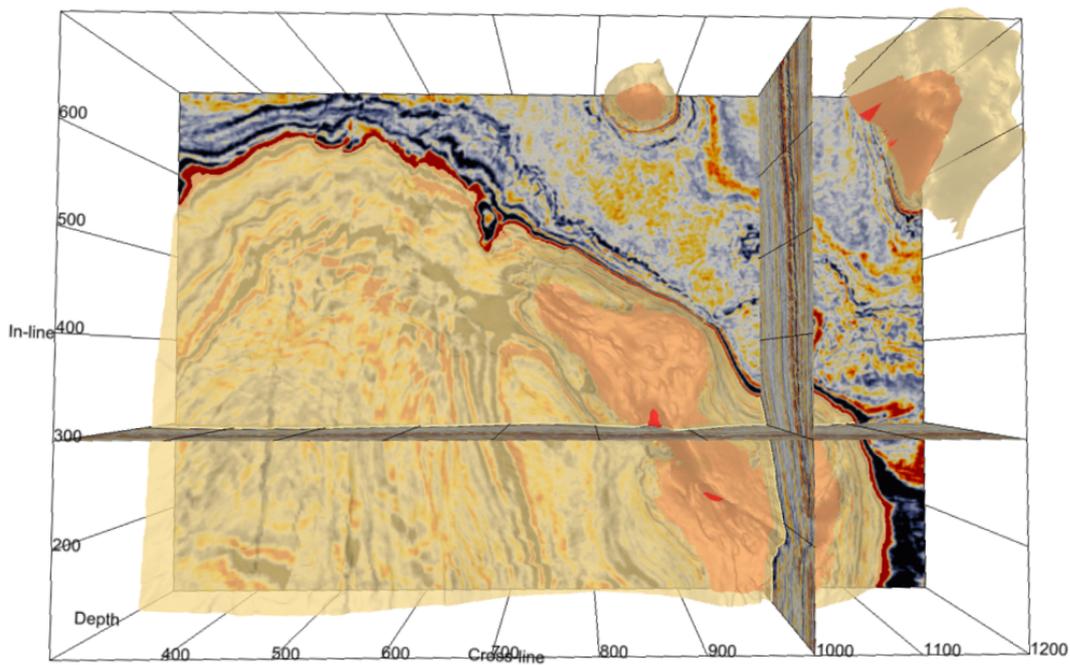


Figura 4.5: Partições do conjunto de dados. Fonte: Alaudah et al. (2019).

4.2 Extração e agregação dos atributos

A partir dos dados de amplitude, contidos no *Dataset*, foi utilizado o *software* OpendTect (DGB, 2018) versão 6.6 para extração dos atributos sísmico. Os atributos foram escolhidos por um especialista, sendo eles: Energia, Fase

Instantânea, Pseudo Relevo e Textura, por terem características relevantes e que representam as sísmicas de uma forma bem atenuada assim como o dado de amplitude. Foi gerado um volume para cada atributo, exatamente do mesmo tamanho do dado de amplitude e depois foram divididos em três blocos, um para treinamento e os outros dois blocos para teste. Assim, como o dado de amplitude contido no *Dataset* que também são divididos em três blocos.

Após a extração, os atributos foram agrupados formando uma espécie de canal cada um. Por exemplo, dado uma *inline* referente ao dado de amplitude nela continha as outras *inline* de cada atributo respectivamente acoplado. No final essa *inline* estaria com uma espécie de cinco canais, uma para amplitude, e outros quatro dos atributos, como ilustrado na Figura 4.6. Assim, foi feito para todas as *inline* e *crosslines* usadas neste trabalho. Foram feitos experimentos sem o dado de amplitude, nesse caso apenas os atributos foram agrupados, da forma mencionada anteriormente. A Figura 4.7 apresenta um exemplo em uma *inline* de como ficou o agrupamento e a entrada dela na rede.

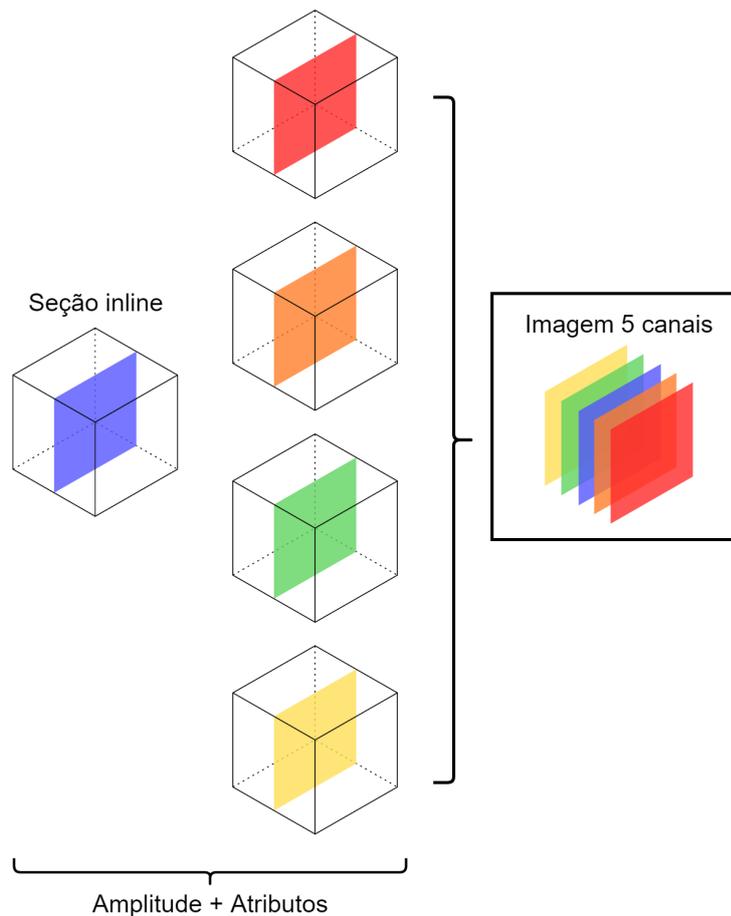


Figura 4.6: Processo de agregação dos atributos para a entrada da rede.

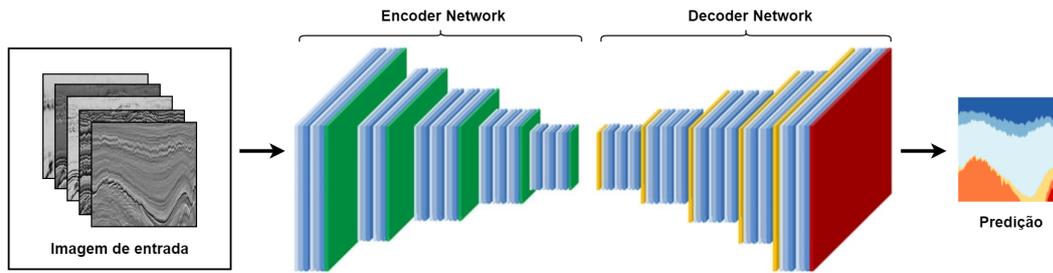


Figura 4.7: Exemplo da imagem de entrada na rede.

4.3 Arquitetura

Após os atributos selecionados e preparados foi utilizada uma rede de deconvolução de código aberto disponível por Alaudah et al. (2019) para realizar a classificação das fácies sísmicas. A arquitetura é baseada na VGG16 modificada para ter *bacthnormalization*. A rede é composta por duas partes, *encoder* e *decoder*. A parte do *encoder* corresponde a um extrator de características que transforma o dado de entrada em uma representação multidimensional de características, enquanto a parte do *decoder* representa um gerador de formas que fornece a segmentação para as classes de entrada a partir das características recuperadas do *encoder*. Por fim, a camada de saída mostra a probabilidade de cada pixel pertencer a uma das classes predeterminadas com o mesmo tamanho do dado de entrada.

A Figura 4.8 mostra a arquitetura da rede utilizada, onde as camadas brancas do lado do *encoder* são de convolução e do lado do *decoder* são de deconvolução, as camadas vermelhas são de *max-pooling* e as camadas verdes são de *unpooling*. Cada camada de convolução ou deconvolução é seguida por uma *Rectified Linear Unit* (ReLU). As camadas em vermelho executam 2×2 *max-pooling* para selecionar a resposta máxima do filtro em pequenas janelas. Os índices das respostas máximas para cada camada de *pooling* são então compartilhados com suas respectivas camadas de *unpooling* para desfazer essa operação de *pooling* e obter uma imagem de resolução mais alta (ALAUDAH et al., 2019).

Como foram adicionados mais canais nos dados sísmicos, a entrada da rede precisou ser adaptada para aceitar esses novos dados modificados, se tornando uma arquitetura multicanais.

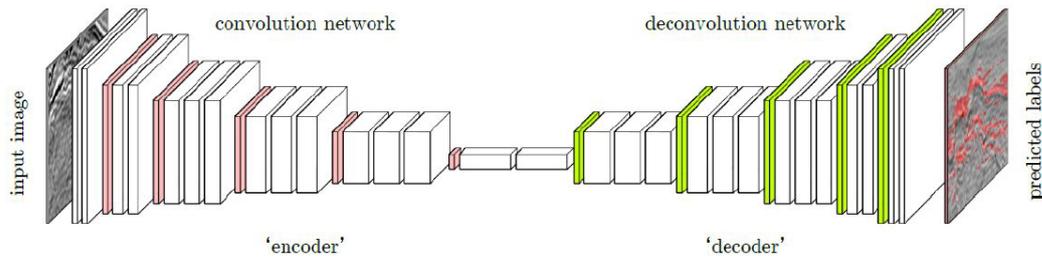


Figura 4.8: Arquitetura da rede de deconvolução. Fonte: Alaudah et al. (2019).

4.4

Função de *loss*

A função de perda utilizada foi a *Weighted Cross-entropy* (WCE) (SUDRE et al., 2017) para tentar resolver o problema do desbalanceio das classes no conjunto de dados. Classes com poucos números de amostras não contribuem significativamente para a perda total e, portanto, tendem a ser ignoradas durante o treinamento. Uma maneira de remediar esse problema é atribuir pesos adequados a cada classe. A equação é definida como:

$$WCE = -\frac{1}{N} \sum_{n=1}^N w r_n \log(p_n) + (1 - r_n) \log(1 - p_n), \quad (4-1)$$

Onde w é um vetor de peso cujo valor pode ser escolhido pelo usuário classe por classe e fixado ou ajustado automaticamente durante o treinamento. Maior valor de w aumenta a importância da classe especificada durante o treinamento. r_n representa o valor de referência, p_n o valor predito e N é o total de amostras.

4.5

Métricas de avaliação

Para avaliar o desempenho do modelo, foi utilizado um conjunto de métricas baseadas em Alaudah et al. (2019). Foram definidas quatro métricas: acurácia por pixel, acurácia por classe, média da acurácia por classe e *Frequency Weighted Intersection over Union* (FWIU). Onde G_i é o conjunto de *pixels* que pertencem à classe i e F_i o conjunto de *pixels* classificados como classe i . Assim, o conjunto de *pixels* classificados corretamente é $F_i \cap G_i$. E N_c é o número de classes.

A Acurácia por pixel (AP) (equação 4-2) é uma métrica de segmentação semântica que denota a porcentagem de pixels que são classificados com precisão na imagem. Esta métrica calcula a razão entre a quantidade de pixels adequadamente classificados e o número total de pixels na imagem.

$$AP = \frac{\sum_i |F_i \cap G_i|}{\sum_i |G_i|} \quad (4-2)$$

A Acurácia por classe para a classe i (CA_i) (equação 4-3) é a razão entre a quantidade de *pixels* que estão corretamente classificados de uma classe i e o total de pixel dessa classe i .

$$CA_i = \frac{|F_i \cap G_i|}{|G_i|} \quad (4-3)$$

A Média da acurácia por classe (MAC) (equação 4-4) é definida como somatório do resultado das classes CA_i sobre todas as classes.

$$MAC = \frac{1}{n_c} \sum_i \frac{|F_i \cap G_i|}{|G_i|} \quad (4-4)$$

A métrica *Intersection over Union* (IoU) é definida como o número de elementos da interseção de G_i e F_i sobre o número de elementos de seu conjunto união. Essa métrica mede a sobreposição entre os dois conjuntos. Além disso, quando calculamos a média da IoU em todas as classes, chegamos à Interseção Média sobre a União (Média da IoU). Para evitar que essa métrica seja excessivamente sensível as classes pequenas, é comum pesar cada classe por seu tamanho. A métrica resultante é conhecida como *Frequency Weighted Intersection over Union* (FWIU) (4-5), assim conseguimos avaliar melhor classes desbalanceadas.

$$FWIU = \frac{1}{\sum_i |G_i|} \cdot \sum_i |G_i| \cdot \frac{|F_i \cap G_i|}{|F_i \cup G_i|} \quad (4-5)$$

5

Resultados e discussão

Neste capítulo, são apresentados os cenários usados para a realização dos experimentos e discutidos os resultados obtidos nos testes efetuados propostos para a classificação de fácies sísmicas, em seguida é realizado um comparativo com um trabalho relacionado da literatura, no qual o nosso foi fortemente inspirado.

5.1

Experimentos

Foram definidos três cenários de testes, o primeiro foi testar cada um dos atributos individualmente, ou seja, a entrada da rede era com apenas um canal, assim, quatro modelos diferentes foram treinados neste cenário, sendo um modelo para cada atributo. O segundo cenário foi testar os atributos em conjunto, os quatro passaram pela etapa de agregação e a entrada da rede recebeu imagens com quatro canais, neste cenário apenas um modelo foi treinado. O terceiro cenário é parecido com o segundo, mas neste a amplitude foi incluída em conjunto com os atributos, logo, a entrada da rede foi com cinco canais, assim como no segundo cenário apenas um modelo foi treinado.

Foram utilizadas seções de *inlines* e *crosslines* no conjunto de treinamento, totalizando 1102 amostras, sendo separado 10% delas para a validação. As dimensões das seções verticais possuem tamanhos diferentes, por isso elas foram redimensionadas para 256 x 256 a fim de evitar problemas de dimensionamento com a rede. As configurações do treinamento são definidas na Tabela 5.1. Todos os experimentos foram realizados três vezes e tirado a média.

Tabela 5.1: Configurações de treinamento de rede.

Épocas	500 com Early Stopping
Taxa de aprendizagem	0.001
Otimizador	Adam
Batch size	8

Após o treinamento da rede, foram calculadas as métricas tratadas na seção 4.5. Em seguida, foi realizada uma etapa de pós-processamento, onde foi feita uma reamostragem para obter o tamanho original das imagens, da mesma forma que foi feito para o treinamento só que da forma inversa. Os resultados obtidos para cenário 1 são apresentados na Tabela 5.2.

Tabela 5.2: Resultado das métricas de avaliação para Cenário 1.

	AP	Acurácia por classe						MAC	FWIU
		Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6		
Amplitude	0.890	0.425	0.517	0.735	0.963	0.892	0.971	0.751	0.812
Energia	0.888	0.369	0.491	0.762	0.969	0.827	0.985	0.734	0.809
Fase Instan.	0.861	0.442	0.464	0.603	0.928	0.866	0.986	0.715	0.767
Pseudo Relevô	0.869	0.580	0.303	0.714	0.966	0.846	0.971	0.730	0.802
Textura	0.873	0.295	0.515	0.657	0.949	0.850	0.979	0.708	0.789

O melhor resultado entre os atributos foi com a Energia que obteve 80,91%, o segundo melhor foi com o Pseudo Relevância que teve 80,20%, enquanto a Textura e a Fase Instantânea, alcançaram 78,96% e 76,73%, respectivamente, todos baseado na métrica FWIU. Já a amplitude que o dado mais comumente utilizado para realizar classificação de fácies, obteve 81,23% baseado na mesma métrica. Analisando os resultados baseados na métrica MAC, a Energia mais uma vez se saiu melhor entre os outros atributos, alcançando 73,41% e a amplitude 75,11%. Apesar do atributo de Energia ter se saído melhor do que os outros atributos, ele não conseguiu ultrapassar o resultado da amplitude, assim os resultados obtidos revelaram que alguns atributos podem ser mais relevantes do que outros na tarefa de classificação de fácies sísmicas, mas individualmente eles não conseguem cumprir com satisfação essa tarefa. Por esse motivo vários atributos que contribuem para o mesmo propósito devem ser utilizados simultaneamente ao realizar a classificação, assim podendo obter um melhor resultado.

Os resultados para os cenários 2 e 3 são apresentados na Tabela 5.3. Lembrando que nesses cenários os atributos foram agrupados em quatro canais, assim, como a amplitude em conjunto com os atributos formando cinco canais, ambos em um único processo de classificação cada.

Tabela 5.3: Resultado das métricas de avaliação para os Cenários 2 e 3.

	AP	Acurácia por classe						MAC	FWIU
		Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6		
Amplitude	0.890	0.425	0.517	0.735	0.963	0.892	0.971	0.751	0.812
Atributos	0.911	0.563	0.631	0.710	0.977	0.903	0.973	0.793	0.851
Att + Amp	0.912	0.618	0.595	0.737	0.981	0.898	0.976	0.801	0.857

Os resultados para os cenários 2 e 3 foram superiores em relação ao cenário 1. O cenário 2 obteve 85,10% e o cenário 3 alcançou 85,70%, baseado na métrica FWIU, enquanto a amplitude ficou com 81,20% como mencionado anteriormente. Analisando a métrica MAC o resultado não foi diferente, ou seja, ambos os cenários 2 e 3 se saíram melhor do que a amplitude, alcançaram 79,30% e 80,10% respectivamente, a amplitude obteve 75,10%. Fazendo uma comparação entre os dois cenários, através dos resultados das métricas MAC e FWIU o cenário 3, obteve melhor resultado do que o cenário 2, mas mesmo ficando um pouco abaixo, o cenário 2 ainda foi melhor que a amplitude. De forma resumida, os atributos obtiveram um resultado melhor em todas as métricas comparado com o resultado da amplitude, ou seja, combinar vários atributos em um único processo de classificação se mostrou bastante eficaz.

5.2

Comparação com o trabalho de referência

Na Tabela 5.4 comparamos o nosso trabalho do cenário 3 com o de Alaudah et al. (2019), ambos fizeram uso dos mesmos dados de amplitude, tanto no treinamento quanto nos testes, no trabalho deles eles usaram a técnica de *data augmentation* no nosso usamos os atributos. A rede utilizada também foi a mesma, assim, como as métricas utilizadas para avaliação dos resultados.

Tabela 5.4: Comparação com o trabalho de referência.

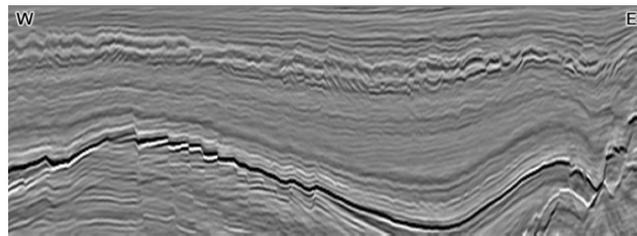
Atributos	AP	Acurácia por classe						MAC	FWIU
		Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6		
Atributos	0.911	0.563	0.631	0.710	0.977	0.903	0.973	0.793	0.851
Att + Amp	0.912	0.618	0.595	0.737	0.981	0.898	0.976	0.801	0.857
Alaudah et al. (2019) ¹	0.879	0.219	0.539	0.744	0.951	0.872	0.973	0.716	0.789
Alaudah et al. (2019) ²	0.905	0.602	0.674	0.772	0.941	0.938	0.974	0.817	0.832

1 - Modelo sem *data augmentation*

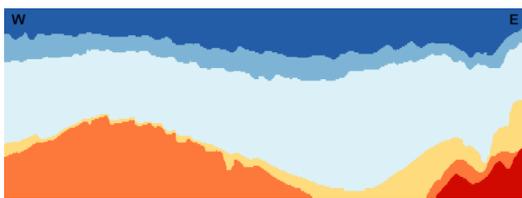
2 - Modelo com *data augmentation*

O melhor resultado que eles obtiveram foi usando *data augmentation*, conseguiram 83,20%, já sem o uso dessa técnica obtiveram 78,90% o nosso trabalho, mesmo não fazendo uso dessa técnica obteve um resultado melhor em comparação com os dois resultados do trabalho de referência, o cenário 3 alcançou 85,70% baseado na métrica de FWIU para os resultados apresentados. Analisando a métrica AP, eles obtiveram 87,90% e 90.50% já o nosso 91,20%. Assim, fazendo uma comparação direta entre o modelo com *data augmentation* e um com atributos, o multiatributos performou melhor.

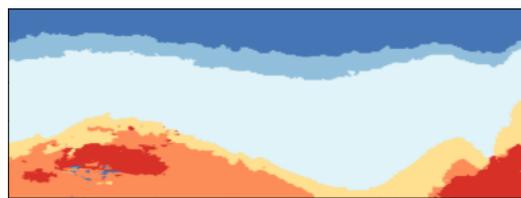
O trabalho de referência disponibilizou uma imagem dos resultados que eles obtiveram em uma *inline* no *dataset* de teste 1. A Figura 5.1 apresenta uma comparação entre essa imagem do artigo juntamente com resultado do nosso modelo para essa mesma *inline*. As imagens 5.1 (d) e (e) são modelos do trabalho citado com e sem *data augmentation* (DA).



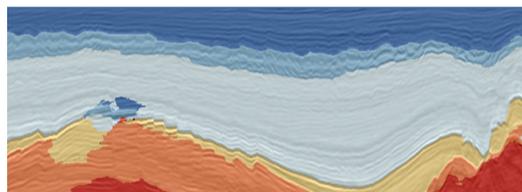
(a) Seção *Inline*



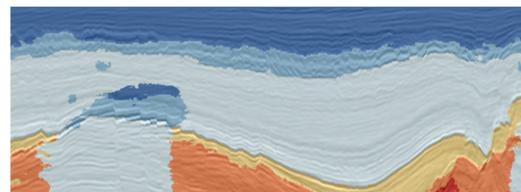
(b) *Ground Truth*



(c) Predição do nosso modelo



(d) Modelo com DA

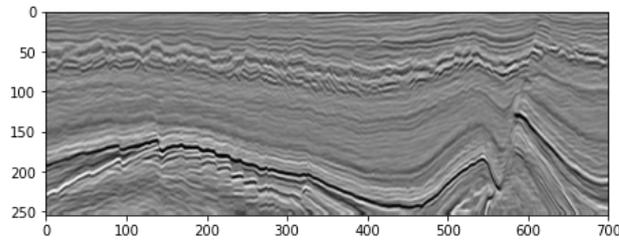


(e) Modelo sem DA

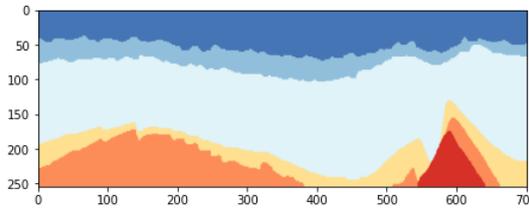
Figura 5.1: Comparação entre o trabalho de referência e o nosso modelo em uma *inline*.

5.3 Resultados Qualitativos

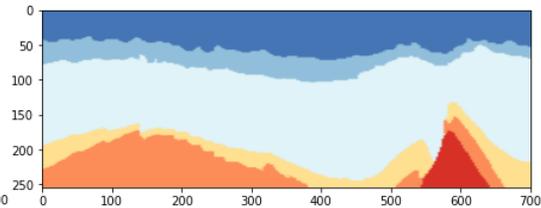
Caso de acerto é quando o modelo consegue uma ótima predição, alcançando acima de 80% em uma determinada imagem, de acordo com a métrica FWIU. A Figura 5.2 mostra um caso de acerto do modelo no *dataset* de teste. Nela temos uma *inline* que contém as seis camadas, observando a predição a rede acertou praticamente todas, contendo apenas pequenos erros, mas no geral a predição foi muito satisfatória.



(a) Seção *Inline*



(b) *Ground Truth*



(c) Predição

Figura 5.2: Caso de acerto em uma *inline* do *dataset* de teste.

Na Figura 5.3 temos um outro caso de acerto na predição do modelo, dessa vez em uma *crossline*. Nessa imagem contém quatro das seis classe que contém nos dados, e podemos observar que assim como na *inline* o modelo também conseguiu prever bem a *crossline*, mostrando ser um modelo bem robusto para ambas as seções verticais.

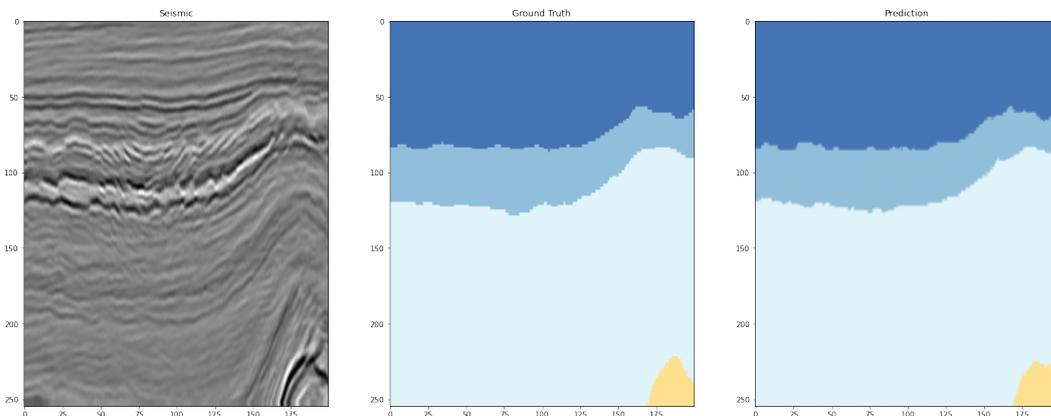
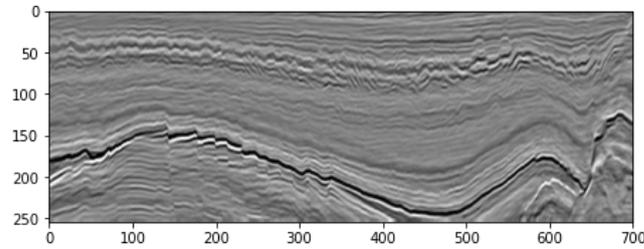
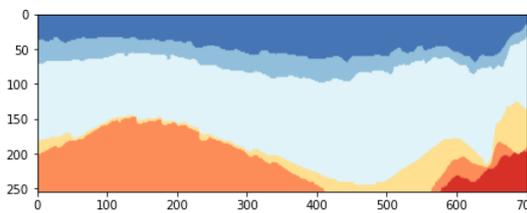


Figura 5.3: Caso de acerto em uma *crossline*. Sísmica (esquerda), *Ground Truth* (centro) e Predição (direita).

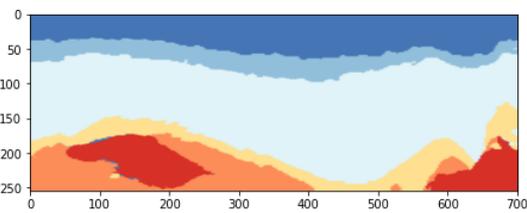
Houve também casos de erro que é quando o modelo obtém uma predição inferior a 80%, baseado na métrica FWIU. A Figura 5.4 apresenta um caso de erro do modelo em uma *inline*. Observando a predição o modelo errou três das seis classes que tinham na *inline*, os erros foram nas três classes minoritárias (Classe 1, Classe 2 e Classe 3). Como foi mencionado na seção 4.1 por se tratar de um *dataset* desbalanceado o modelo teve dificuldade de predizer as classes menores, por conterem menos informações sobre elas.



(a) Seção *Inline*



(b) *Ground Truth*



(c) Predição

Figura 5.4: Caso de erro em uma *inline* do *dataset* de teste.

Outro caso de erro pode ser visto na Figura 5.5 em uma *crossline*, os erros cometidos são sempre nas classes com menos informação sobre elas durante o treinamento, mas mesmo com os erros o modelo consegue acertar mais do que errar.

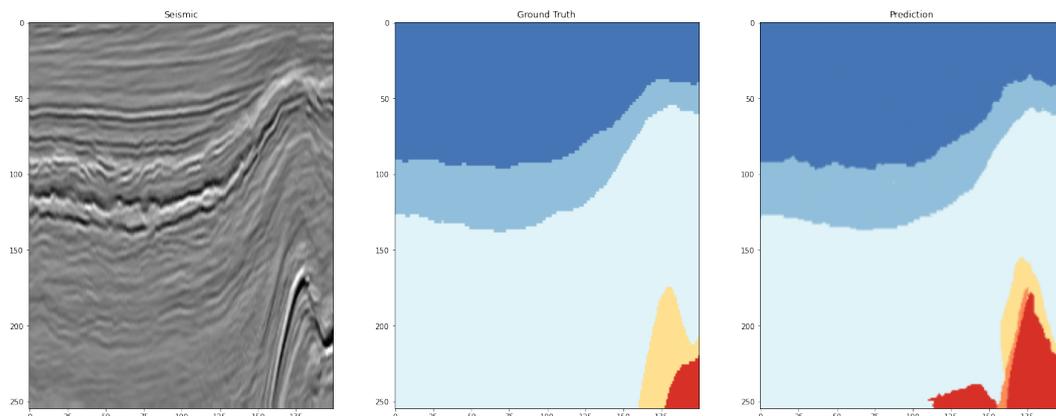


Figura 5.5: Caso de erro em uma *crossline*. Sísmica (esquerda), *Ground Truth* (centro) e Predição (direita).

6

Conclusão e trabalhos futuros

O presente trabalho apresentou uma metodologia para classificação de fácies sísmicas utilizando multiatributos sísmicos. Para validar o método, foi empregado um conjunto de dados abertos reais e comparado diretamente com o trabalho de Alaudah et al. (2019). Métricas quantitativas e predições do modelo confirmam a qualidade dos resultados.

O método consiste na utilização da combinação de um conjunto de atributos sísmicos e a amplitude para a classificação de fácies sísmicas do dado sísmico. Para isso, foi empregado uma rede *encoder-decoder* para múltiplas entradas de dados. Como as camadas sísmicas eram consideravelmente desbalanceadas, foi empregado a função de perda *Weighted Cross-entropy* para contornar esse problema.

O melhor resultado obtido foi utilizando os atributos em conjunto com a amplitude em um único processo de classificação, alcançando 85,73%, baseado na métrica FWIU. Os resultados mostraram que utilizar atributos sísmicos na tarefa de classificação de fácies sísmicas, performou melhor do que o modelo com data augmentation.

Como principal contribuição do trabalho destacamos uma nova proposta para o problema de classificação supervisionada de fácies sísmicas usando atributos sísmicos. Assim, como mais uma forma de interpretar os dados sísmicos.

Mesmo com resultados satisfatórios, acreditamos que na metodologia proposta ainda existem algumas evoluções que podem alcançar melhores resultados. Como trabalhos futuros, seria interessante, utilizar *data augmentation* que foi uma técnica usada no trabalho que comparamos. Outra evolução seria colocar na entrada um mecanismo para seleção automática de atributos ao invés de seleção manual, além de testar outras combinações deles.

7

Referências bibliográficas

AL-MOQBEL, A. M. S. **Reservoir characterization using seismic reflectivity and attributes**. Tese (Doutorado) — Massachusetts Institute of Technology, 2002.

ALAUDAH, Y. et al. A machine-learning benchmark for facies classification. **Interpretation**, Society of Exploration Geophysicists and American Association of Petroleum . . . , v. 7, n. 3, p. SE175–SE187, 2019.

ALMEIDA, V. S. **Processamento Sísmico e uso de Atributos em Dados de Reflexão da Porção Central da Bacia do Recôncavo**. Monografia (Graduação em Geologia) — Universidade Federal da Bahia, 2019.

AZIZ, I. A.; JAAFAR, J.; GILAL, A. R. The study of opendtect seismic data interpretation and visualization package in relation to seismic interpretation and visualization models. **IJCSNS Int. J. Comput. Sci. Netw. Secur**, v. 17, p. 124–134, 2017.

BARNES, A. E. Seismic attributes in your facies. **CSEG recorder**, v. 26, n. 7, p. 41–47, 2001.

BARNES, A. E. **Handbook of poststack seismic attributes**. [S.l.]: Society of Exploration Geophysicists, 2016.

BROWN, A. R. **Interpretation of three-dimensional seismic data**. [S.l.]: Society of Exploration Geophysicists and American Association of Petroleum . . . , 2011.

BULHÕES, É. M.; AMORIM, W. N. de. Princípio da sismocamada elementar e sua aplicação à técnica volume de amplitudes (tecva). In: EUROPEAN ASSOCIATION OF GEOSCIENTISTS & ENGINEERS. **9th International Congress of the Brazilian Geophysical Society**. [S.l.], 2005. p. cp–160.

CHEN, Q.; SIDNEY, S. Seismic attribute technology for reservoir forecasting and monitoring. **The Leading Edge**, Society of Exploration Geophysicists, v. 16, n. 5, p. 445–448, 1997.

CHOPRA, S.; MARFURT, K. J. Seismic attributes—a historical perspective. **Geophysics**, Society of Exploration Geophysicists, v. 70, n. 5, p. 350–2850, 2005.

CHOPRA, S.; MARFURT, K. J. **Seismic attributes for prospect identification and reservoir characterization**. [S.l.]: Society of Exploration Geophysicists and European Association of . . . , 2007.

DGB, E. S. **dGB Earth Sciences, OpendTect**. 2018. <<https://www.dgbes.com/index.php/software/free#opendtect>>. Acessado: 15-08-2022.

FERNANDES, B. J. T. **Redes neurais com extração implícita de características para reconhecimento de padrões visuais**. Tese (Doutorado) — Universidade Federal de Pernambuco, 2013.

FIGUEIREDO, A. M. **Mapeamento Automático de Horizontes e Falhas em Dados Sísmicos 3D baseado no algoritmo de Gás Neural Evolutivo**. Dissertação (Mestrado em Informática) — Pontifícia Universidade Católica do Rio de Janeiro, 2007.

FILHO, O. M.; NETO, H. V. **Processamento digital de imagens**. [S.l.]: Brasport, 1999.

FONTES, P. H. L.; BAHIA, S.

O uso de atributos sísmicos na delimitação da rocha geradora da região do baixo de miranga-bacia do recôncavo — Universidade Federal da Bahia, Salvador, BA, fev 2018.

GERHARDT, A. L. B. **Aspectos da Visualização Volumétrica de Dados Sísmicos**. Dissertação (Mestrado em Engenharia Civil) — Pontifícia Universidade Católica do Rio de Janeiro, 1998.

HALL-BEYER, M. Gcm texture: A tutorial v. 3.0 march 2017. Previously available at [http://www.ualgary.ca/UofC/nasdev/mhallbey . . .](http://www.ualgary.ca/UofC/nasdev/mhallbey...), 2017.

HART, B. S. Definition of subsurface stratigraphy, structure and rock properties from 3-d seismic data. **Earth-Science Reviews**, Elsevier, v. 47, n. 3-4, p. 189–218, 1999.

HUA, K.-L. et al. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. **OncoTargets and therapy**, Dove Press, v. 8, 2015.

JANNUZZI, J. **Aplicação e Análise de Atributos para a Interpretação Sísmica 3D no Pré-Sal do Novo Campo de Jubarte, Parque das Baleias, Bacia de Campos**. Monografia (Graduação em Geofísica) — Universidade Federal Fluminense, 2020.

JR., J. M. P. **Geração de Malhas 3D para Dados Sísmicos**. Dissertação (Mestrado em Engenharia de Sistemas e Computação) — Universidade Federal do Rio de Janeiro, 2009.

LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, IEEE, v. 86, n. 11, p. 2278–2324, 1998.

LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional networks and applications in vision. In: IEEE. **Circuits and Systems (ISCAS), Proceedings of 2010 IEEE International Symposium on**. [S.l.], 2010. p. 253–256.

LI, F. et al. Addcnn: An attention-based deep dilated convolutional neural network for seismic facies analysis with interpretable spatial–spectral maps. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 59, n. 2, p. 1733–1744, 2020.

LIU, M. et al. Seismic facies classification using supervised convolutional neural networks and semisupervised generative adversarial networks. **Geophysics**, Society of Exploration Geophysicists, v. 85, n. 4, p. O47–O58, 2020.

MAGGIORI, E. et al. High-resolution semantic labeling with convolutional neural networks. 11 2016.

RANDEN, T. et al. Three-dimensional texture attributes for seismic data analysis. In: **SEG Technical Program Expanded Abstracts 2000**. [S.l.]: Society of Exploration Geophysicists, 2000. p. 668–671.

ROBINSON, E. A.; TREITEL, S. **Geophysical signal analysis**. [S.l.]: Society of Exploration Geophysicists, 2000.

SILVA, G. L. F. d. et al. **Diagnóstico de nódulos pulmonares em imagens de tomografia computadorizada usando redes neurais convolucionais evolutivas**. Dissertação (Mestrado) — Universidade Federal do Maranhão, 2017.

SUDRE, C. H. et al. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In: **Deep learning in medical image analysis and multimodal learning for clinical decision support**. [S.l.]: Springer, 2017. p. 240–248.

TANER, M. T. Seismic attributes. **CSEG recorder**, v. 26, n. 7, p. 48–56, 2001.

THOMAS, J. E. et al. Fundamentos de engenharia de petróleo, ed. **Interciência, Rio de Janeiro, Petrobrás**, 2001.

TOLSTAYA, E.; EGOROV, A. Automatic neural network-based seismic facies classification using pseudo-labels. In: ONEPETRO. **International Petroleum Technology Conference**. [S.l.], 2022.

TRINIDAD, M. J. C. et al. Seismic facies segmentation using atrous convolutional-lstm network. 2021.

ZHANG, H. et al. Automatic seismic facies interpretation using supervised deep learning facies interpretation by deep learning. **Geophysics**, GeoScienceWorld, v. 86, n. 1, p. IM15–IM33, 2021.

ZHAO, T. Seismic facies classification using different deep convolutional neural networks. In: ONEPETRO. **2018 SEG International Exposition and Annual Meeting**. [S.l.], 2018.

ZINI, J. E.; RIZK, Y.; AWAD, M. A deep transfer learning framework for seismic data analysis: A case study on bright spot detection. **IEEE Transactions on Geoscience and Remote Sensing**, v. 58, n. 5, p. 3202–3212, 2020.