



Mayara Gomes Silva

**Identificação de horizontes em sísmica usando
rede neural convolucional**

Dissertação de Mestrado

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

Orientador: Prof. Marcelo Gattass

Rio de Janeiro
Setembro de 2022



Mayara Gomes Silva

Identificação de horizontes em sísmica usando rede neural convolucional

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, 2 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.

Mayara Gomes Silva

Graduado em ciência da computação pela Universidade Federal do Maranhão.

Ficha Catalográfica

Gomes Silva, Mayara

Identificação de horizontes em sísmica usando rede neural convolucional / Mayara Gomes Silva; orientador: Marcelo Gattass. – 2022.

51 f: il. color. ; 30 cm

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

Inclui bibliografia

1. Informática – Teses. 2. Bloco F3. 3. Segmentação de horizontes. 4. Rede neural convolucional. I. Gattass, Marcelo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Informática. III. Título.

CDD: 004

Aos meus pais e família
pelo apoio.

Agradecimentos

Aos meus pais, pela educação, e liberdade para escolher meus próprios caminhos.

Ao meu orientador Professor Marcelo Gattass pelo estímulo e parceria para a realização deste trabalho.

Ao Felipe pela co-orientação, suporte e conselhos durante o desenvolvimento deste trabalho.

Aos meus colegas do mestrado e do Tecgraf que me apoiaram dando feedbacks para esse trabalho e pelo companheirismo, em especial meus companheiros Anderson, Eduardo e Nelia.

A Kelson pelo suporte, apoio e companheirismo em todos os momentos.

A todos os amigos e familiares que de uma forma ou de outra me estimularam ou me ajudaram, em especial a Anny.

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

Resumo

Gomes Silva, Mayara; Gattass, Marcelo. **Identificação de horizontes em sísmica usando rede neural convolucional**. Rio de Janeiro, 2022. 51p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

O petróleo e gás são importantes na economia mundial, utilizados como matéria-prima em vários produtos. Para a extração desses produtos é necessário realizar a caracterização dos reservatórios de hidrocarbonetos. A partir dessa caracterização são extraídos um volume com dados sísmicos da região de interesse. Esses dados são interpretados para identificação de várias características, como a classificação de fácies sísmicas, horizontes, falhas, e gás. A grande quantidade de dados do volume de sísmica, torna a interpretação manual cada vez mais desafiadora. Muitos pesquisadores da área de interpretação sísmica tem investido em métodos utilizando redes neurais. As redes neurais convolucionais (CNN) são muito utilizadas em problemas de visão computacional, e obtém ótimos resultados em muitos problemas com dados 2D. O presente trabalho tem como objetivo a aplicação de redes neurais convolucionais no mapeamento supervisionado de horizontes sísmicos. Avaliamos nossa proposta usando o bloco F3 com as anotações de fácies sísmicas. Os dados foram utilizados baseados em modelo de seção e patches. Na previsão de horizonte foram avaliadas as arquiteturas da ResUnet e DC-Unet. Como função de perda foram analisadas a Generalized Dice e a perda Focal Tversky. O método mostrou resultados promissores com a ResUnet e função de perda Focal Tversky, nos dados baseados em patches de 128x128, alcançando aproximadamente 56% na métrica Dice. A implementação completa e as redes treinadas estão disponíveis em https://github.com/mayaragomys/seismic_horizons.

Palavras-chave

Bloco F3; Segmentação de horizontes; Rede neural convolucional.

Abstract

Gomes Silva, Mayara; Gattass, Marcelo (Advisor). **Convolutional neural network for seismic horizons identification**. Rio de Janeiro, 2022. 51p. Dissertação de Mestrado – Departamento de Informática, Pontifícia Universidade Católica do Rio de Janeiro.

Oil and gas are important in the world economy, used as raw materials in various products. For the extraction of these products, it is necessary to carry out the characterization of the hydrocarbon reservoirs. This characterization extracts a volume with seismic data from the region of interest. These data are interpreted to identify various features, such as the classification of seismic facies, horizons, faults, and gas. A large amount of seismic volume data makes manual interpretation increasingly challenging. Many researchers in the field of seismic interpretation have invested in methods using neural networks. Convolutional Neural Networks (CNN) are widely used in computer vision problems and get great results in many situations with 2D data. The present work aimed to apply convolutional neural networks in the supervised mapping of seismic horizons. We evaluated our proposal using the F3 block with seismic facies annotations. The data representation in the input layer are patches of sections. In the horizon forecast, we evaluate the architectures of ResUnet and DC-Unet. We use the Generalized Dice and the Focal Tversky loss functions for the loss function. The method delivered promising results with the ResUnet and Focal Tversky loss function on data based on 128x128 patches, reaching approximately 56% on the Dice metric. The full implementation and the trained networks are available at https://github.com/mayaragomys/seismic_horizons.

Keywords

Block F3; Segmentation of horizons; convolutional neural network.

Sumário

1	Introdução	14
1.1	Objetivo Geral	15
1.2	Objetivos Específicos	15
1.3	Organização da Dissertação	15
2	Trabalhos relacionados	16
2.1	Redes neurais na identificação de estruturas em sísmicas	16
2.2	Redes neurais na detecção de horizontes sísmicos	18
3	Fundamentação	20
3.1	Dados Sísmicos	20
3.2	Rede neural convolucional	23
3.3	Métricas de Validação	29
4	Método	31
4.1	Etapas da Solução	32
5	Resultados	39
5.1	Dados 3D do bloco F3	39
5.2	Treinamento e Teste	40
5.3	Discussão	42
6	Conclusão e trabalhos futuros	47
6.1	Trabalhos Futuros	47
7	Referências bibliográficas	49

Lista de figuras

Figura 2.1	Seções sísmicas mostrando os resultados da classificação dos diferentes modelos.	16
Figura 2.2	Resultados da análise de fácies sísmica de uma seção sísmica usando rede neural.	17
Figura 2.3	Predição de um inline presente no dataset Facies-Mark feitas pela DNFS.	18
Figura 2.4	Predição de uma seção da segmentação de horizontes.	19
Figura 3.1	Aquisição sísmica marítima.	21
Figura 3.2	Traço sísmico (esquerda), linha sísmica (centro) e volume sísmico (direita).	22
Figura 3.3	Blocos de construção de redes neurais. (a) Unidade neural simples usada no U-Net e (b) unidade residual com mapeamento de identidade usado no ResUnet proposto.	24
Figura 3.4	Arquitetura da ResUnet	25
Figura 3.5	Arquitetura da MultiResUNet	26
Figura 3.6	Bloco Dual-Channel	27
Figura 3.7	Arquitetura da DC-Unet	27
Figura 4.1	Fluxograma das etapas do método do modelo baseado em seção	32
Figura 4.2	Fluxograma das etapas do método do modelo baseado em patches	33
Figura 4.3	Exemplo do funcionamento da definição dos horizontes.	34
Figura 4.4	Exemplo de uma seção com a adaptação das anotações.	35
Figura 4.5	Exemplo da aplicação de espelhamento horizontal em uma seção sísmica.	36
Figura 4.6	Exemplo da extração de patches em uma seção. (a) Seção sísmica. (b) Patches de dimensão 256x256 gerados de uma Seção sísmica. (c) Patches de dimensão 128x128 gerados de uma Seção sísmica. (d) Patches de dimensão 64x64 gerados de uma Seção sísmica.	37
Figura 5.1	Modelo 3D geológico do bloco F3	39
Figura 5.2	Divisão das bases visualizadas no modelo geológico do bloco F3	40
Figura 5.3	Exemplo de resultados de inlines e crosslines com modelos baseados em seção. (a) Imagem de amplitude com a marcação. (b) DC-Unet com Focal Tversky. (c) DC-Unet com Generalized Dice. (d) ResUnet com Focal Tversky. (e) ResUnet com Generalized Dice.	43
Figura 5.4	Resultado de uma seção de Inline em patches usando a ResUnet: 80,19% de Dice; 66,94% de Jaccard	45
Figura 5.5	Resultado de uma seção de Inline em patches usando a ResUnet: 58,20% de Dice; 41,04% de Jaccard	45

Figura 5.6 Exemplo de resultados de uma inline e uma crossline com modelos baseados em patches usando a ResUnet. (a) Imagem de amplitude. (b) Imagem de amplitude com a marcação. (c) Rótulos. (d) ResUnet com Focal Tversky. (e) ResUnet com Generalized Dice. (f) DC-Unet com Focal Tversky. (g) DC-Unet com Generalized Dice.

46

Lista de tabelas

Tabela 5.1	Divisão das bases	40
Tabela 5.2	Quantidade de imagens geradas pelo pré-processamento	41
Tabela 5.3	Resultados dos modelos baseados em seção.	41
Tabela 5.4	Resultados dos modelos baseados em patches variando as dimensões.	42
Tabela 5.5	Resultados dos modelos baseados em patches de 128x128	42

Lista de Abreviaturas

CNN – Rede Neural Convolucional

BN – *Batch Normalization*

GDL – *Generalized Dice Loss*

FT – *Focal Tversky*

FTL – *Focal Tversky Loss*

TL – *Tversky Loss*

LSTM – *Long Short-Term Memory*

DNFS – *Deep Neural Network For Facies Segmentation*

*O insucesso é apenas uma oportunidade para
recomeçar com mais inteligência.*

Henry Ford, *My Life and Work*.

1

Introdução

O setor de petróleo e gás é um dos mais importantes na economia mundial, sendo matéria-prima de grande relevância em vários produtos, como na produção de plásticos, tintas, detergentes, como fonte de energia, entre outras aplicações.

A descoberta de um reservatório de hidrocarbonetos (óleo e gás) em uma nova área é uma tarefa que envolve um largo e dispendioso estudo e análise de dados geofísicos e geológicos das bacias (SILVA et al., 2014). Para a exploração desses reservatório o método que vem sendo largamente utilizado para caracterizar um reservatório é a exploração indireta da subsuperfície da terra, devido a sua eficiência (SILVA et al., 2014; AMARAL et al., 2021).

A etapa de caracterização de um reservatório é essencial no delineamento, desenvolvimento e produção de reservas de hidrocarbonetos. O resultado da aquisição desses dados é um volume sísmico tridimensional da região de interesse (FIGUEIREDO, 2015).

Os dados extraídos descrevem características da região de interesse, revelando informações importantes, como estruturais e estratigráficas. A interpretação desses dados é feita por um especialista, que identifica as características da região geológica, como a classificação de fácies sísmicas, a detecção de horizontes (fronteiras entre fácies sísmicas), a identificação de áreas com sal ou gás, falhas sísmicas. Porém, esta avaliação demanda muito tempo devido a grande quantidade de dados do volume.

Nos últimos anos, as redes neurais tem obtido resultados promissores em uma ampla variedade de aplicações, revolucionando os campos de aprendizado de máquina e visão computacional. Vários pesquisadores como Zhao (2018), e Guo et al. (2020), tem investido em métodos utilizando redes neurais para interpretar esses dados.

A rede neural convolucional (CNN) em relação a outros métodos de classificação supervisionados tem duas características importantes para problemas de classificação em imagens, que é uma consciência espacial (utiliza os valores de intensidade de cada pixel individualmente) e extração automática de características (analisa os padrões entre os pixels em uma imagem gerando recursos, como os atributos em dados sísmicos) (ZHAO, 2018).

A fim de auxiliar o especialista nesse processo de interpretação, este trabalho foca na estrutura de horizonte, que é a fronteira entre as fácies sísmica. Como objetivo, este trabalho propõe a detecção binária de horizontes em dados

sísmicos usando redes neurais convolucionais em segmentação supervisionada.

1.1

Objetivo Geral

O objetivo dessa dissertação é detecção de horizontes sísmicos em dados sísmicos. Para alcançar esse objetivo modelos de deep learning serão avaliados e comparados.

1.2

Objetivos Específicos

Essa dissertação tem por objetivos específicos os seguintes:

- Identificação dos horizontes.
- Estudo de redes neurais convolucionais para segmentação de dados binários;
- Estudo de funções de perda para problemas de segmentação com classes desbalanceadas;

1.3

Organização da Dissertação

Esta dissertação está organizada em cinco capítulos, no primeiro está a introdução. O Capítulo 2 apresenta alguns trabalhos relacionados ao uso de redes neurais em dados sísmicos. O Capítulo 3 apresenta a fundamentação teórica sobre o dado sísmico e redes neurais convolucionais usadas como base para o desenvolvimento deste trabalho. O Capítulo 4 detalha o método proposto. O Capítulo 5 detalha o conjuntos de parâmetros e os testes feitos para testar as hipóteses, destaca e discute os resultados obtidos e as conclusões. Por fim, o Capítulo 6 faz as considerações finais deste trabalho e apresenta propostas para trabalhos futuros.

2

Trabalhos relacionados

Este capítulo apresenta uma revisão da literatura sobre interpretação de sísmica utilizando redes neurais. Em geral, os métodos são de agrupamento não supervisionado e classificação supervisionada. Os métodos supervisionados tem o conhecimento de onde pertence cada estrutura, assim durante a classificação a precisão é melhorada. Os trabalhos apresentados nesse capítulo se restringem apenas as abordagens supervisionadas.

2.1

Redes neurais na identificação de estruturas em sísmicas

Esses métodos buscam uma segmentação de estruturas em dados sísmicos, como identificação de fácies sísmicas, sal e falhas. Algumas metodologias são citadas abaixo.

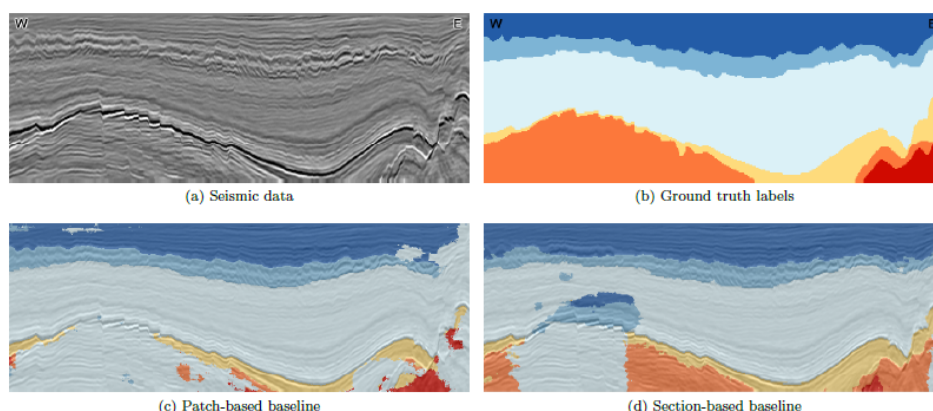


Figura 2.1: Seções sísmicas mostrando os resultados da classificação dos diferentes modelos. Resultado reportado em (ALAUDAH et al., 2019)

Alaudah et al. (2019) propuseram um método que se concentrava na classificação das fácies em dados sísmicos 3D, além disso fizeram a modelagem dos dados sísmicos 3D. Utilizando a base de dados do Bloco F3 da Holanda, mapearam os dados em seis classes de fácies sísmica, sendo classes desbalanceadas. A partir dos dados mapeados utilizaram uma rede neural com arquitetura de rede de deconvolução para classificação das classes, e utilizaram modelos baseados em seção e patch. Os autores reportaram resultados indicando a eficiência do método em fatias 2D (Figura 2.1). O artigo não cita que o método utiliza funções de perda para tratar as classes desbalanceadas, no entanto, faz o uso de técnicas de data augmentation nos dados para superar esse desequilíbrio de classes, o que melhorou os resultados para as classes menores, porém não foi

suficiente como observa-se nos resultados das métricas apresentadas, onde as classes com menos exemplos apresentam valores consideravelmente inferiores as classes com mais exemplos.

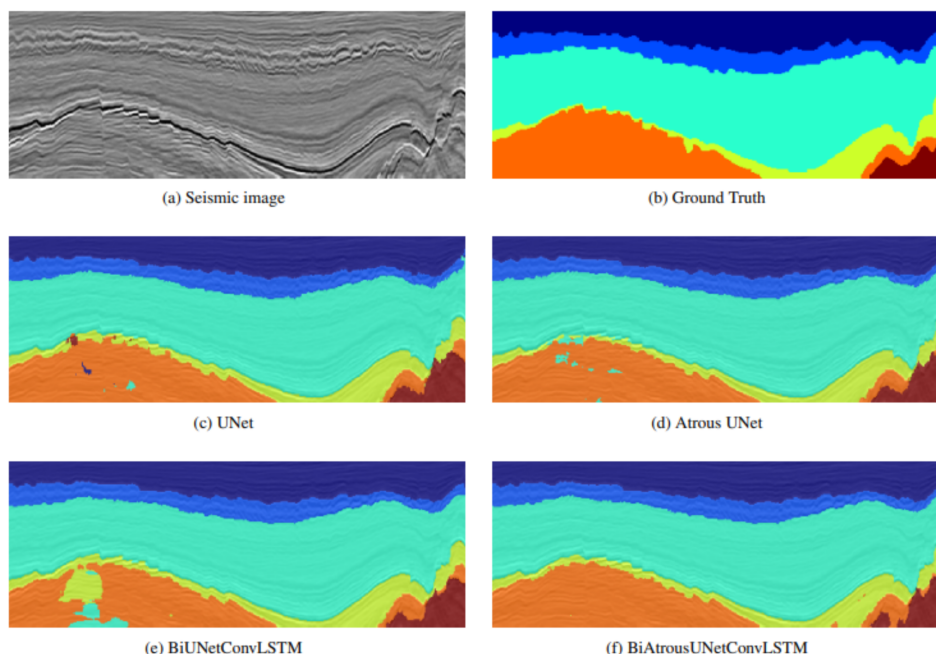


Figura 2.2: Resultados da análise de fácies sísmica de uma seção sísmica usando rede neural. Resultado reportado em (TRINIDAD et al., 2021)

Os autores Trinidad et al. (2021) aplicaram rede neural na classificação de fácies sísmicas utilizando a mesma base do trabalho de Alaudah et al. (2019). Considerando que o dado sísmico contém informações temporais ao longo do eixo (inline e crossline), os autores propuseram utilizar essas informações em uma rede neural recorrente, a LSTM (*Long short-term memory*), junto com outras arquiteturas, a Unet e Atrous UNet. Os resultados mostraram o método promissor, com melhores resultados comparado ao trabalho de Alaudah et al. (2019). A Figura 2.2 mostra os resultados obtidos.

Outros trabalhos que apresentam métodos para extrair sismofácies são os de Zhao (2018) e Li et al. (2020), utilizando respectivamente um modelo de CNN baseado em codificador-decodificador, e modelo baseado em mapas de atenção. A base utilizada foi o bloco F3 adquirida no Mar do Norte. Desta base foram extraídas oito sismofácies com padrões de amplitude distintos, e uma nona para representar as amostras que não pertencem às oito fácies alvo. Os métodos mostraram resultados promissores.

Na identificação de corpos de sal em sísmicas os autores Islam (2020) proporam um método baseado em U-Net plus e ResNet. Já Alfarhan, Deriche e Maalej (2020) usaram modelos baseados na VGG19 e na ResNet para identificar falhas sísmica e corpos de sal.

2.2

Redes neurais na detecção de horizontes sísmicos

Esses métodos buscam uma segmentação binária, identificando as sismo-fácies e as linhas separatórias dessas sismo-fácies. Algumas metodologias são citadas abaixo.




Figura 2.3: Predição de um inline presente no dataset Facies-Mark feitas pela DNFS. Resultado reportado em (LIMA, 2021)

Lima (2021) apresenta um método com a aplicação de redes neurais profundas que identifica as linhas separatórias de sismo-fácies. Baseando-se nas redes U-Net e StNet, obteve-se a rede neural chamada DNFS (*Deep Neural Network For Facies Segmentation*). Esta rede é voltada a segmentação binária de dados sísmicos, permitindo segmentar a transição entre as fácies sísmicas. A arquitetura da rede é do tipo codificador-decodificador, utilizando a combinação de duas funções de perda a *cross-entropy* e *Jaccard*. Utilizando o conjunto de dados StData-12 e Facies-Mark, os resultados reportados apresentam um índice acima de 95% relativo à métrica IoU. Na Figura 2.3 observa-se um resultado dessa metodologia. O texto apresenta resultados indicando a eficiência do método de acordo com a métrica utilizada, porém não informa se houve um pré-processamento após a segmentação para tratar a descontinuidade das linhas separatórias das sismo-fácies.

Calhes et al. (2021) avaliou duas redes, a PSP-Net e Deeplab V3+, juntamente com a função focal loss. Diferente do trabalho anterior, neste foi realizado a segmentação por instância, cada horizonte foi identificado como uma classe. Primeiramente as fácies sísmicas foram segmentadas, em seguida os




Figura 2.4: Predição de uma seção da segmentação de horizontes. (CALHES et al., 2021)

horizontes foram extraídos individualmente. Os dados usados foram o conjunto do bloco F3. O método foi dividido em 4 etapas: (1) imagem multiclasse e imagens monoclasse, (2) treinamento e teste, (3) detecção dos contornos, e (4) otimização dos contornos. Os resultados obtiveram métricas promissoras, diferente do método binário não tem o problema de descontinuidade do horizonte. Na Figura 2.4 observa-se um resultado dessa metodologia.

3

Fundamentação

Neste capítulo serão discutidas as referências usadas como base para o desenvolvimento deste trabalho. Primeiramente, são comentadas as referências sobre os dados sísmicos, com o objetivo de entender o contexto que esse trabalho se insere. Em seguida, as referências relacionadas ao método, que será abordado conceitos de redes neurais convolucionais e funções de perda. Por último será abordado as métricas utilizadas para validar os modelos.

3.1

Dados Sísmicos

Neste trabalho vamos abordar a sísmica por reflexão empilhada. Este é um método indireto de exploração, o mais utilizado atualmente, devido a sua eficiência, fornecendo alta definição das características geológicas em subsuperfícies propícias à acumulação de hidrocarbonetos (AMARAL et al., 2021).

Segundo Robinson e Treitel (1980), a exploração de hidrocarbonetos (óleo e gás) baseada em sísmica pode ser dividida em três etapas: aquisição, processamento e interpretação. Nas subseções seguintes faremos uma breve descrição de cada etapa.

3.1.1

Aquisição

O primeiro passo para encontrar reservas de hidrocarbonetos é a aquisição ou levantamento de dados sísmicos. A aquisição é feita por uma fonte que gera ondas (impulsos) sísmicas em pontos específicos na superfície da área a ser mapeada que se propagam abaixo da superfície da terra (SILVA et al., 2014).

O levantamento sísmico se inicia com a geração de uma onda sonora. Nos levantamentos terrestres essa geração pode se dar por explosivos ou caminhões de impacto. No mar usamos canhões de ar.

Quando a onda atinge a interface entre duas rochas de características físicas diferentes, parte da onda é refratada e continua viajando para baixo e uma parte é refletida e retorna a superfície. Esta onda de retorno é captada por sensores, em aquisições terrestres são por geofones e hidrofones para as que são adquiridas no mar. (FIGUEIREDO, 2007).

As informações captadas pelos sensores são gravadas em sismógrafos, que armazena o tempo de chegada da onda e a intensidade medida neste momento

(SILVA, 2004; FIGUEIREDO, 2007). Após o armazenamento, os dados são enviados para a etapa seguinte, que é o processamento. Na Figura 3.1 pode-se observar os processos de aquisição marítima.




Figura 3.1: Aquisição sísmica marítima. Fonte:(JAPÃO, 2018)

3.1.2 Processamento

A etapa de processamento transforma o dado coletado em traços, que registram como uma onda sonora seria registrada se a explosão e o receptores estivessem na mesma posição da superfície e a onda se propagasse apenas na vertical. Este passo é chamado de empilhamento. Nesta etapa também se corrige erros de aquisição etapa de aquisição. Depois desta etapa, os dados sísmicos são grades bi ou tridimensional com uma amostra de amplitude sísmica em cada vértice da grade (voxel) (SILVA, 2004).

Inicialmente o dado tridimensional possui duas dimensões espaciais e uma dimensão temporal. As espaciais estão relacionadas as posições das fontes e receptores do empilhamento. A dimensão de tempo é uma amostragem do sinal de amplitude, geralmente feita com intervalo de 4 milissegundos ou 250 Hz. Esta frequência é conhecida como a frequência de amostragem. A dimensão em tempo pode ser convertida em profundidade com o conhecimento da velocidade da onda nas rochas. Este processo é conhecido como conversão tempo-profundidade(FIGUEIREDO, 2007).

A Figura 3.2 ilustra como as amostras são organizadas em dados sísmicos. A figura do lado esquerdo mostra um traço sísmico que é representado por um sinal de onda, onde a dimensão é 1D. Esta informação pode ser codificada numa escala de cores se transformando numa coluna de pixels coloridos. No centro temos uma seção, que é formada por um conjunto de traços sísmicos formando uma seção de dimensão 2D, sendo chamada de linha sísmica. Do lado direito apresentamos o volume sísmico, que é formado por várias linhas sísmicas. Nos dados do volume sísmico temos duas direções espaciais, que são chamadas de inline (direção de aquisição das linhas sísmicas) e crossline (direção perpendicular a direção de aquisição), além de uma direção temporal (FIGUEIREDO, 2015).

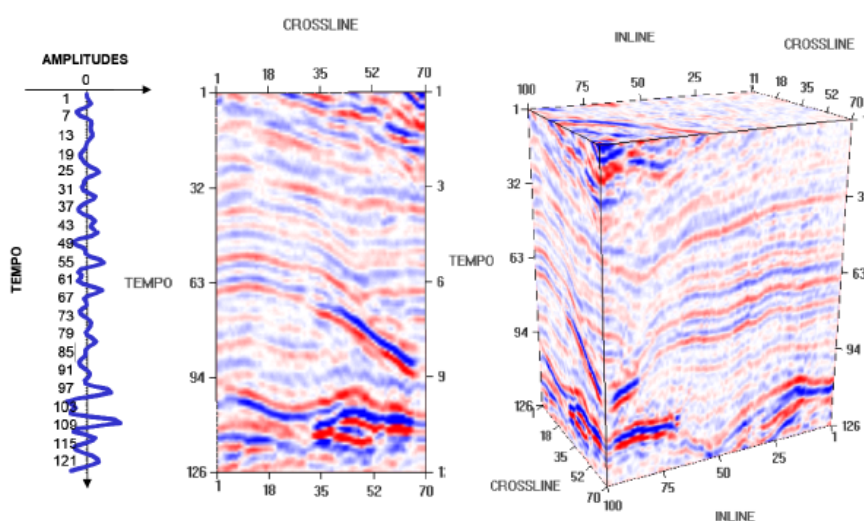


Figura 3.2: Traço sísmico (esquerda), linha sísmica (centro) e volume sísmico (direita). Fonte: reportado em (FIGUEIREDO, 2015)

3.1.3 Interpretação

Na etapa de interpretação, o especialista, em geral um geólogo ou geofísico, analisa os dados sísmicos e tenta interpretar as estruturas que represente a geologia contida na área do levantamento.

Segundo Silva et al. (2014) de acordo com o foco da interpretação sísmica, ela pode ser dividida em estratigráfica e estrutural. A interpretação estratigráfica visa entender a maneira como as camadas foram se formando ao longo do tempo. Na estrutural foca em identificar as camadas geológicas, como, as interfaces entre as camadas (horizonte sísmico), as falhas geológicas que recortam as camadas.

O mapeamento dos horizontes é uma das tarefas mais importantes da interpretação sísmica. Segundo O’Neal (1991), um horizonte sísmico é a superfície que separa duas camadas diferentes de rocha, onde tal superfície está associada com uma reflexão que se estende por uma grande área. Este trabalho foca na identificação de horizontes.

3.2

Rede neural convolucional

Nos últimos anos o aprendizado profundo com redes neurais convolucionais em problemas de visão computacional tem evoluído bastante, alcançando resultados promissores em muitos problemas da área. Segundo Ferreira (2017) algoritmos tradicionais de classificação utilizados para classificação em imagens, necessitam da etapa de extração de características, porém em algoritmos de aprendizado profundo não é necessário essa etapa, pois as características são aprendidas automaticamente a partir do dado bruto, assim espera-se que essa técnica tenha muito mais sucesso por precisar de menos engenharia manual.

Nas subseções faremos uma breve descrição de cada uma das arquiteturas utilizada neste trabalho. Para uma visão mais aprofundada sugerimos consultar os trabalhos de Zhang, Liu e Wang (2018) e Lou, Guan e Loew (2021)

3.2.1

ResUnet

A arquitetura da ResUnet é baseada na U-net e em aprendizado residual (ZHANG; LIU; WANG, 2018). A U-Net combina informações detalhadas de baixo nível e informações semânticas de alto nível (RONNEBERGER; FISCHER; BROX, 2015), e a estrutura de aprendizado residual profunda utiliza um mapeamento de identidade para facilitar o treinamento (HE et al., 2016).

A U-Net residual profunda (ResUnet) é construída com base na arquitetura da U-Net, utilizando unidades residuais em vez de unidades neurais simples como blocos básicos (ZHANG; LIU; WANG, 2018). A Figura 3.3 mostra a diferença entre o unidades neurais simples e as unidades residuais. A rede neural residual consiste em uma série de unidades residuais empilhadas. As unidades residuais consistem em dois blocos de convolução 3×3 e um mapeamento de identidade. Cada bloco de convolução inclui uma camada BN (*Batch Normalization*), uma camada de ativação ReLU e uma camada convolucional. O mapeamento de identidade conecta a entrada e a saída da unidade.

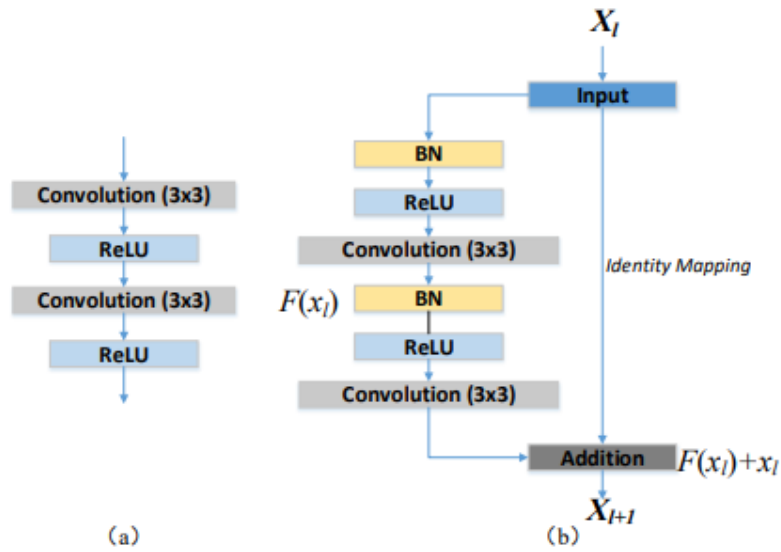


Figura 3.3: Blocos de construção de redes neurais. (a) Unidade neural simples usada no U-Net e (b) unidade residual com mapeamento de identidade usado no ResUnet proposto. (ZHANG; LIU; WANG, 2018)

A ResUnet é composta por três partes: a codificação que define as imagens em uma representação mais compacta; a ponte serve como uma conexão entre o codificador e o decodificador; e a decodificação que recupera as representações das imagens com a segmentação. A Figura 3.4 mostra a arquitetura da ResUnet.

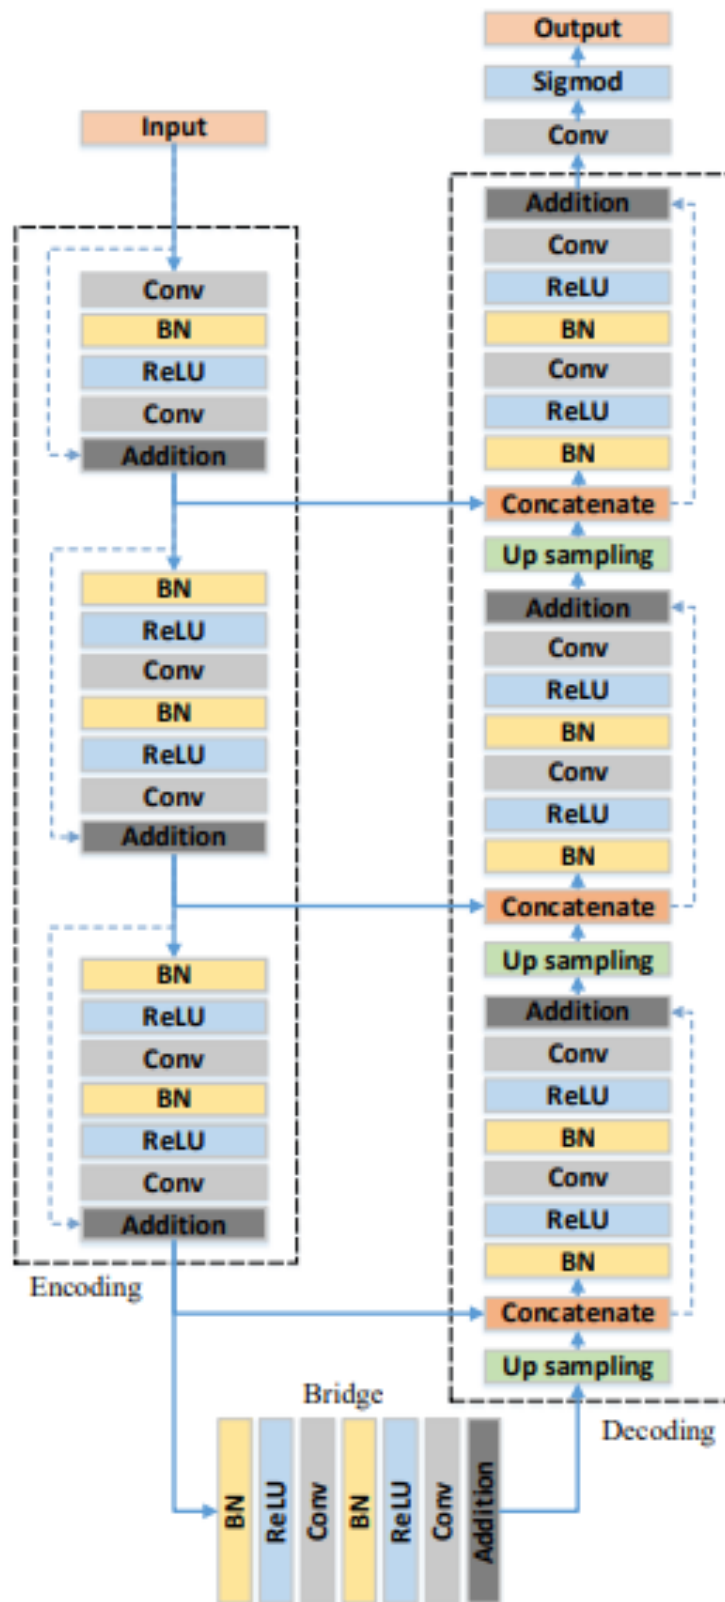


Figura 3.4: Arquitetura da ResUnet. (ZHANG; LIU; WANG, 2018)

3.2.2 DC-Unet

A arquitetura Dual Channel U-Net (DC-UNet) (LOU; GUAN; LOEW, 2021), é uma versão aprimorada da U-Net. O modelo DC-UNet foi testado em uma variedade de bases de imagens médica e comparado com a U-net, e os resultados mostraram que a DC-UNet supera o modelo clássico da U-Net em todos os casos.

Para construir a arquitetura da DC-Unet os autores também se basearam no modelo da MultiResUNet. Essa arquitetura foi criada pela necessidade de que uma rede precisa ter a capacidade de analisar objetos em diferentes escalas, então foi aplicado o bloco tipo inception (SZEGEDY et al., 2017), para que a arquitetura U-Net tivesse a capacidade de concatenar recursos aprendidos da imagem em diferentes escalas. Além disso, também foi adicionado a camada convolucional 1×1 chamada conexão residual, assim surgindo a MultiResUNet. A Figura 3.5 mostra a arquitetura da MultiResUNet.




Figura 3.5: Arquitetura da MultiResUNet (LIMA, 2021)

Segundo Lou, Guan e Loew (2021) usando o MultiResUNet para segmentar a região da mama a partir de imagens infravermelhas, os resultados mostraram que alguns dos resultados de segmentação foram influenciados por outras interferências, ocorrendo em algumas imagens de mamas pequenas onde os limites da mama não são claros. A fim de resolver esse problema projetando uma arquitetura CNN mais eficaz para extrair mais recursos espaciais foi proposto a DC-Unet. A conexão residual simples no bloco MultiRes foi substituída uma sequência de três camadas convolucionais 3×3 , chamada de bloco Dual Channel (3.6). A Figura 3.7 mostra a arquitetura da DC-UNet.

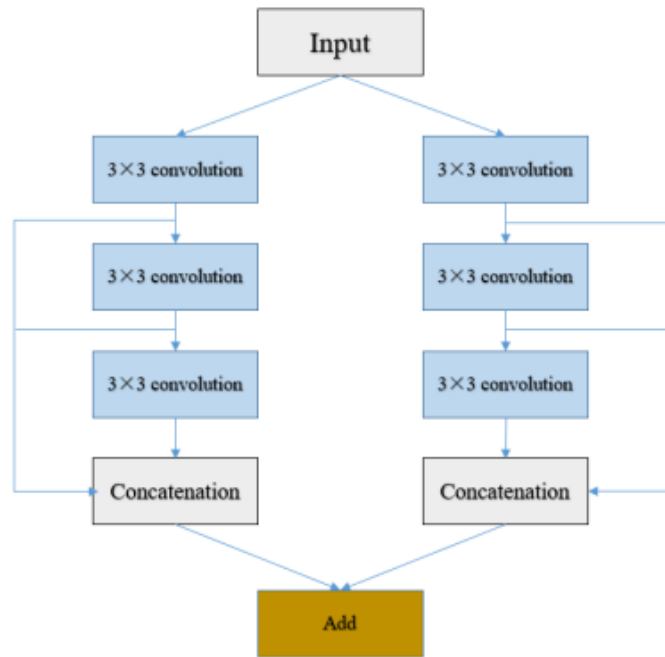


Figura 3.6: Bloco Dual-Channel (LIMA, 2021)




Figura 3.7: Arquitetura da DC-Unet (LIMA, 2021)

3.2.3 Funções de perda

A segmentação com rede neural convolucional não depende apenas da escolha da arquitetura da rede, mas também da escolha de uma função de perda. Essas funções de perda foram definidas considerando aquelas que melhor se ajustam aos problemas de segmentação, e que consideram o desequilíbrio entre as classes. Portanto, as funções avaliadas foram Generalized Dice loss e Focal Tversky Loss.

3.2.3.1

Generalized Dice loss

O coeficiente Dice (DSC) (HASHEMI et al., 2018) é um índice de sobreposição amplamente utilizado em problemas de segmentação. O cálculo desse índice é apresentado na Equação 3-1:

$$DSC = \frac{\sum_{i=1}^N p_i g_i + \epsilon}{\sum_{i=1}^N p_i + g_i + \epsilon} \quad (3-1)$$

onde, $g_i \in \{0, 1\}$ representa o rótulo verdadeiro e $p_i \in [0, 1]$ o rótulo previsto. O número total de pixels em uma imagem é indicado por N. O termo ϵ é usado aqui para evitar a questão numérica de dividir por 0.

Em problemas de segmentação pode ocorrer um desequilíbrio entre as classes, o que pode resultar em baixo desempenho quando a função de perda não pondera esse desequilíbrio. O coeficiente de Dice não considera essa ponderação entre as classes desbalanceadas. Para mitigar este problema, a Perda de Dados Generalizada (GDL) (CRUM; CAMARA; HILL, 2006) propõe ponderar o desbalanceamento dessas classes adicionando pesos para as classes.

A GDL apresenta uma estrutura generalizada para sobreposições que atinge esses objetivos definindo medidas de sobreposição de volume parcial e multirótulo com uma medida de erro associada (CRUM; CAMARA; HILL, 2006). A equação 3-2 apresenta o cálculo da GDL:

$$GDL = 1 - 2 \frac{\sum_{l=1}^2 w_l \sum_n g_{ln} p_{ln}}{\sum_{l=1}^2 w_l \sum_n g_{ln} + p_{ln}} \quad (3-2)$$

onde, w_l é usado para fornecer invariância a diferentes propriedades do conjunto de rótulos. O g_n representa o rótulo verdadeiro e p_n o rótulo previsto.

3.2.3.2

Focal Tversky Loss

A função de perda focal Tversky (FT) é uma combinação das funções Focal e Tversky. A função de perda focal (LIN et al., 2017) baseia-se na entropia cruzada, visando lidar com o desequilíbrio de classes. Para lidar com o desequilíbrio é utilizado um expoente modulador para reduzir os erros de peso atribuídos aos exemplos bem classificados, assim é possível evitar que um grande número de exemplos negativos domine o gradiente deste modo amenizando o desequilíbrio das classes.

O índice de similaridade de Tversky (HASHEMI et al., 2018) é uma generalização da pontuação Dice, que permite flexibilidade no balanceamento de falsos positivos e falsos negativos. A equação 3-3 apresenta o cálculo do índice de similaridade de Tversky:

$$TI_c = \frac{\sum_{i=1}^N p_{ic}g_{ic} + \epsilon}{\sum_{i=1}^N p_{ic}g_{ic} + \alpha \sum_{i=1}^N p_{i\bar{c}}g_{ic} + \beta \sum_{i=1}^N p_{ic}g_{i\bar{c}} + \epsilon} = \frac{TP}{TP + \alpha * FP + \beta * FN} \quad (3-3)$$

onde,

- c : classes dos rótulos;
- p : amostras com os rótulos preditos;
- g : amostras com os rótulos verdadeiros.

Considerando um problema binário, $p_{ic} \in [0, 1]$ é a probabilidade do pixel i pertencer a classe de interesse c , $p_{i\bar{c}}$ é a probabilidade do pixel i pertencer a classe de não interesse c . O mesmo é válido para g_{ic} e $g_{i\bar{c}}$. O ϵ é utilizado para evitar divisão por zero. O β e α são hiperparâmetros que podem ser ajustados em casos de grande desequilíbrio de classes. Para a função de perda esse índice Tversky é adaptado da seguinte forma:

$$TL = \sum_c 1 - TI_c \quad (3-4)$$

Segundo Hashemi et al. (2018) a perda FT se propõe a resolver o problema do coeficiente dice na dificuldade em segmentar pequenas ROIs. Para resolver este problema foi proposto a FT 3-5, que é parametrizada por γ para controlar exemplos entre ROI de fundo fácil e difícil durante o treinamento.

$$FTL_c = \sum_c (1 - TI_c)^{\frac{1}{\gamma}} \quad (3-5)$$

3.3

Métricas de Validação

As métricas tem como objetivo medir o desempenho do método e promover a validação dos resultados obtidos, sendo possível comparar e identificar a melhor configuração para o problema.

Para avaliar problemas de segmentação existem algumas métricas empregadas pela literatura. A fim de avaliar a metodologia proposta neste trabalho foram escolhidas as seguintes métricas: jaccard, Dice e Recall. Elas apresentam as seguintes relações:

$$Recall = \frac{VP}{VP + FN} \quad (3-6)$$

$$jaccard(G, P) = \frac{|G \cap P|}{|G \cup P|} = \frac{|G \cap P|}{|G| + |P| - |G \cap P|} \quad (3-7)$$

$$Dice(G, P) = \frac{2|G \cap P|}{|G| + |P|} \quad (3-8)$$

onde,

- VP : Verdadeiros positivos (amostras de horizonte classificadas como horizonte);
- FN : Falsos negativos (amostras de horizonte classificadas como não horizonte).
- G : Rótulos verdadeiros ou padrão ouro.
- P : Rótulos preditos pelo modelo.

A Sensibilidade ou *recall* (Equação 3-6) é o número de imagens corretamente classificadas para a classe de interesse, neste caso, os horizontes.

O índice *jaccard* ou IoU (Equação 3-7) calcula a intersecção (sobreposição) entre o conjunto de amostras da segmentação manual com a segmentação prevista sobre a união entre esses conjunto. Essa métrica varia de 0 a 1, quanto mais próximo de 1, maior é a intersecção entre os objetos.

Segundo Zijdenbos et al. (1994) a pontuação Dice reflete melhor o tamanho e a concordância de localização para segmentação de objetos. O coeficiente de similaridade Dice (Equação 3-8) está correlacionado ao IoU, também varia de 0 a 1, quanto mais próximo de 1, mais semelhante está a segmentação predita da verdadeira.

Este trabalho se propõe utilizar uma rede neural convolucional para identificar as fronteiras entre as fácies sísmica em dados sísmicos 2D. Além de identificar funções de perda que se adéquem ao problema.

Considerando que uma seção sísmica é uma matriz, esta pode ser tratada como uma imagem. As redes neurais convolucionais tem mostrado um bom desempenho em problemas de processamento de imagem, como segmentação de objetos e em imagens médicas. Então, foram identificadas algumas arquiteturas baseadas em camadas convolucionais que obtiveram ótimos resultados aplicadas a dados médicos. Então, as arquiteturas selecionadas para este trabalho foram a ResUnet e a DC-Unet.

A ResUnet é baseada na Unet, que é uma rede amplamente utilizada em dados médicos. Além disso, é aplicado o conceito de bloco residual mantendo a estrutura encoder-decoder da Unet, assim obtendo uma arquitetura mais rápida. A ResUnet foi apresentada por (ZHANG; LIU; WANG, 2018) e aplicada em dados de extração de estradas em uma segmentação binária, sua seleção se deve por apresentar melhores resultados que a Unet.

A DC-Unet é baseada na multiResUnet, tem mais parâmetros que a ResUnet, mas apresentou bons resultados em problemas binários de imagens médicas em pequenas estruturas.

A segmentação em aprendizado profundo não depende apenas da escolha da arquitetura da rede, mas também da escolha de uma função de perda. Para definir as funções de perda utilizadas foram consideradas aquelas que melhor se ajustam aos problemas de segmentação. Além disso, também foi considerado o desequilíbrio entre as classes na escolha das melhores funções. Portanto, as funções selecionadas foram a Generalized Dice Loss e Focal Tversky Loss.

Os dados neste trabalho foram avaliados no formato de seção e patches. A vantagem da abordagem em seção é primeiramente a praticidade, a segunda é que a rede pode aprender melhor as relações entre as classes observando a seção completa. Porém neste trabalho para usar as inlines e crossline foi necessário fazer o redimensionamento para padronizar as dimensões dos dados. Já o modelo baseado em patch é treinado em pequenos patches extraídos das inlines e crosslines dos dados de treino. Essa abordagem pode ser mais viável do que usar seções inteiras para o treinamento, e diferente da abordagem por seção esta não modifica as características do dado redimensionando a seção.

Nas seções seguintes é apresentado uma descrição do detalhamento das

etapas dos processos da metodologia.

4.1

Etapas da Solução

Esta seção apresenta as etapas do método proposto, que está estruturado em duas etapas: pré-processamento e segmentação. Neste trabalho utilizamos modelos baseado em seção (Figura 4.1) e modelo baseado em patches (Figura 4.2).

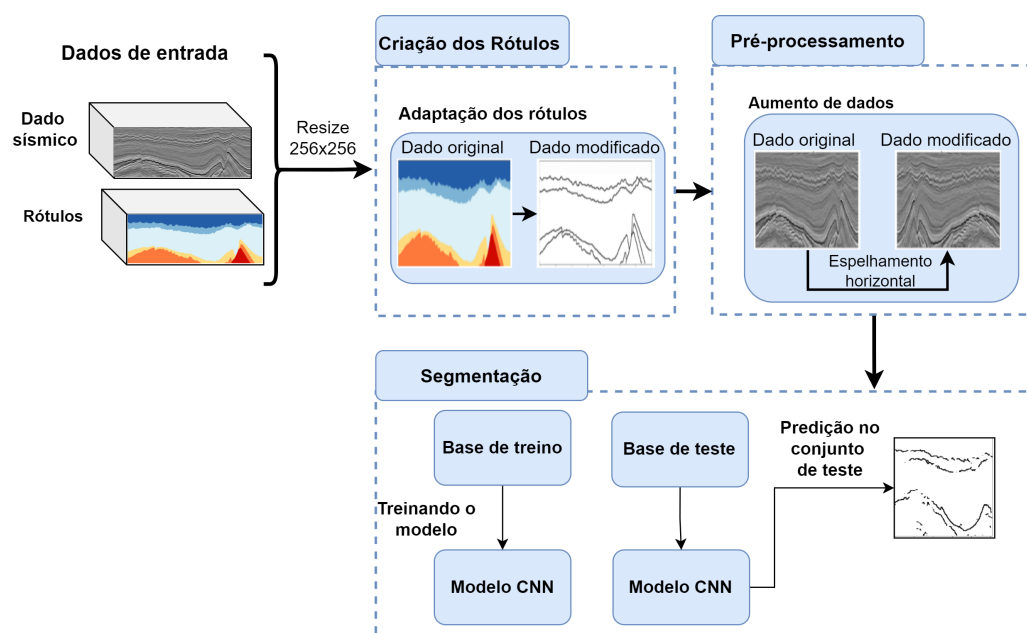


Figura 4.1: Fluxograma das etapas do método do modelo baseado em seção.

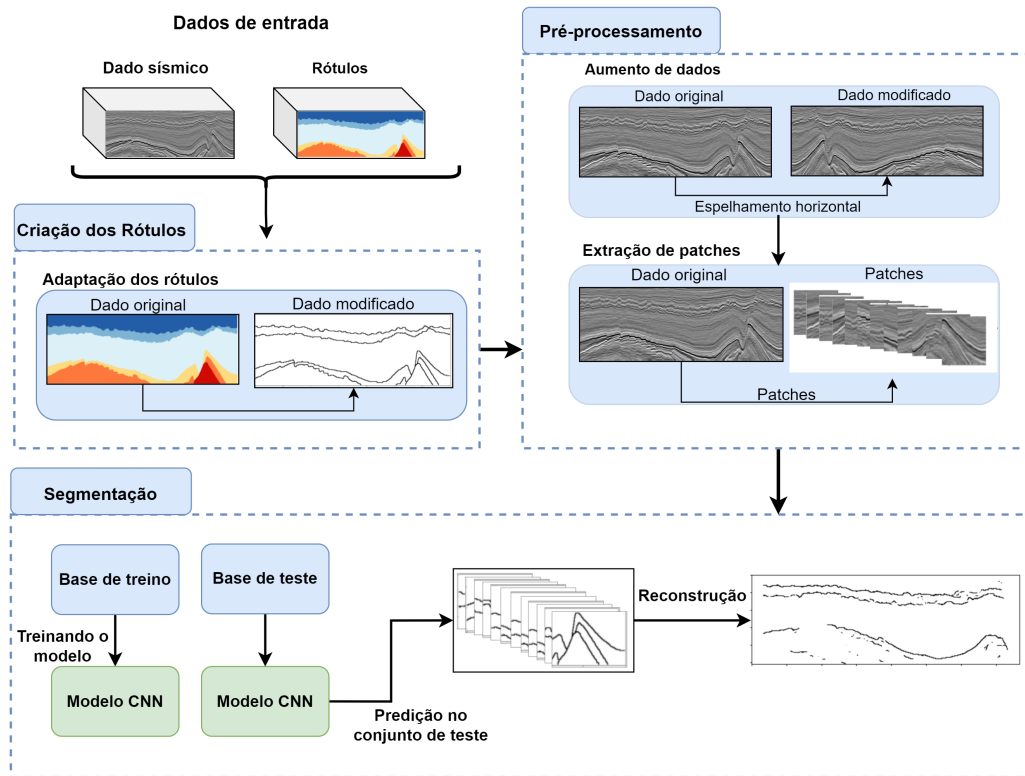


Figura 4.2: Fluxograma das etapas do método do modelo baseado em patches.

4.1.1

Pré-processamento

A etapa de pré-processamento teve como objetivo preparar os rótulos das imagens da base e aumentar a quantidade dos dados a fim de melhorar o aprendizado. Esta etapa está dividida em três etapas: Adaptação das anotações, Aumento de dados e Extração de patches.

Neste trabalho foram utilizadas todas as bases do conjunto de dados. O volume dos dados foram manipulados no formato de seção, ou seja, imagem 2D, utilizando as inlines e crosslines.

4.1.1.1

Adaptação das anotações

As anotações dos rótulos deste conjunto de dados consideram um problema multiclasse, onde são divididas em 6 fácies sísmicas. Os horizontes são fronteiras entre essas fácies. Como o objetivo deste trabalho é encontrar essas fronteiras consideramos o problema como binário, por isso foi necessário adaptar as anotações dos rótulos. Nas imagens definimos o rótulo de background com valor 0 e os horizontes com valor 1. Para visualização dos resultados neste trabalho o background é representado pela cor branca e os horizontes pela cor preta.

Os horizontes foram definidos encontrando os pixels de limite entre as fácies, com espessura 2, considerando os pixels de limite das duas fácies que fazem fronteira. Na Figura 4.3 temos um exemplo do processo para definir um pixel como horizontes. A partir da matriz inicial o algoritmo encontra um pixel que é diferente de algum dos seus vizinhos (vizinhança 8), na imagem ele está demarcado com a cor vermelha e a vizinhança pela cor azul. Em seguida, este pixel e os vizinhos que são diferentes dele são marcados como horizonte (cor verde). Neste trabalho, foi considerado uma vizinhança de 8, a fim de obter mais informações sobre as características dessa transição.

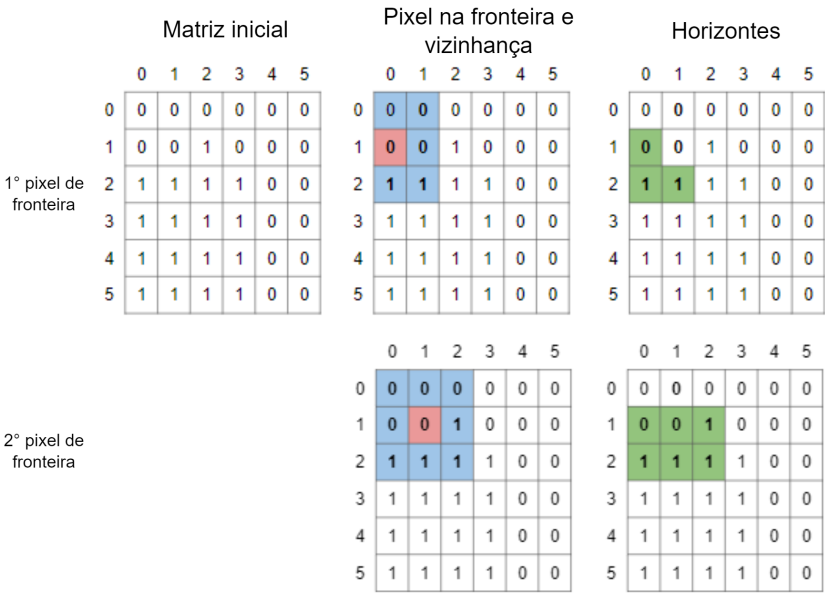


Figura 4.3: Exemplo do funcionamento da definição dos horizontes.

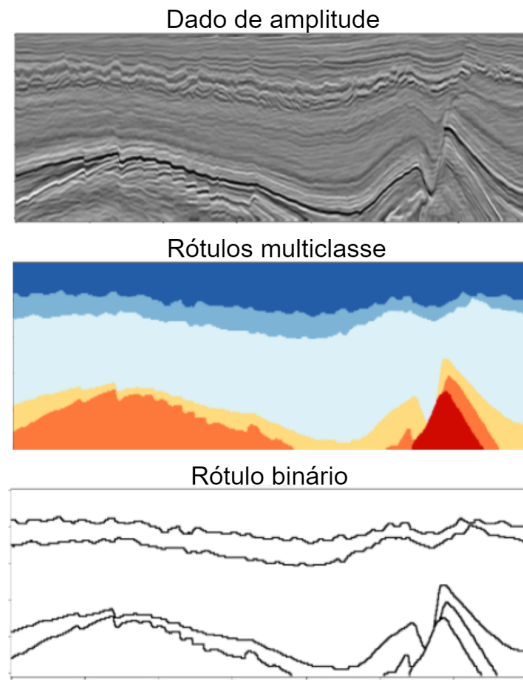


Figura 4.4: Exemplo de uma seção com a adaptação das anotações.

4.1.1.2

Aumento de dados

As arquiteturas das redes neurais profundas são complexas, e com muitos parâmetros para ajustar, então são necessários muitos dados para treinar e ajustar o modelo, caso não haja dados suficientes pode ocorrer superajuste nos modelos (LASHGARI; LIANG; MAOZ, 2020). Neste caso uma abordagem para resolver o problema é utilizar a técnica de aumento de dados.

O aumento de dados tem como objetivo gerar novas imagens aplicando algumas operações de transformações nas imagens existentes na base. Para cada operação aplicada é gerada uma nova imagem. Algumas dessas operações podem ser as seguintes: rotação, adição de ruídos, zoom, espelhamento horizontal.

Neste trabalho foi utilizado apenas o espelhamento horizontal (Figura 4.5) assim como no trabalho de Lima (2021), a fim de preservar as características do dado sísmico. Essa operação faz uma rotação da imagem no eixo y.




Figura 4.5: Exemplo da aplicação de espelhamento horizontal em uma seção sísmica.

4.1.1.3

Extração de patches

A extração de patches teve como objetivo manter as características do dado sem a necessidade de modificar a dimensão do dado, apenas dividindo a imagem. A fim de avaliar o comportamento do aprendizado da rede utilizando patches, foram analisados alguns tamanhos, sendo os seguintes: 256x256, 128x128 e 64x64.

As seções de cada base tem dimensões diferentes, assim serão geradas quantidades de patches diferentes para cada dimensão. Como são gerados patches quadrados e as seções variam de tamanho, foi utilizado padding com valor zero nas extremidades da imagem, a fim de manter a padronização. A largura do padding também varia de acordo com as dimensões da seção.

A Figura 4.6 mostra exemplos de uma seção de 255x701 dividida nos três tamanhos de patches, gerando as seguintes quantidades de imagens: 3 de 256x256, 12 de 128x128 e 24 de 64x64. As linhas vermelhas representam a divisão.

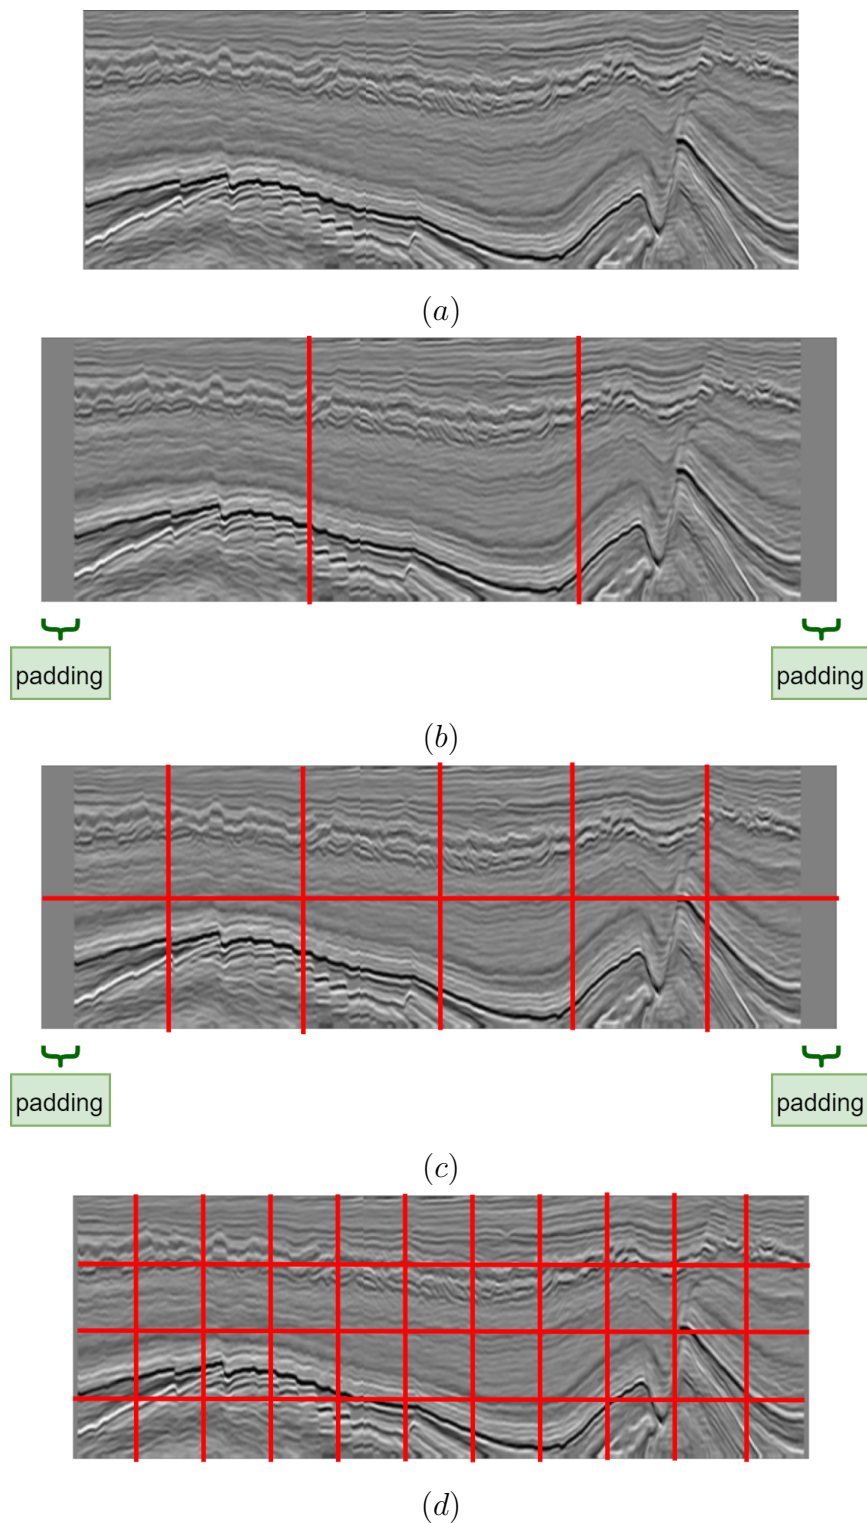


Figura 4.6: Exemplo da extração de patches em uma seção. (a) Seção sísmica. (b) Patches de dimensão 256×256 gerados de uma Seção sísmica. (c) Patches de dimensão 128×128 gerados de uma Seção sísmica. (d) Patches de dimensão 64×64 gerados de uma Seção sísmica.

4.1.2

Segmentação

Nesta etapa é realizado a segmentação dos horizontes e avaliação do aprendizado dos modelos. Primeiramente, foram escolhidas as CNNs que seriam utilizadas neste trabalho. Em seguida, realizado o treinamento e validação das configurações dos modelos baseados em seção e patches.

Então, para o treinamento dos modelos foi reservada aleatoriamente 10% da base de treino para o conjunto de validação. Em seguida, as imagens de amplitudes e dos rótulos dessas duas bases são passadas como entrada para o modelo da rede neural convolucional para a fase de treinamento que tem como finalidade aprender os pixels que representam as fronteiras.

Depois que o modelo da rede é treinado, esse modelo é avaliado utilizando as duas bases de teste. Após a segmentação das imagens da base de teste os dados preditos são avaliados com as métricas definidas. As métricas do modelo baseado em patches são calculadas na predição dos patches, em seguida é feito a reconstrução da seção para visualização da predição.

5 Resultados

Este capítulo apresenta e discute os resultados obtidos nos testes efetuados do método proposto. Primeiramente, é apresentado uma descrição da base de dados, em seguida as condições e parâmetros de cada teste, e a comparação e discussão dos resultados apresentados.

5.1 Dados 3D do bloco F3

O conjunto de dados utilizado neste trabalho foi o Facies-Mark (ALAUDAH et al., 2019). Os autores fizeram anotação das camadas geológicas do bloco F3, definindo seis classes nessas anotações, onde cada uma representa uma fácies sísmica, exceto uma que é a união de duas fácies, a Rijnland e Chalk.

A Figura 5.1 mostra o modelo geológico 3D do bloco F3 com as classes das fácies sísmicas anotadas.




Figura 5.1: Modelo 3D geológico do bloco F3. Fonte:(ALAUDAH et al., 2019).

O volume desses dados é composto por inline e crossline. A Tabela 5.1 mostra a divisão desses dados em três conjuntos e a quantidade de inlines e crosslines.

A figura 5.2 mostra a divisão das bases visualizadas no modelo geológico do bloco F3.

Tabela 5.1: Divisão das bases

Base	Crossline	Inline
Treino	701	401
Teste 1	701	200
Teste 2	200	601

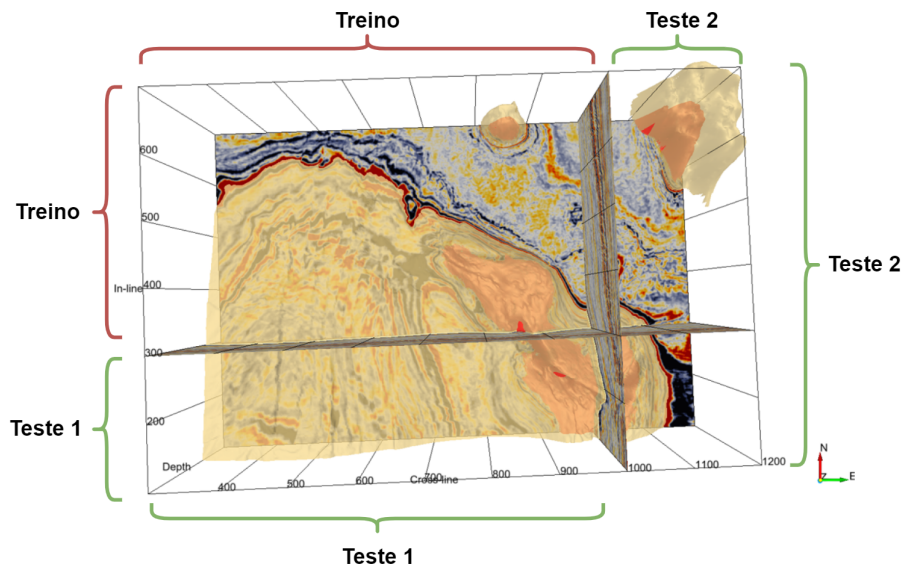


Figura 5.2: Divisão das bases visualizadas no modelo geológico do bloco F3. Fonte:Adaptado de Alaudah et al. (2019).

5.2 Treinamento e Teste

Para a implementação da metodologia proposta foi utilizado a linguagem open source de script python versão 3.7. Os modelo das redes foram implementados usando o framework TensorFlow na versão 2.8. Eles foram treinados usando o otimizador Adam (KINGMA, 2015), com uma taxa de aprendizado de 0,001 e um máximo de 300 épocas, interrompendo o treinamento com a técnica *Early Stopping* se não houver melhora em 10 épocas.

O conjunto de dados de treinamento foi composto por seções de inlines e crosslines, nessas seções foram aplicados pré-processamento definindo em modelos de seção e patches. A partir do modelo de seção foram extraídos do volume sísmico as seções, em seguida usando foi gerado a mesma quantidade de imagens a partir das seções definindo dois conjuntos de dados, com aumento de dados e sem. Para o modelo em patches foi definido três conjuntos com dimensão de 256x256, 128x128 e 64x64. A Tabela 5.2 apresenta a quantidade total de imagens geradas para cada configuração, divididas em três partes: treino, validação e teste. A quantidade de imagens com aumento de dados é o dobro para cada configuração da tabela, apenas na base de teste não foi

aplicado essa técnica.

Tabela 5.2: Quantidade de imagens geradas pelo pré-processamento

Conjunto de dados	Treino	Validação	Teste
Seção	991	111	1702
Patches de 256	2342	263	2502
Patches de 128	9368	1052	9608
Patches de 64	33508	3764	37632

Foram realizadas diversas sessões de treinamento para comparar as configurações dos modelos. Ao final de cada treinamento, os modelos gerados tiveram os pesos armazenados da melhor época. A Tabela 5.3 a seguir mostra as métricas de avaliação para base de teste obtidas para os modelos baseados em seção.

Tabela 5.3: Resultados dos modelos baseados em seção.

Modelo	Função de perda	Aumento de dados	Dice (%)	Recall (%)	Jaccard (%)
ResUnet	Focal Tversky	-	52,03	47,20	35,42
		Horizontally Flip	52,61	50,41	35,51
	Generalized Dice	-	50,93	43,44	34,60
		Horizontally Flip	51,18	45,75	34,18
	Focal Tversky	-	32,52	44,00	35,48
		Horizontally Flip	32,32	46,19	34,67
DC-Unet	Generalized Dice	-	33,21	40,16	33,28
		Horizontally Flip	33,24	42,60	33,54

Os diferentes tamanhos de patches foram avaliados comparando as redes DC-Unet e a ResUnet com a função de perda que obteve melhor resultado nos testes com base na seção, essa função foi a Focal Tversky. A Tabela 5.4 a seguir mostra as métricas de avaliação obtidas para os modelos baseados em patches, comparando os modelos de rede neural.

Tabela 5.4: Resultados dos modelos baseados em patches variando as dimensões.

Modelo	Função de perda	Patches	Dice (%)	Recall (%)	Jaccard (%)
ResUnet	Focal Tversky	256	53,96	50,65	36,71
		128	56,09	55,00	38,66
		64	50,60	51,88	34,39
DC-Unet	Focal Tversky	256	38,50	46,95	36,68
		128	42,29	50,21	38,23
		64	34,21	42,57	33,83

Após avaliar o melhor tamanho de patches, foram gerados os testes com as configurações de rede, função de perda e aumento de dados para as dimensões 128x128, que foi a que obteve melhores métricas entre as demais dimensões. Tabela 5.5 a seguir mostra as métricas de validação obtidas para os modelos baseados em patches de 128x128.

Tabela 5.5: Resultados dos modelos baseados em patches de 128x128

Modelo	Função de perda	Aumento de dados	Dice (%)	Recall (%)	Jaccard (%)
ResUnet	Generalized Dice	-	54,37	47,76	37,16
		Horizontal flipping	55,27	49,75	37,67
	Focal Tversky	-	56,09	55,00	38,66
		Horizontal flipping	55,61	57,37	37,95
	Generalized Dice	-	43,59	41,72	35,48
		Horizontal flipping	45,68	43,81	37,67
DC-Unet	Focal Tversky	-	42,29	50,21	38,23
		Horizontal flipping	41,58	49,39	37,65

5.3 Discussão

Os testes exibidos na seção anterior mostram a capacidade dos modelos propostos. Na Tabela 5.3 é apresentado as métricas alcançadas pelos modelos

baseados em seção. Observa-se, que os modelos apresentaram resultados promissores, considerando que o problema de identificar as bordas entre as fácies não é trivial. A rede ResUnet com a função de perda Focal Tversky e aumento de dados apresentou os maiores valores nas métricas, sendo promissora alcançando valores aproximados de 53%, 50% e 36%, para dice, recall e jaccard, respectivamente.

A Figura 5.3 apresenta os resultados gráficos dos modelos de seção avaliados, em seções de inline e crossline. As imagens a esquerda indicam as seções com as marcações dos horizontes, e as imagens em preto e branco os resultados das predições dos modelos com aumento de dados.

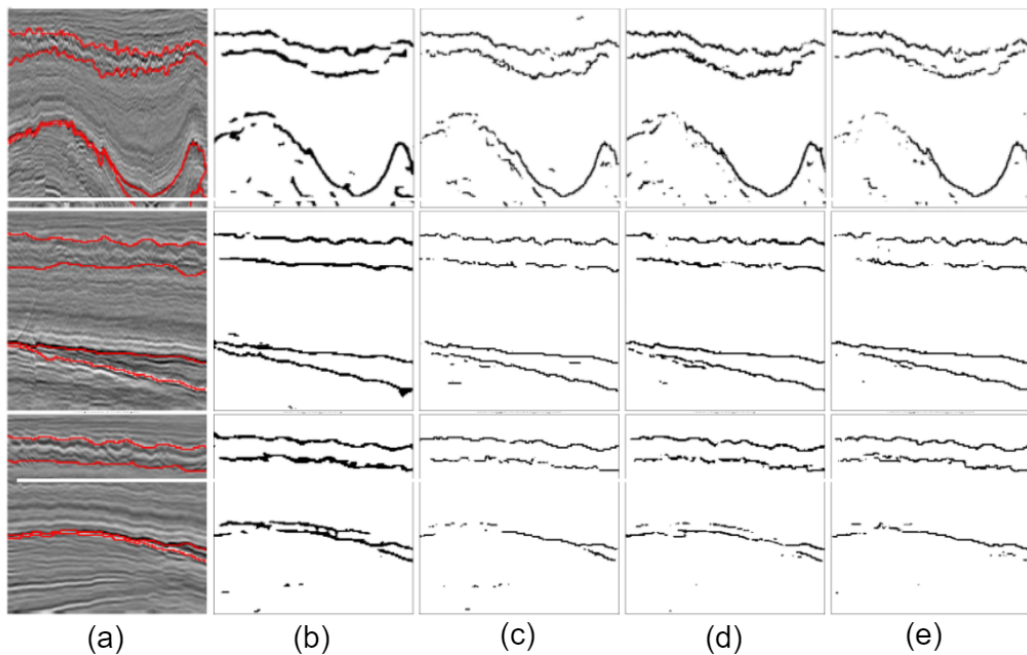


Figura 5.3: Exemplo de resultados de inlines e crosslines com modelos baseados em seção. (a) Imagem de amplitude com a marcação. (b) DC-Unet com Focal Tversky. (c) DC-Unet com Generalized Dice. (d) ResUnet com Focal Tversky. (e) ResUnet com Generalized Dice.

Os resultados para comparação dos patches foram realizados sem aumento de dados. Na Tabela 5.4 observou-se que o melhor tamanho de patche para estes dados sísmicos foi o de 128x128. Alcançando uma eficiência de aproximadamente 56%, 55% e 38%, para dice, recall e jaccard, respectivamente.

Na Figura 4.6 da Seção 4.1.1.3 pode-se observar um exemplo de uma seção de inline e a aplicação da técnica de extração de patches com as diferentes dimensões. Observando esse exemplo com a dimensão de 128x128 a imagem foi dividida horizontalmente em duas partes, visualmente as características dos horizontes da primeira parte possuem menos contrastes que as características dos horizontes da segunda. Então, acredita-se que com essa dimensão foi

possível que as imagens de cada patches tivessem informações de características de horizontes mais semelhantes entre si, considerando que cada horizontes é uma fronteira entre duas fácies sísmicas diferentes, essa divisão pode ser interessante. Já nas dimensões de 256x256 é considerado a altura da seção inteira, assim não divide em imagens diferentes essas características. Na dimensão de 64x64 os patches são muito pequenos, a informação na vertical de um horizonte pode acabar sendo dividida em duas imagens, assim dificultando o aprendizado das redes.

Os melhores resultados com os dados baseados em seção e patches mostraram que o último obteve melhores resultados nas métricas, porém não é possível fazer uma comparação direta das métricas, pois foi aplicado redimensionamento nos dados dos modelos baseados em seção. Mas, como a dimensão de 128x128 foi melhor que a de 256x256 que considera a vertical inteira da seção, acreditasse que o modelo baseado em patches pode ser melhor que o de seção.

Após identificar o melhor tamanho de patches, foi realizado os testes com todas as configurações propostas usando os patches de 128x128. Na Tabela 5.5 observou-se os melhores resultados foi com a rede ResUnet com a função de perda Focal Tversky sem aumento de dados. Alcançando uma eficiência de aproximadamente 56%, 55% e 38%, para dice, recall e jaccard, respectivamente.

Com a aplicação do aumento de dados houve uma melhora em quase todas as métricas dos modelos, mostrando a importância na quantidade e diversificação dos dados no aprendizado das redes neurais nesses dados. Apenas no melhor resultado alcançado com patches de 128x128 os resultados foram melhores sem aumento de dados para as métricas de dice e jaccard, o recall melhorou com essa técnica. No trabalho de Alaudah et al. (2019), o aumento de dados em sísmica também resultou em melhores resultados.

A arquitetura da ResUnet obteve melhores resultados nos modelos comparando com a DC-Unet, além de ser mais rápida por ter menos parâmetros para treinar.

As funções de perda utilizadas neste trabalho são baseadas em regiões, dentre elas a que apresentou um melhor desempenho na maioria das configurações foi a função de perda Focal Tversky.

A Figura 5.6 apresenta os resultados gráficos de uma inline e uma crossline nos modelos baseados em patches. No retângulo verde observa-se uma falha sísmica, onde o modelo não conseguiu identificar os pixels como horizonte. Observou-se que as falhas sísmicas influenciaram negativamente na classificação dos pixels de horizontes, acredita-se que mesmo considerando um determinado conjunto de pixels que apresentam falhas como horizonte

na marcação, as características desses pixels podem ser diferentes dos demais considerados horizontes, assim dificultando o aprendizado dos modelos. Nos resultados apresentados no trabalho de Lima (2021) a detecção dos horizontes mesmo em casos de instabilidade na fronteira, como as falhas sísmicas, nesses casos houve descontinuidade desses horizontes.

Nas Figuras 5.4 e 5.4 temos o resultado da previsão de duas seções em um modelo baseado em patche. Podemos observar na intersecção na Figura 5.4, que visualmente o modelo obteve bons resultados, conseguindo identificar as bordas, errando apenas a distância de alguns pixels previstos (erros em azul) dos rótulos reais (rótulos verdadeiros em verde). No entanto, como as métricas são calculadas pixel a pixel, a diferença nessa distância dos pixels previstos até os rótulos reais afeta os resultados das métricas, obtendo-se assim valores menores. Assim, considerando este cenário, os resultados são promissores. Outro ponto que podemos observar na Figura 5.5 é um caso de falha sísmica, visualmente o modelo identificou bem a fronteira, porém errou em locais com falhas, e isso também afeta os resultados das métricas.




Figura 5.4: Resultado de uma seção de Inline em patches usando a ResUnet: 80,19% de Dice; 66,94% de Jaccard




Figura 5.5: Resultado de uma seção de Inline em patches usando a ResUnet: 58,20% de Dice; 41,04% de Jaccard

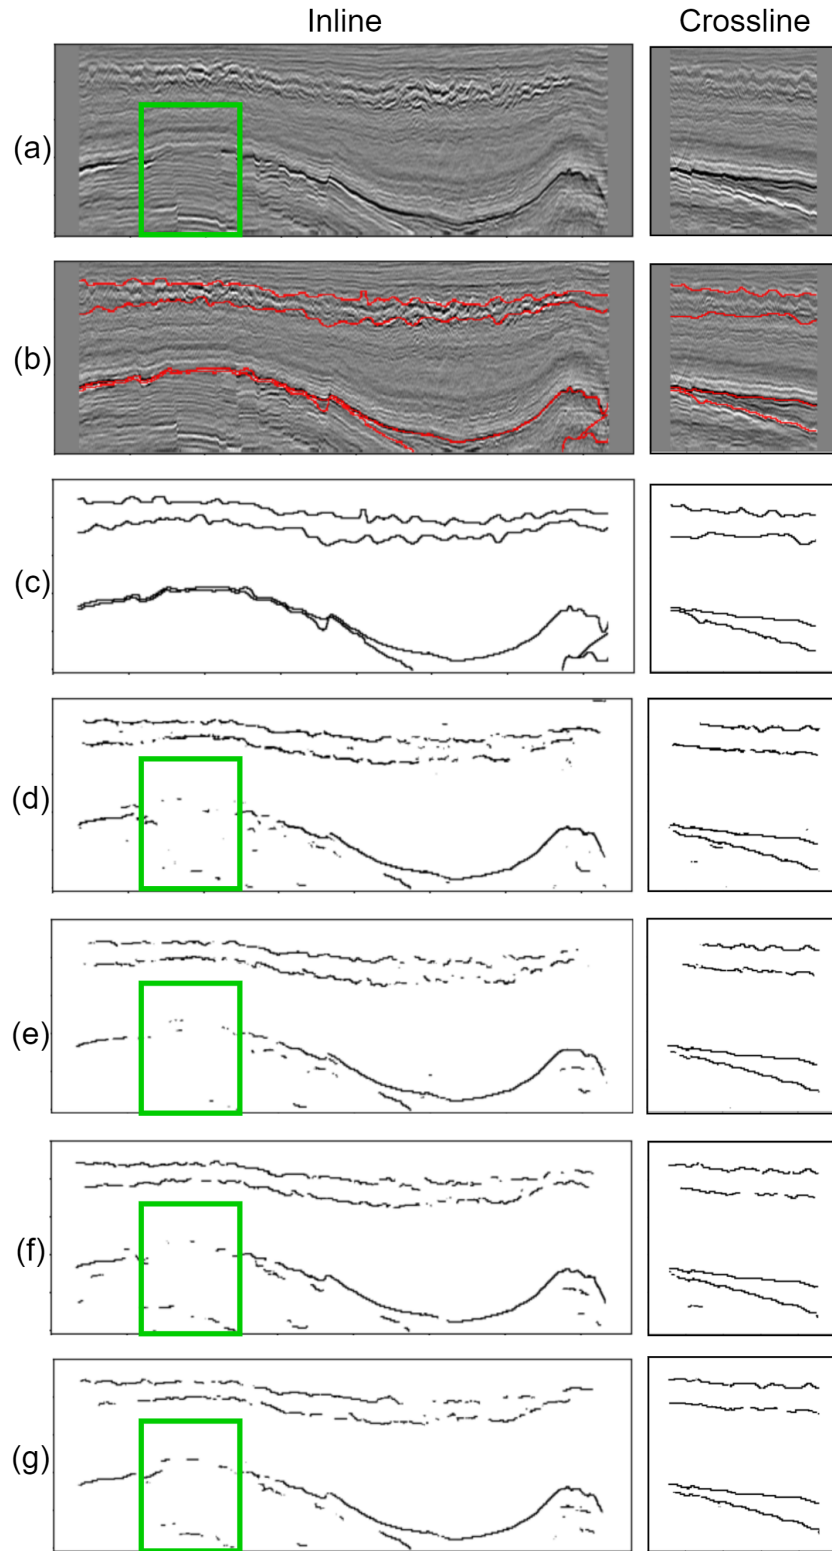


Figura 5.6: Exemplo de resultados de uma inline e uma crossline com modelos baseados em patches usando a ResUnet. (a) Imagem de amplitude. (b) Imagem de amplitude com a marcação. (c) Rótulos. (d) ResUnet com Focal Tversky. (e) ResUnet com Generalized Dice. (f) DC-Unet com Focal Tversky. (g) DC-Unet com Generalized Dice.

6

Conclusão e trabalhos futuros

Durante o desenvolvimento deste trabalho, foi discutido sobre a interpretação de dados sísmicos, visando o problema da detecção de horizontes, a fim de auxiliar e facilitar a interpretação para o especialista. Então, este trabalho apresentou um estudo com diferentes configurações utilizando arquiteturas de redes convolucionais, aumento de dados e funções de perda, a fim de segmentar os horizontes de forma supervisionada.

As métricas mostraram que a aplicação do aumento de dados melhorou o aprendizado da maioria dos modelos, obtendo melhores resultados quando comparado com os resultados sem o aumento de dados.

Foi notado que em regiões onde existem falhas sísmicas, há descontinuidade dos horizontes. Nesse lugar específico, onde temos falhas sísmicas, parece ser mais difícil para o modelo reconhecer a diferença entre o objeto e o fundo. Assim, podendo influenciar negativamente no aprendizado dos modelos. Neste trabalho, observou-se que os modelos não conseguiram identificar os horizontes em casos com as falhas sísmicas, nesses casos houve descontinuidade desses horizontes.

Após aplicar e estudar redes convolucionais, observou-se que a ResUnet com a função de perda Focal Tversky é uma técnica promissora para a identificação de horizontes. E ainda existe uma grande variedade de configurações de técnicas de deep learning que podem ajudar a construir um modelo melhor onde as configurações usadas neste trabalho não tiveram um bom desempenho.

6.1

Trabalhos Futuros

A fim de ampliar e melhorar os resultados desta pesquisa, algumas tarefas podem ser realizadas para contribuir com a metodologia. Assim, seguem sugestões para a ampliação deste estudo:

- Otimização dos parâmetros das redes neurais.
- Avaliar a utilização de outros tipos de aumento de dados.
- Um outro ponto para o aprimoramento do processo de detecção dos horizontes, seria realizar a segmentação por instância, identificar cada horizonte individualmente poderia resolver a identificação em áreas com falhas.
- Avaliar a utilização de outras arquiteturas de redes, como as Recorrentes;

- Avaliar a segmentação tridimensional, pois considerando que as fácies sísmicas estão correlacionadas entre as seções, pode-se melhorar os resultados.

Referências bibliográficas

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.

ALFARHAN, M.; DERICHE, M.; MAALEJ, A. Robust concurrent detection of salt domes and faults in seismic surveys using an improved unet architecture. **IEEE Access**, IEEE, 2020.

AMARAL, R. G. d. et al. Elaboração de algoritmo para aplicação de aprendizado de máquina a fim de reconhecer armadilhas geológicas do tipo domo salino em seções sísmicas. Brasil, 2021.

CALHES, D. et al. Simplifying horizon picking using single-class semantic segmentation networks. In: IEEE. **2021 34th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)**. [S.l.], 2021. p. 286–292.

CRUM, W. R.; CAMARA, O.; HILL, D. L. Generalized overlap measures for evaluation and validation in medical image analysis. **IEEE transactions on medical imaging**, IEEE, v. 25, n. 11, p. 1451–1461, 2006.

FERREIRA, A. d. S. Redes neurais convolucionais profundas na detecção de plantas daninhas em lavoura de soja. 2017.

FIGUEIREDO, A. M. **Pse User esce LSeeS «... Tese (Doutorado) — PUC-Rio, 2007.**

FIGUEIREDO, A. M. **Mapeamento de eventos Sísmicos Baseado EM Algoritmos de Agrupamento de Dados.** Tese (Doutorado) — Pontifical Catholic University of Rio de Janeiro, Brazil, 2015.

GUO, Y. et al. Fault and horizon automatic interpretation by cnn: a case study of coalfield. **Journal of Geophysics and Engineering**, Oxford University Press, v. 17, n. 6, p. 1016–1025, 2020.

HASHEMI, S. R. et al. Tversky as a loss function for highly unbalanced image segmentation using 3d fully convolutional deep networks. **arXiv preprint arXiv:1803.11078**, 2018.

HE, K. et al. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2016. p. 770–778.

ISLAM, M. S. ul. Using deep learning based methods to classify salt bodies in seismic images. **Journal of Applied Geophysics**, Elsevier, v. 178, p. 104054, 2020.

JAPÃO, M. D. Processamento e interpretação de dados sísmicos monocanal no anticlinal joetsu, bacia de joetsu. 2018.

KINGMA, D. P. & ba j.(2014). adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2015.

LASHGARI, E.; LIANG, D.; MAOZ, U. Data augmentation for deep-learning-based electroencephalography. **Journal of Neuroscience Methods**, Elsevier, v. 346, p. 108885, 2020.

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.

LIMA, G. C. Segmentação de fácies sísmicas com redes neurais. Universidade do Vale do Rio dos Sinos, 2021.

LIN, T.-Y. et al. Focal loss for dense object detection. In: **Proceedings of the IEEE international conference on computer vision**. [S.l.: s.n.], 2017. p. 2980–2988.

LOU, A.; GUAN, S.; LOEW, M. Dc-unet: rethinking the u-net architecture with dual channel efficient cnn for medical image segmentation. In: SPIE. **Medical Imaging 2021: Image Processing**. [S.l.], 2021. v. 11596, p. 758–768.

O'NEAL, B. **Encyclopedia of Western Gunfighters**. [S.l.]: University of Oklahoma Press, 1991.

ROBINSON, E.; TREITEL, S. Geophysical signal analysis: Pren tice-hall. **Englewood Cliffs**, 1980.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. **International Conference on Medical image computing and computer-assisted intervention**. [S.l.], 2015. p. 234–241.

SILVA, P. H. R. d. et al. Compressão de dados sísmicos com perda controlada. Universidade do Estado do Rio de Janeiro, 2014.

SILVA, P. M. C. e. **Visualização Volumétrica de Horizontes EM Dados Sísmicos 3D**. Tese (Doutorado) — Pontifical Catholic University of Rio de Janeiro, Brazil, 2004.

SZEGEDY, C. et al. Inception-v4, inception-resnet and the impact of residual connections on learning. In: **Thirty-first AAAI conference on artificial intelligence**. [S.l.: s.n.], 2017.

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

ZHANG, Z.; LIU, Q.; WANG, Y. Road extraction by deep residual u-net. **IEEE Geoscience and Remote Sensing Letters**, IEEE, v. 15, n. 5, p. 749–753, 2018.

ZHAO, T. Seismic facies classification using different deep convolutional neural networks. In: **SEG Technical Program Expanded Abstracts 2018**. [S.l.]: Society of Exploration Geophysicists, 2018. p. 2046–2050.

ZIJDENBOS, A. P. et al. Morphometric analysis of white matter lesions in mr images: method and validation. **IEEE transactions on medical imaging**, IEEE, v. 13, n. 4, p. 716–724, 1994.