

Arthur Bridi Guazzelli

**Classificação de Fácies Sísmicas por Redes
Neurais Convolucionais**

Florianópolis

2019

Arthur Bridi Guazzelli

Classificação de Fácies Sísmicas por Redes Neurais Convolucionais

Monografia submetida ao Programa de Graduação em Ciência da Computação para a obtenção do Grau de Bacharel.

Universidade Federal de Santa Catarina
Departamento de Informática e Estatística
Ciência da Computação

Orientador: Prof. Dr. Mauro Roisenberg

Florianópolis

2019

Guazzelli, Arthur Bridi

Classificação de Fácies Sísmicas por Redes Neurais Convolucionais / Arthur
Bridi Guazzelli; Orientador: Prof. Dr. Mauro Roisenberg; 2019.

67 p. : il. (algumas color.) ; 30 cm.

Trabalho de Conclusão de Curso de Graduação – Universidade Federal
de Santa Catarina, Departamento de Informática e Estatística, Ciência da
Computação, Florianópolis, 2019.

Inclui referências

1. Ciência da Computação. 2. Inteligência Artificial. 3. Deep Learning. I.
Roisenberg, Mauro. II. Universidade Federal de Santa Catarina. III. Título

Arthur Bridi Guazzelli

Classificação de Fácies Sísmicas por Redes Neurais Convolucionais

Esta Monografia foi julgada aprovada para a obtenção do Título de "Bacharel em Ciência da Computação", e aprovada em sua forma final pelo Programa de Graduação em Ciência da Computação.

Florianópolis, Data indefinida:

**José Francisco Danilo De Guadalupe
Correa Fletes**
Coordenador do Curso

Banca Examinadora:

Prof. Dr. Mauro Roisenberg
Orientador

Profa. Dra. Jerusa Marchi
Universidade Federal de Santa Catarina

Prof. Dr. Rafael de Santiago
Universidade Federal de Santa Catarina

Florianópolis
2019

Resumo

Avanços tecnológicos no processo de caracterização de reservatórios de petróleo e gás como a sísmica 3D e atributos sísmicos enriqueceram a descrição da subsuperfície realizada por especialistas. No entanto, a análise dessa grande quantidade de dados se tornou uma tarefa complexa. Como objetivo, este trabalho explora o uso de redes convolucionais na classificação de fácies sísmicas, uma das etapas que compõem a caracterização de reservatórios. Através de um método de amostragem que captura as informações espaciais dos dados sísmicos, os modelos gerados foram aplicados em dados sintéticos do reservatório Stanford VI-E e em um *benchmark* baseado no bloco F3, parte de um reservatório real. Comparando-se com outros modelos avaliados no mesmo conjunto de dados, as redes classificadoras produzidas neste trabalho obtiveram resultados similares, passando de 90% de acurácia na classificação de algumas fácies sísmicas. Apresentando também flexibilidade para o uso prático destes modelos.

Palavras-chaves: fácies sísmicas; classificação; redes convolucionais; deep learning.

Abstract

Technological advances in oil and gas reservoir characterization such as 3D seismics and seismic attributes enriched the subsurface's description made by specialists. Nevertheless, the analysis of this now huge volume of data became a complex task. This work explores the use of convolutional neural networks for seismic facies classification, one of the steps of reservoir characterization. Through a sampling method that captures spacial information of seismic data, the models produced were applied in both synthetic data of the Stanford VI-E reservoir and in a benchmark based on the F3 block, which is part of a real reservoir. Compared to other models in the same benchmark, the classifiers produced here had similar results, with over 90% class accuracy on some instances. The sampling method is also flexible to use in practical cases.

Key-words: seismic facies; classification; convolutional neural networks; deep learning.

Lista de Figuras

Figura 1 – Método sísmico marítimo.	22
Figura 2 – Classificação de fácies sísmicas em uma seção sísmica 2D.	23
Figura 3 – Subáreas da inteligência artificial.	24
Figura 4 – Arquitetura de uma RNA com três camadas.	27
Figura 5 – Estrutura de uma unidade de uma RNA.	27
Figura 6 – Função de ativação ReLU.	28
Figura 7 – Operação de convolução.	29
Figura 8 – Função de <i>max pooling</i>	30
Figura 9 – Processo de geração de imagens RGB a partir de amostras do cubo sísmico.	33
Figura 10 – Fluxograma do método proposto neste trabalho.	34
Figura 11 – Localização do bloco F3.	36
Figura 12 – Partições do conjunto de dados bloco F3.	37
Figura 13 – Curvas de aprendizagem para o conjunto Stanford VI-E	41
Figura 14 – Modelo estratigráfico do reservatório Stanford-VI.	42
Figura 15 – Exemplos amostrados do conjunto de treinamento do reservatório Stanford VI-E.	43
Figura 16 – Frequência de exemplos por classe no conjunto de treinamento.	44
Figura 17 – Frequência de exemplos por classe no conjunto de treinamento após o balanceamento.	44
Figura 18 – Matriz de confusão do resultado de classificação do conjunto Stanford VI-E.	45
Figura 19 – Comparação 3D da previsão com as fácies reais no reservatório Stanford VI-E.	46
Figura 20 – Cubo de fácies da partição Treinamento.	47
Figura 21 – Distribuição de frequência dos dados de treinamento do modelo 2.a.	48
Figura 22 – Exemplos de treinamento do bloco F3.	49
Figura 23 – Matrizes de confusão para os conjuntos de teste #1 e #2	51
Figura 24 – Resultados dos modelos de base do <i>benchmark</i> para os conjuntos Teste #1 e #2.	52

Lista de Tabelas

Tabela 1 – Arquitetura da rede utilizada para a classificação em ambos os reservatórios	40
Tabela 2 – Resultado no conjunto Stanford VI-E.	45
Tabela 3 – Resultados dos modelos na partição Teste #1.	50
Tabela 4 – Resultados dos modelos na partição Teste #2.	50
Tabela 5 – Resultados dos modelos nas partições Teste #1 e #2.	50
Tabela 6 – Resultados dos conjuntos Teste #1 e #2 com métricas do <i>benchmark</i> . .	52

Lista de Abreviaturas e Siglas

IA	Inteligência Artificial
ML	<i>Machine Learning</i>
RNA	Rede Neural Artificial
RNC	Rede Neural Convolutacional
ReLU	<i>Rectified Linear Unit</i>
PA	<i>Pixel Accuracy</i>
MCA	<i>Mean Class Accuracy</i>
FWIU	<i>Frequency Weighted Intersection over Union</i>

Sumário

1	INTRODUÇÃO	17
1.1	Objetivos	17
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	18
1.2	Método de Pesquisa	18
1.3	Estrutura do Trabalho	18
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Processo de Caracterização de Reservatórios	21
2.1.1	Aquisição Sísmica	21
2.1.2	Atributos Sísmicos	22
2.1.3	Fácies Sísmicas	23
2.2	Deep Learning	23
2.2.1	Tipos de Aprendizagem	25
2.2.2	Problemas de Classificação	26
2.2.3	Redes Neurais Artificiais	26
2.2.4	Redes Neurais Convolucionais	28
3	PROPOSTA	31
3.1	Método Proposto	31
3.2	Modelo de Rede Neural Convolucional	32
3.3	Conjunto de Dados	32
3.4	Métricas de Avaliação	34
3.4.1	Acurácia Média	34
3.4.2	F1-Score	34
3.4.3	Matriz de Confusão	35
3.5	Comparação com Trabalhos Relacionados	35
4	EXPERIMENTOS E RESULTADOS	39
4.1	Reservatório Stanford VI-E	41
4.1.1	Geração de Dados de Treinamento e Teste	42
4.1.2	Normalização e Balanceamento dos Dados	43
4.1.3	Resultados	44
4.2	Bloco F3	46
4.2.1	Geração de Dados de Treinamento	47
4.2.2	Resultados	49

5	CONCLUSÕES	53
5.1	Trabalhos Futuros	53
	REFERÊNCIAS	55
	APÊNDICE A – ARTIGO DO TCC	57

1 Introdução

A caracterização de reservatórios de petróleo e gás se beneficiou de avanços tecnológicos como a sísmica 3D e atributos sísmicos, que fornecem informações qualitativas da geometria e dos parâmetros físicos da subsuperfície. Essas tecnologias, tornaram complexa a análise dessa grande quantidade de dados disponíveis aos intérpretes (SANCEVERO, 2007). A classificação de fácies sísmicas é uma das etapas que compõem a caracterização de reservatórios. Na geologia, uma fácies sísmica é definida como um corpo rochoso com características de reflexão distintas daqueles em seu entorno (READING, 1996).

No processo de classificação de tais fácies, a abordagem não supervisionada empregada na indústria utiliza atributos sísmicos como entrada de um algoritmo de clusterização. Nesse contexto, o algoritmo de redes de Kohonen, ou *Self Organizing Maps*, teve melhores resultados (COLÉOU; POUPON; AZBEL, 2003) e atualmente é utilizado em aplicações comerciais. Todavia, abordagens como essa não resolvem todos os problemas da classificação de fácies sísmicas sem trazer suas próprias limitações e desafios. Resultados úteis dependem mais dos atributos selecionados do que o método de clusterização utilizado (BARNES; LAUGHLIN, 2002). A seleção de um bom conjunto de atributos dentre as centenas disponíveis representa um problema em questão de tamanho e dimensionalidade dos dados. Além disso, nem todo atributo pode ser relevante para a análise e muitos deles contém informações redundantes (BARNES, 2007).

Recentemente, algoritmos de *deep learning* foram propostos como alternativa para solucionar os problemas apresentados pela classificação manual e assistida—por técnicas não supervisionadas—de fácies sísmicas (ZHAO, 2018). Esses algoritmos são usados para extrair representações dos dados e realizar a classificação de fácies sísmicas de maneira automática. Este trabalho, então, propõe o desenvolvimento de um classificador de fácies sísmicas fazendo uso das técnicas de *deep learning* com o objetivo de obter um mapeamento entre dados sísmicos e valores de fácies de um reservatório.

1.1 Objetivos

1.1.1 Objetivo Geral

Implementar um classificador de fácies sísmicas empregando redes neurais convolucionais, integrando dados sísmicos 3D e dados de poços para treinamento, tendo em vista a redução de tempo e aumento da acurácia no processo de caracterização de reservatórios de petróleo e gás.

1.1.2 Objetivos Específicos

- **Estudo do processo de caracterização de reservatórios:** ter um entendimento básico das características inerentes do problema de classificação de fácies sísmicas e sua importância no contexto maior.
- **Comparar os resultados com trabalhos relacionados:** outras redes neurais classificadoras já foram propostas nesse domínio. Tem-se como objetivo comparar os resultados obtidos neste trabalho com outras implementações da literatura a fim de melhor avaliar os pontos positivos e negativos do produto deste projeto.

1.2 Método de Pesquisa

O método de pesquisa seguido neste trabalho teve como início o estudo teórico do processo de caracterização de reservatórios de petróleo e o problema de classificação de fácies sísmicas, os tipos de dados que são utilizados atualmente, e técnicas empregadas para realizar a classificação. Além disso, também cabe um estudo sobre redes neurais convolucionais e o processo de desenvolvimento de um modelo de aprendizagem de máquina, incluindo a definição de métricas de avaliação dos modelos.

Em sequência, foram escolhidas as bibliotecas utilizadas na implementação, realizada através da linguagem de programação Python. Na fase de implementação, as decisões tomadas quanto a definição das arquiteturas de redes neurais foram orientadas pelas métricas ou embasadas na literatura, a fim de obter bons resultados com os modelos.

Por fim, foram realizados testes em dados sintéticos e em dados reais a fim de obter comparações com técnicas de classificação semelhantes (WALDELAND; SOLBERG, 2017; ZHAO, 2018; YAZEED et al., 2019), e avaliar os pontos positivos e negativos da proposta implementada.

1.3 Estrutura do Trabalho

O capítulo 2 aborda alguns conhecimentos necessários para esclarecer a problemática deste trabalho, aprofundando-se nos conceitos importantes para a implementação da proposta de pesquisa.

No capítulo 3, é detalhada a abordagem escolhida para cumprir os objetivos de pesquisa, justificando as tecnologias, dados utilizados e métodos aplicados. Também são discutidos os detalhes de implementação da solução. Os problemas encontrados no processo e como foram solucionados ou contornados.

O capítulo 4 apresenta cenários de experimentos realizados sobre a implementação da proposta e a discussão de seus resultados.

Por fim, no capítulo 5, é realizada a discussões finais do trabalho acerca dos resultados obtidos, suas implicações e direcionamentos para a realização de trabalhos futuros.

2 Fundamentação Teórica

Aqui serão apresentados os conceitos que guiaram a realização deste trabalho. Primeiramente descrevendo o contexto da caracterização de reservatórios e as definições de método sísmico, atributos sísmicos, e fácies sísmicas envolvidos no processo de caracterização. Posteriormente, será discutida a motivação do uso de *deep learning* neste trabalho. Além disso, serão expostos os tipos de algoritmos de aprendizagem, as definições de problemas de classificação, redes neurais artificiais e redes neurais convolucionais.

2.1 Processo de Caracterização de Reservatórios

De acordo com Sancevero (2007), o processo de caracterização de reservatórios é uma das tarefas de maior importância no estudo de um campo petrolífero, sendo utilizada para gerar diferentes modelos da subsuperfície e fornecer uma melhor compreensão do campo explorado. Do ponto de vista econômico, a descrição correta de um reservatório melhora as estimativas de retorno das reservas e dá base às decisões de alto custo como, por exemplo, a localização de poços exploratórios.


O processo de caracterização agrega dados de diferentes fontes, escalas e métodos, como dados sísmicos, dados de poços, dados de produção, informações sobre física de rochas e modelos geológicos. Tendo como objetivo gerar modelos estáticos 3D de permeabilidade, porosidade, litologia e saturação. Esses modelos auxiliam na localização de hidrocarbonetos—petróleo e gás (SANCEVERO, 2007).

Inserido no contexto da caracterização de reservatórios, o presente trabalho foca nas informações de origem sísmica e de poços, que serão detalhadas a seguir.

2.1.1 Aquisição Sísmica

Os dados sísmicos são obtidos através do método de reflexão sísmica, no qual ondas de energia geradas artificialmente por fontes como explosivos, canhões de ar, caminhões vibradores, e outras, se propagam pela terra abaixo da superfície. Com a mudança das propriedades físicas do meio em que essas ondas se propagam, parte de sua energia é refletida e captada por instrumentos chamados geofones, ou hidrofones no caso marítimo (SANCEVERO, 2007). Na Figura 1, o processo de aquisição sísmica marítima é ilustrado. Nesse caso, as ondas de energia são geradas por um canhão de ar e as reflexões são captadas por hidrofones, puxados pelo navio através de cabos, em diferentes distâncias da fonte.

Figura 1 – Método sísmico marítimo.



Fonte: <<https://krisenergy.com/company/about-oil-and-gas/exploration/>>

O método sísmico fornece alguns parâmetros tais como: tempo de chegada das ondas; amplitude das ondas; características das ondas (relacionadas à estrutura de superfícies refletoras) e o padrão das ondas (relacionadas à estrutura local e ambiente deposicional). Destes parâmetros, em um processo manual, um geofísico extrai informações sobre a subsuperfície. Atualmente prevalece na indústria do petróleo o levantamento sísmico 3D, onde os dados representam um volume da subsuperfície.

2.1.2 Atributos Sísmicos


De acordo com Taner (2000), atributo sísmico é qualquer informação derivada do dado sísmico, seja por medidas diretas ou pela aplicação de equações e relações. Já (CHEN; SIDNEY, 1997) definem como atributo medidas específicas da geometria, cinemática, dinâmica e de relações estatísticas extraídas do dado sísmico. Por exemplo, a amplitude, frequência e taxa de variação podem ser considerados atributos sísmicos. Essas diferentes representações dos dados sísmicos dão ao intérprete uma maior capacidade de análise, o que levou a uma caracterização mais eficiente e precisa dos reservatórios (SANCEVERO, 2007).

2.1.3 Fácies Sísmicas

Reading (1996) define fácies sísmicas como unidades nas quais os parâmetros de suas reflexões, como a configuração das reflexões, a continuidade, a amplitude, a frequência, a velocidade intervalar, diferem das unidades de fácies sísmicas vizinhas. Essas unidades podem ser mapeadas para duas ou três dimensões.

A partir da delimitação da forma externa e dos parâmetros de uma região de reflexões, pode-se interpretar essa unidade de fácies sísmica no contexto do ambiente geológico a fim de realizar previsões sobre a litologia do ambiente (SANCEVERO, 2007). A Figura 2, ilustra uma classificação de fácies sobreposta (colorido) com os dados de reflexão em uma seção reservatório sintético Stanford VI-E.

Figura 2 – Classificação de fácies sísmicas em uma seção sísmica 2D.



Fonte: Autor.

2.2 Deep Learning

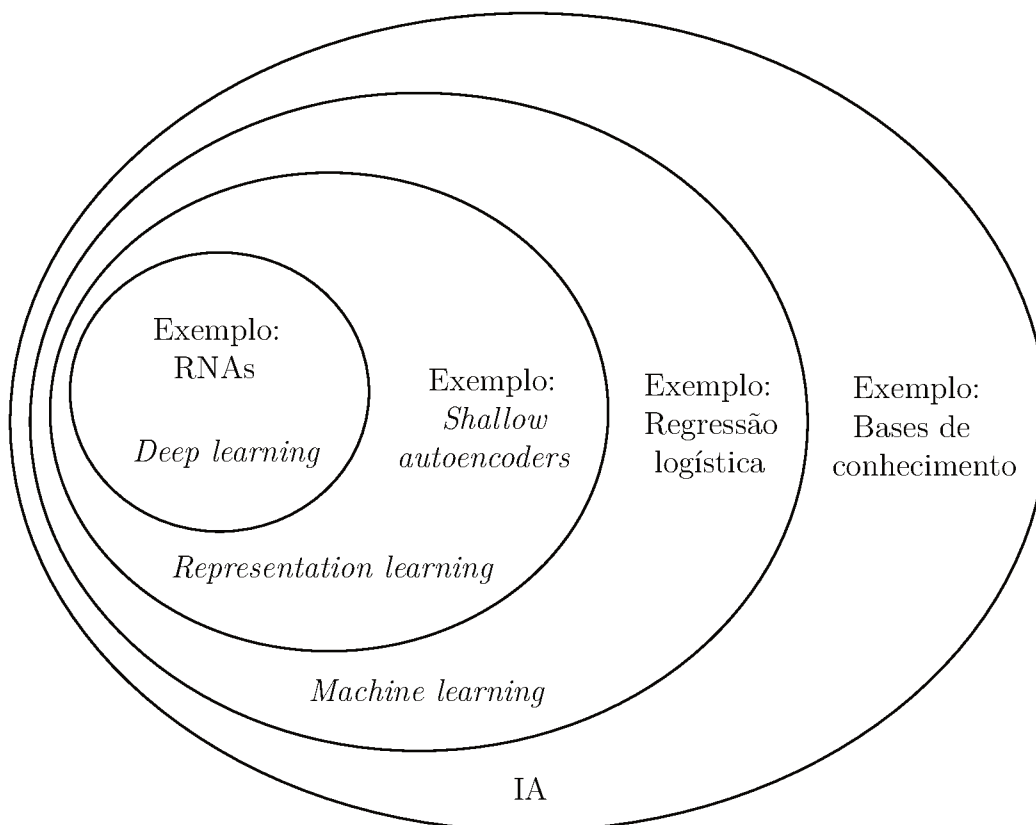
Antes de entrar no conceito de *deep learning* e suas técnicas, cabe um breve histórico da área da Inteligência Artificial (IA) para contextualizar o leitor sobre problemas que Redes Neurais Artificiais (RNA) atacam e a motivação de seu uso neste trabalho.

O campo da inteligência artificial teve sucesso inicialmente solucionando problemas que são facilmente especificados de maneira formal. O jogo de xadrez, por exemplo, possui um espaço finito de posições possíveis para as peças e essas possuem movimentos limitados.

Em 1997, o supercomputador da IBM, Deep Blue, derrotou o campeão mundial Garry Kasparov em condições de torneio (CAMPBELL; HOANE; HSU, 2002). Mas os problemas que se mostram realmente desafiadores para o campo da IA são aqueles que nós humanos conseguimos resolver de forma intuitiva de modo que temos dificuldade em expressá-los formalmente, como reconhecimento de fala ou de objetos em imagens.

Isso levou ao desenvolvimento da subáreas de IA, ilustradas na Figura 3 junto com exemplos de modelos característicos de cada uma dessas áreas. Particularmente, a área de *machine learning* (ML) é caracterizada por algoritmos de aprendizagem. Segundo Mitchell (1997), dizemos que um programa de computador aprende com a experiência E em uma tarefa T com métricas de desempenho P , se seu desempenho na tarefa T , mensurado por P , aumenta com a experiência E . Por exemplo, um programa que aprende a jogar xadrez pode melhorar seu desempenho, medido pela probabilidade de ganhar o próximo jogo, obtendo experiência jogando contra si mesmo. Entretanto, o desempenho de algoritmos mais básicos como regressão logística e *naive Bayes* depende muito da representação de seus dados de entrada. A escolha de boas características—que definem a representação dos dados—é uma tarefa difícil para muitas aplicações de ML (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 3 – Subáreas da inteligência artificial.



Fonte: adaptado de Goodfellow, Bengio e Courville (2016).

Para resolver o problema de encontrar uma boa representação dos dados de entrada, uma abordagem de ML conhecida como *deep learning*, faz uso de uma hierarquia de abstrações construídas gradualmente a partir de abstrações mais simples dos dados de entrada. No reconhecimento de imagens, por exemplo, a identificação de objetos parte de um conjunto de valores de *pixels*, onde são identificadas bordas comparando os valores de *pixels* vizinhos. Contornos e cantos podem então ser reconhecidos como conjuntos de bordas, e partes de objetos podem ser identificadas com a presença de contornos específicos. Certas partes de objetos, finalmente, ajudam a identificar o objeto contido na imagem.

Pode-se, então, traçar um paralelo com as técnicas não supervisionadas que têm sido empregadas para a classificação de fâcies, como mencionado anteriormente, a qualidade do resultado desses métodos depende, em grande parte, da escolha dos atributos sísmicos (COLÉOU; POUPON; AZBEL, 2003). Ou seja, o desafio encontra-se na representação dos dados que são usados como entrada. Com o uso de modelos de *deep learning* essas representações são extraídas do cubo sísmico em cada camada da hierarquia.

Deep learning, como uma subárea de ML, é caracterizado por algoritmos de aprendizagem que buscam otimizar uma função de erro à medida que dados são apresentados. A seguir, dois tipos de aprendizagem serão explicados, além da definição de um problema de classificação que é tema deste trabalho. Por fim, são apresentados os principais conceitos de redes neurais artificiais e Redes Neurais Convolucionais (RNC), que são os modelos de computação empregados para realizar a hierarquia de abstrações em imagens discutida acima.

2.2.1 Tipos de Aprendizagem

Algoritmos de ML são usualmente divididos em duas categorias amplas: os de aprendizagem supervisionada e de aprendizagem não-supervisionada (GOODFELLOW; BENGIO; COURVILLE, 2016).

Na aprendizagem não-supervisionada o algoritmo tem a tarefa de encontrar padrões em um conjunto de dados, sem nenhum tipo de resposta esperada sendo fornecida. Algoritmos de clusterização e redução de dimensionalidade estão nessa categoria. Os algoritmos de aprendizagem supervisionada são aqueles em que cada exemplo $x^{(i)}$ do conjunto de dados possui um rótulo, ou alvo, $y^{(i)}$ associado (MOHRI; ROSTAMIZADEH; TALWALKAR, 2012).

Durante o desenvolvimento de aplicações de aprendizagem supervisionada, os dados rotulados disponíveis são separados em três conjuntos disjuntos: dados de treinamento; dados de validação; e dados de teste. Os dados de treinamento, como o nome sugere, são utilizados durante a etapa de aprendizagem do algoritmo, é com esse conjunto que os pesos do algoritmo são ajustados. Os dados de validação fornecem uma prévia da capacidade de

generalização do algoritmo durante a etapa de treinamento, mas não são usados no ajuste dos pesos, as métricas calculadas em cima desse conjunto também podem ser utilizadas para realizar comparações entre modelos nessa etapa. Por fim, os dados de teste são uma prova final para avaliar o modelo de teste em dados que nunca foram vistos durante todo o processo de treinamento.

2.2.2 Problemas de Classificação

A tarefa de classificação está entre as mais realizadas no campo da inteligência artificial. Nela, o objetivo é especificar uma entre k classes a qual uma determinada entrada pertence. Assim, a saída do algoritmo de aprendizagem é uma função $h : \mathbb{R}^n \rightarrow \{1, \dots, k\}$. De tal modo que uma entrada x aplicada no modelo resulte em um código numérico y correspondente a uma determinada classe. (GOODFELLOW; BENGIO; COURVILLE, 2016). Um exemplo de problema de classificação é o reconhecimento de objetos, onde a entrada é uma imagem e a saída esperada é o código numérico associado ao objeto na imagem. Nessa categoria, o conjunto de dados CIFAR-10¹ fornece imagens com exemplos de 10 classes diferentes (aviões, carros, pássaros, gatos, veados, cães, sapos, cavalos, navios, e caminhões) para treinamento de algoritmos de aprendizagem.

2.2.3 Redes Neurais Artificiais

Redes neurais artificiais, mais especificamente do tipo *feedforward*, são modelos típicos de *deep learning*. A ideia básica desses modelos é aproximar uma função $f(\vec{x})$ pela composição de outras funções diferentes (GOODFELLOW; BENGIO; COURVILLE, 2016). Redes neurais levam esse nome pois são formadas por unidades, ou neurônios², conectadas entre si. Nos modelos *feedforward*, as conexões são feitas apenas em uma direção, fazendo com que a informação percorra a rede diretamente da entrada para a saída (RUSSELL; NORVIG, 2009).

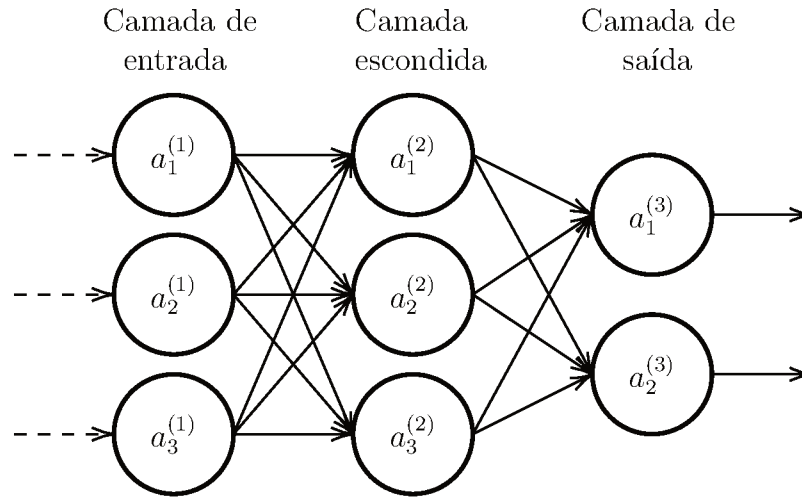
RNAs são estruturadas em camadas, nomeadas de acordo com sua posição na rede. A camada de entrada é a primeira camada da rede, e tem seus valores definidos pelos dados de entrada. No final da rede está a camada de saída. Durante a etapa de aprendizado da rede, o rótulo y dos exemplos determinam que valores devem aparecer na camada de saída. Todas as outras camadas entre a entrada e saída são chamadas de camadas escondidas. O algoritmo de aprendizagem deve decidir como utilizar essas camadas para aproximar a função $f(\vec{x})$ (GOODFELLOW; BENGIO; COURVILLE, 2016). A Figura 4

¹ O conjunto CIFAR-10 pode ser encontrado no seguinte endereço: <<https://www.cs.toronto.edu/~kriz/cifar.html>>.

² O termo “neurônio” ainda faz parte da terminologia do campo da IA por conta da inspiração biológica de seus primeiros modelos computacionais, como (MCCULLOCH; PITTS, 1943). Hoje, o interesse de pesquisas em IA foca em propriedades mais abstratas das redes e na sua capacidade de aprendizado. Modelos computacionais mais realistas de neurônios são objeto de estudo da área conhecida como neurociência computacional.

exemplifica uma rede neural com uma camada de cada tipo. Podemos ver essa rede como uma composição de funções $f(\vec{x}) = f^{(2)}(f^{(1)}(\vec{x}))$, onde $f^{(1)}$ e $f^{(2)}$ representam a camada escondida e a camada de saída, respectivamente.


Figura 4 – Arquitetura de uma RNA com três camadas.



Fonte: Autor.

A unidade, ou neurônio, é o componente mais básico das RNAs. O primeiro modelo de neurônio capaz de ser treinado com exemplos foi proposto por Rosenblatt (1958). Hoje, essas unidades são um pouco diferentes das originalmente propostas, mas, de forma geral, cada neurônio possui um vetor de entrada com pesos associados e uma função de ativação g onde b é denominado *bias* e assume valor constante 1, como mostra a Figura 5.

Figura 5 – Estrutura de uma unidade de uma RNA.




Fonte: Autor.

Para que a rede tenha uma expressividade maior, ou seja, consiga aprender funções mais complexas, a função de ativação deve ser não linear. Uma das funções de ativação mais utilizadas em redes neurais modernas é a *Rectified Linear Unit* (ReLU) (RAMA-

CHANDRAN; ZOPH; LE, 2017), ilustrada na Figura 6 e descrita pela equação:

$$g(z) = \max\{0, z\}$$

Figura 6 – Função de ativação ReLU.



Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).


2.2.4 Redes Neurais Convolucionais

Redes neurais convolucionais são um tipo especializado de RNA para processamento de dados como séries temporais e imagens. Redes convolucionais usam a operação de convolução no lugar da multiplicação de matrizes em pelo menos uma de suas camadas.

A convolução, denotada pelo símbolo $*$, é uma operação matemática entre uma entrada I e um *kernel* K . Entretanto, muitas bibliotecas de redes neurais implementam a função *cross-correlation* mantendo o nome de convolução. As duas funções são similares com a exceção que, na convolução, o *kernel* é rotacionado em relação à entrada. Tal diferença não altera o aprendizado da rede, pois o algoritmo aprenderá os valores do *kernel* nas posições apropriadas (GOODFELLOW; BENGIO; COURVILLE, 2016). A operação de *cross-correlation* para uma entrada bidimensional é definida na equação 2.1 e exemplificada na Figura 7. Os índices i e j representam a linha e coluna do resultado S , respectivamente. Os índices m e n são referentes aos valores possíveis de linha e coluna, respectivamente, do *kernel* K . Este trabalho seguirá a convenção de chamar essas duas operações de convolução.

$$S(i, j) = (I * K)(i, j) = \sum_n \sum_m I(i + m, j + n) K(m, n) \quad (2.1)$$

Figura 7 – Operação de convolução.



Fonte: adaptada de Goodfellow, Bengio e Courville (2016)

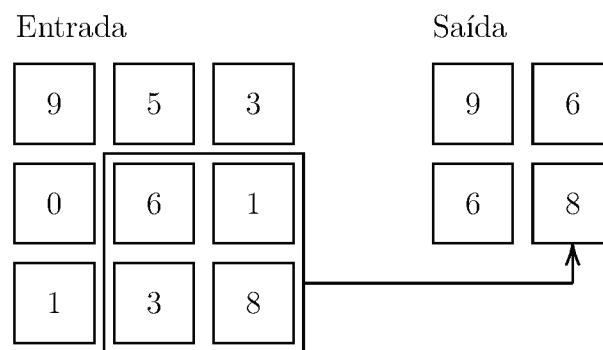
Segundo Goodfellow, Bengio e Courville (2016), a convolução em redes neurais faz uso de três ideias para melhorar o processo de aprendizagem:

- **conectividade esparsa:** quando o *kernel* é menor do que a entrada, uma unidade de uma camada não interage com todas as unidades da camada anterior. Na Figura 7, por exemplo, vemos que a unidade destacada na saída interage apenas com uma porção da entrada em contraste com a Figura 4, onde um neurônio está sempre conectado a todos os neurônios da camada anterior. Isso aumenta a eficiência da rede em termos de memória, pois menos parâmetros são usados, e tempo de processamento, por envolver menos operações;
- **compartilhamento de parâmetros:** isso se refere ao uso dos parâmetros do *kernel* em todos os elementos da entrada (com possíveis exceções nas bordas). Na Figura 7, todos os elementos da saída utilizam os mesmos parâmetros do *kernel*, enquanto uma rede neural tradicional teria um conjunto de parâmetros exclusivo para cada cada neurônio;

- **representações equivariantes:** a convolução tem a propriedade de ser equivariante à translação devido ao modo que os parâmetros da rede são compartilhados. Uma função $f(x)$ é equivariante a uma função $g(x)$ se $f(g(x)) = g(f(x))$. No caso do processamento de imagens, essa propriedade é útil pois a convolução cria um mapa de onde certas características aparecem na imagem. Se o objeto aparecer em diferentes posições da imagem, esse mapeamento acompanhará o deslocamento do objeto.

Outra técnica empregada em redes convolucionais é a operação de *pooling*, que atua como um sumarizador de informação. Diferentes funções de *pooling* podem ser utilizadas, mas um efeito em comum dessas funções é a invariância a pequenas translações na entrada. Uma das funções mais comumente utilizadas nesse tipo de operação é a *max pooling* (ZHOU; CHELLAPPA, 1988), que retorna o valor máximo de uma região retangular. A Figura 8 exemplifica essa operação sendo aplicada em uma entrada de tamanho 3x3 utilizando uma janela quadrada de tamanho 2 e passos de largura 1. A saída resultante dessa configuração tem tamanho 2x2.

Figura 8 – Função de *max pooling*.



Fonte: Autor.

Em suma, este capítulo apresentou os principais conceitos relacionados ao domínio de classificação de fácies sísmicas e também das características presentes em RNCs, justificando sua escolha como classificador. A seguir, esse conhecimento teórico será amarrado na apresentação da proposta deste trabalho, focando na utilização dos dados de reservatório para realizar o treinamento das redes classificadoras e sua previsão após treinadas.

3 Proposta

Neste capítulo, são detalhados como os conceitos teóricos da seção anterior são colocados em prática na elaboração do método proposto. Em primeiro momento, são discutidas as dificuldades encontradas nas aplicações de *deep learning* em trabalhos similares e a ideia utilizada por este trabalho para tentar contorná-las. Alguns detalhes da implementação, tais como linguagem e bibliotecas, são explicitados em seguida. Depois, o conjunto de dados utilizados pelo método é explicado em termos de formato e amostragem. Por fim, são apresentadas as métricas para avaliação dos modelos produzidos e o *benchmark* que servirá para comparação dos resultados com implementações de diferentes autores.

3.1 Método Proposto

Como dito no capítulo anterior, dados sísmicos são obtidos através medidas indiretas da subsuperfície e sua interpretação para fácies não é um problema trivial, além disso, o resultado da interpretação pode variar de acordo com o especialista. Isso introduz um problema para aplicações de aprendizagem supervisionada com *deep learning*, pois essas dependem de grandes quantidades de dados rotulados. Esse trabalho propõe utilizar dados sísmicos e de poços perfurados a fim de tirar vantagem das especificidades de cada método de amostragem. A sísmica cobre grandes áreas do reservatório com custo relativamente baixo dentro do processo de caracterização, porém seus dados são esparsos e medidos indiretamente. Em alternativa, dados de poços são medidos diretamente durante a perfuração do solo. Possibilitando um maior grau de detalhe e maior frequência de amostragem, porém a um custo elevado. Assim, a classificação manual de fácies em poços pode ser feita com maior precisão por especialistas. Isso é possível pois o conceito de correlação espacial está presente devido a natureza dos problemas geofísicos e permite que previsões sejam realizadas com base em observações realizadas em outras partes do reservatório (DOYEN, 2007).

O uso de redes convolucionais para classificação de fácies a partir de dados sísmicos já foi alvo de diversos estudos como (ZHAO, 2018; WALDELAND; SOLBERG, 2017). Esse tipo de rede neural gerou grandes avanços na área da visão computacional devido a suas vantagens sobre redes neurais tradicionais, discutidas no capítulo anterior. No contexto da caracterização de reservatórios, a identificação de fácies é realizada por intérpretes que fazem uso de imagens sísmicas 2D extraídas de seções verticais do cubo sísmico denominadas *inlines* e *crosslines*, dependendo da direção da seção. Além do dado sísmico original, os intérpretes utilizam os atributos sísmicos para obter diferentes re-

apresentações do cenário a fim de facilitar a classificação. Os trabalhos de Zhao (2018) e Waldeland e Solberg (2017), citados acima, assim como a classificação visual realizada pelos intérpretes, utiliza apenas as seções verticais do dado sísmico, deixando de lado as correlações espaciais completas do dado tridimensional. Nota-se um paralelo entre a área de visão computacional e a classificação de fácies sísmicas, no entanto, Zhao (2018) pontua alguns desafios próprios da última área como a escassez de dados para treinamento, a incerteza inerente dos dados sísmicos e a natureza da interpretação manual desses dados que insere ruído no conjunto de treinamento.

Portanto, a abordagem escolhida nesse trabalho é de utilizar as classificações de fácies em poços como alvo do algoritmo de classificação com o intuito de reduzir o ruído de treinamento e empregar os dados sísmicos tridimensionais na vizinhança da área que será classificada como entrada do algoritmo, tirando proveito da correlação espacial em todas as dimensões. Por consequência, o treinamento da rede é condicionado às regiões do reservatório com poços já perfurados, mas a classificação de fácies realizada pela rede após o treinamento pode ser aplicada em toda extensão da sísmica. A escolha de redes convolucionais como classificador se dá pela sua excelente capacidade de reconhecer e abstrair padrões espaciais dos dados de entrada, conforme apresentado na Subseção 2.2.

3.2 Modelo de Rede Neural Convolutacional

Como classificador, é utilizada uma rede convolutacional 2D—o mesmo tipo empregado na classificação de imagens como no conjunto de dados ImageNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). A linguagem de programação Python foi utilizada para a implementação da proposta. As bibliotecas usadas foram: Keras, para definição, treinamento, e teste dos modelos de redes convolucionais; Tensorflow como *backend* da biblioteca Keras; Matplotlib e K3D para visualização de dados e resultados. O código produzido durante este trabalho se encontra no repositório do GitHub no endereço: <<https://github.com/thurbridi/cnn-facies-classifier>>.

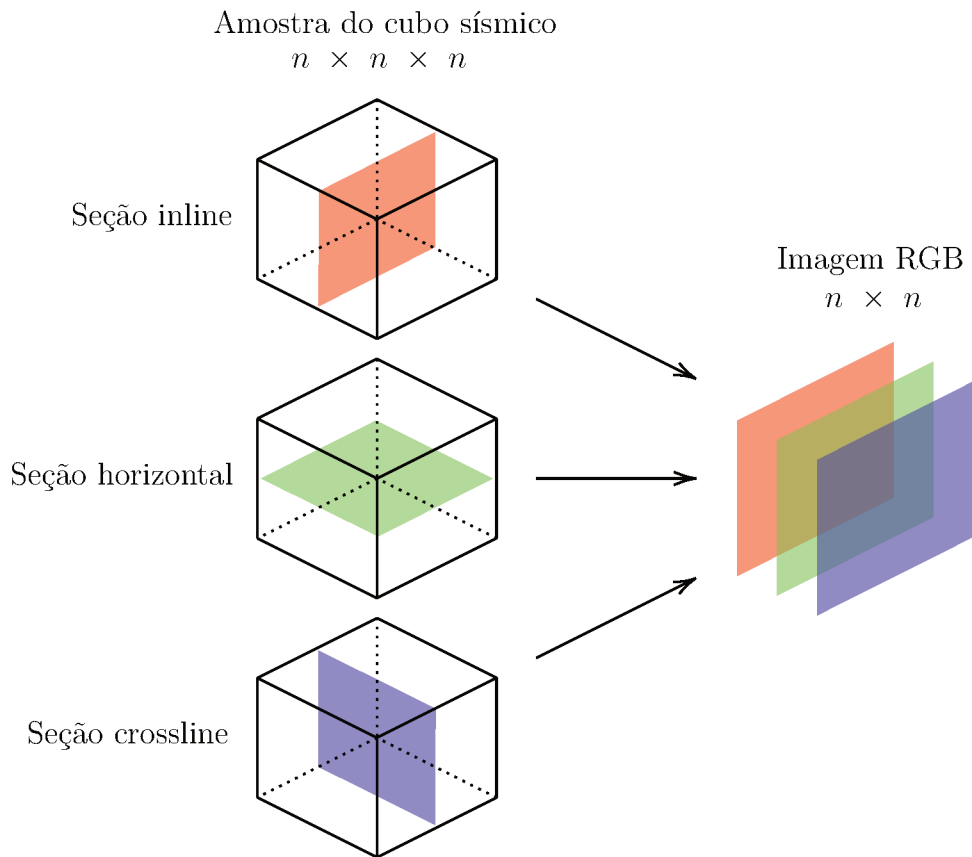
3.3 Conjunto de Dados

Os dados sísmicos são normalmente disponibilizados como um volume de valores de reflexão das ondas de energia originadas pela fonte durante a aquisição sísmica¹. Denomina-se esse volume como cubo sísmico, apesar de não haver nenhuma imposição que suas dimensões tenham tamanhos iguais.

¹ Os dados obtidos no método sísmico ainda passam por uma série de processamentos a fim de reduzir o ruído das medições e descartar reflexões irrelevantes ao reservatório. Essa etapa é chamada de processamento sísmico mas não cabe o seu detalhamento no escopo desse trabalho.

Para cada exemplo usado como entrada da rede é feita uma subamostragem do cubo sísmico para um cubo de dimensões $n \times n \times n$. O objetivo da classificação é o ponto central dessa amostra, ou seja, queremos identificar a qual fácies esse ponto central pertence. O tamanho escolhido para amostragem impõe uma restrição espacial para a rede, já que o aprendizado é realizado com base em exemplos individualmente. Como o modelo utiliza a convolução 2D, é preciso transformar as informações do cubo amostrado para que se adéquem ao formato bidimensional que alimenta o modelo. O objetivo é realizar essa transformação sem perder as correlações espaciais nas três dimensões do cubo e, para isso, são extraídas três seções passando pelo centro do cubo, uma para cada eixo. Essas seções são então empilhadas no formato de uma imagem RGB, com cada seção assumindo os valores de um dos canais de cor. Esse processo é ilustrado na Figura 9.

Figura 9 – Processo de geração de imagens RGB a partir de amostras do cubo sísmico.

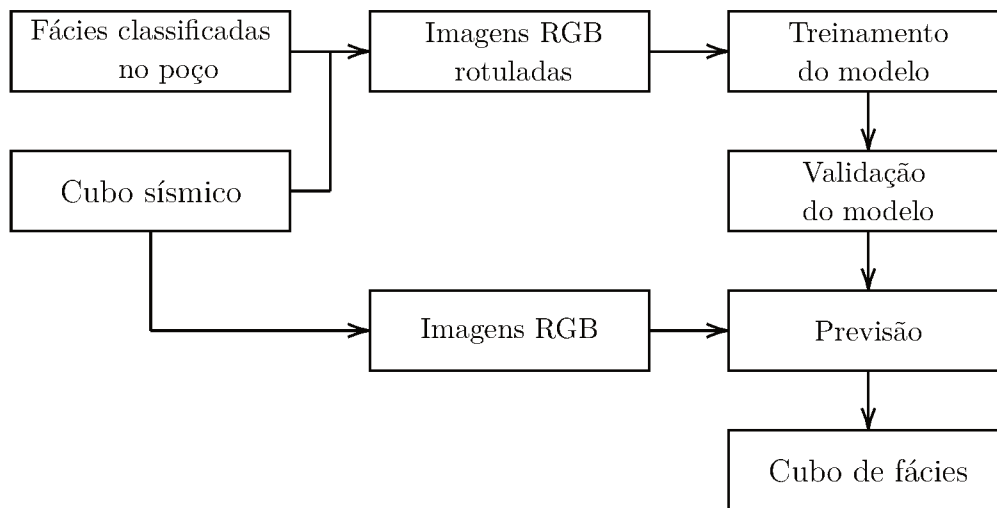


Fonte: Autor.

No caso dos dados usados para treinamento e validação da rede, cada exemplo deve estar associado a um rótulo que identifique a saída esperada. No método aqui proposto, os rótulos de fácies são provenientes das informações de poços, que podem ser visualizados como uma linha, aproximadamente vertical, que atravessa o cubo sísmico. Para cada um dos valores de fácies classificadas no poço, amostramos do cubo sísmico a região em volta

do valor, ou seja, deslizamos um cubo centrado ao longo da linha do poço que atravessa os dados sísmicos, realizando o processo de amostragem descrito acima e associando os valores de fácies classificadas. Então, a utilização desses dados, do treinamento até o uso da rede para previsão do cubo de fácies, pode ser visto de maneira geral na Figura 10.

Figura 10 – Fluxograma do método proposto neste trabalho.



3.4 Métricas de Avaliação

Para avaliar o desempenho dos classificadores durante e após o treinamento, foram definidas três métricas: acurácia média, *F1-Score* e a matriz de confusão. As fórmulas foram retiradas de Sokolova e Lapalme (2009) para classificação multiclasse, considerando classes C_1, \dots, C_l , onde tp_i é o número verdadeiros positivos de C_i , fp_i o número falsos positivos, tn_i o número de verdadeiros negativos e fn_i o número de falsos negativos.

3.4.1 Acurácia Média

A acurácia média (equação 3.1) é uma métrica da efetividade média entre classes alvo do classificador, ou seja, o somatório das acurácias de cada classe dividido pelo número de classes.

$$MA = \frac{\sum_{i=1}^l \frac{tp_i + tn_i}{tp_i + tn_i + fp_i + fn_i}}{l} \quad (3.1)$$

3.4.2 F1-Score

A métrica F1-Score (equação 3.4) é uma média harmônica entre outras duas métricas chamadas *precision* e *recall*, definidas abaixo nas equações 3.2 e 3.3, respectivamente. *Precision* é a fração de exemplos relevantes entre todos os exemplos que foram previstos

como pertencentes de uma classe. Enquanto que *recall* é fração de exemplos relevantes dentre todos os exemplos que de fato pertencem a uma classe.

O índice M representa o cálculo da média macro dessas grandezas, em outras palavras, a métrica é calculada para cada classe individualmente e então é feita a média entre as classes.

$$precision_M = \frac{\sum_{i=1}^l \frac{tp_i}{tp_i + fp_i}}{l} \quad (3.2)$$

$$recall_M = \frac{\sum_{i=1}^l \frac{tp_i}{tp_i + fn_i}}{l} \quad (3.3)$$

$$F_{1M} = 2 \cdot \frac{precision_M \cdot recall_M}{precision_M + recall_M} \quad (3.4)$$

3.4.3 Matriz de Confusão

Para o caso de classificação binária, a matriz de confusão é definida como:

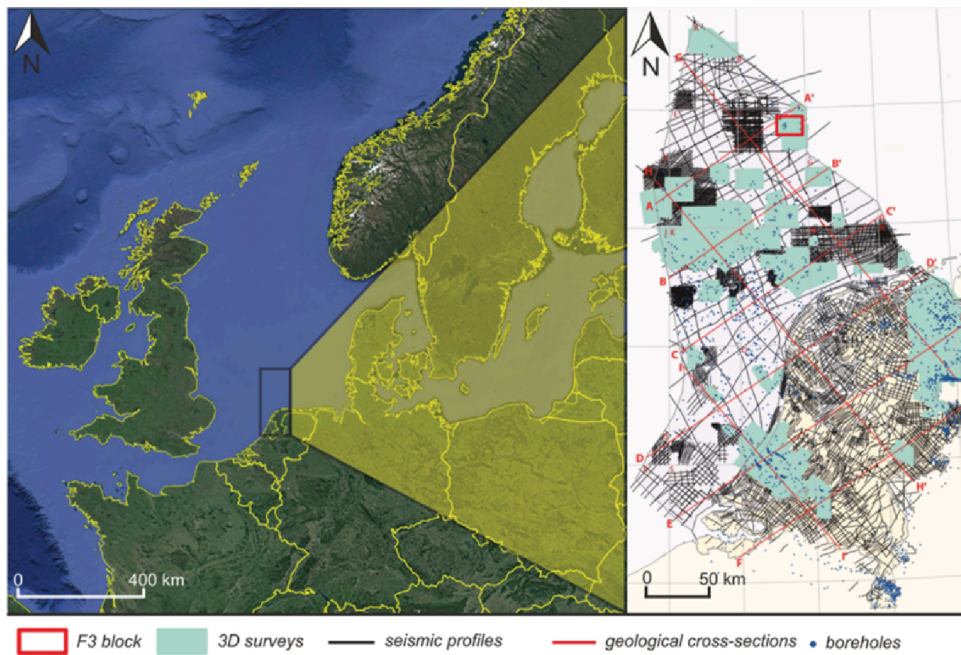
$$\begin{bmatrix} tp & fn \\ fp & tn \end{bmatrix}$$

Na classificação multiclasse, cada linha da matriz corresponde a classe verdadeira e cada coluna a classe prevista pelo classificador. Um elemento na posição (i, j) da matriz representa o número de exemplos pertencentes à classe i que foram classificados como pertencentes a classe j . Exemplos da matriz de confusão multiclasse são mostrados na seção 4, porém cada elemento (i, j) é normalizado pelo número de exemplos pertencentes à classe i .

3.5 Comparação com Trabalhos Relacionados

Como objetivo deste trabalho, foi colocado a comparação dos resultados com trabalhos relacionados. Para tal, será usado o *benchmark* proposto por (YAZEED et al., 2019) que é baseado no bloco F3, localizado na costa dos Países Baixos (ver Figura 11). A utilização de um *benchmark* como esse permite comparações mais diretas e quantitativas entre os métodos e seus resultados.

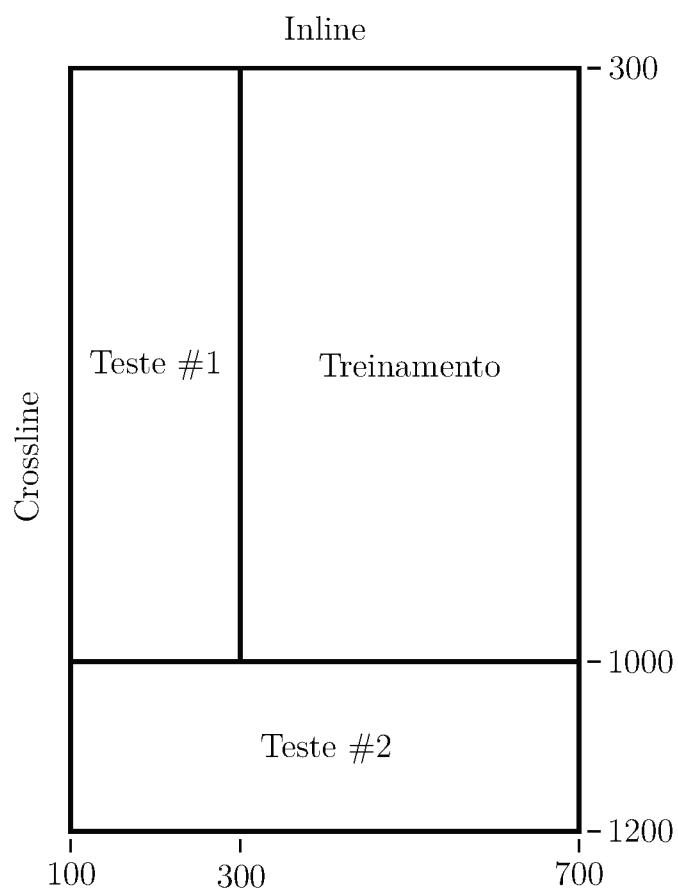
Figura 11 – Localização do bloco F3.



Fonte: Yazeed et al. (2019)

No trabalho citado acima, é gerado um modelo 3D de fácies de uma região do bloco F3, esse modelo e o cubo sísmico da mesma região foram então particionados em três conjuntos distintos: dois para teste de modelos e um para dados de treinamento. O conjunto Treinamento é formado pelos *inlines* [300, 700] e *crosslines* [300, 1000], o conjunto Teste #1 consiste dos *inlines* [100, 299] e *crosslines* [300, 700], o conjunto Teste #2 dos *inlines* [100, 700] e *crosslines* [1001, 1200], ilustrados na Figura 12.

Figura 12 – Partições do conjunto de dados bloco F3.



Fonte: Autor.

Além dos conjuntos de dados, o *benchmark* apresenta dois métodos de classificação implementados por três redes cada um, que são utilizados como patamar. Todos os modelos têm a mesma arquitetura, otimizador, e hiperparâmetros, mas diferem no treinamento e na forma como são aplicados para realizar as previsões.

4 Experimentos e Resultados

Neste capítulo, são detalhados os cenários usados para a realização dos experimentos e os passos que foram dados para alcançar os resultados apresentados. Dois cenários distintos foram empregados: o reservatório sintético Stanford VI-E e o bloco F3, localizado no Mar do Norte próximo aos Países Baixos.

Ao final, foram avaliados 5 modelos, um no conjunto de dados Stanford VI-E e quatro no conjunto do bloco F3. Todos os modelos possuem a mesma arquitetura da Tabela 1 (com exceção das camadas de entrada e saída, que dependem do tamanho da imagem de entrada e a quantidade de classes do problema) e configurações de treinamento. Entretanto, eles divergem nos dados de treinamento em tamanho da entrada e a forma como os dados foram amostrados. A seguir, é detalhado cada um dos modelos, os modelos de número 2 foram treinados para o bloco F3, enquanto o modelo 1.a foi treinado para o reservatório Stanford VI-E.

- **Modelo 1.a:** Foi treinado para o reservatório Stanford VI-E, utilizando o método de amostragem por poços como explicado no Capítulo 3;
- **Modelo 2.a:** Utiliza o método de amostragem por poços, aqui foram usadas as localizações de poços reais do bloco F3, definidas por *inline* e *crossline* do volume, somando seis poços reais e um poço adicional imaginário para obter exemplos de uma classe não representada nos outros seis. A rede foi treinada com imagens de tamanho 32×32 ;
- **Modelo 2.b:** Treinado com todos os dados da partição Treinamento do bloco F3. Usando imagens de tamanho 32×32 ;
- **Modelo 2.c:** Também utiliza todos os dados da partição de treinamento, porém com imagens de tamanho 48×48 ;
- **Modelo 2.d:** Também faz uso de todos os dados de treinamento, treinada com imagens 64×64


A ideia dos modelos 2.b-d é não restringir a quantidade de dados de treinamento quando comparadas às redes do *benchmark*.

Tabela 1 – Arquitetura da rede utilizada para a classificação em ambos os reservatórios

Camada	Tipo	Unidades	Filtros	Kernel
1	Conv 2D Ativação (ReLU)	–	32	7×7
2	Max Pooling	–	–	2×2
3	Dropout	–	–	–
4	Conv 2D Ativação (ReLU)	–	64	5×5
5	Max Pooling	–	–	2×2
6	Dropout	–	–	–
7	Conv 2D Ativação (ReLU)	–	128	3×3
8	Max Pooling	–	–	2×2
9	Dropout	–	–	–
10	Flatten	–	–	–
11	Dense Ativação (ReLU)	200	–	–
12	Dense Ativação (SoftMax)	4 (Stanford VI-E) ou 6 (Bloco F3)	–	–

A modelagem da rede convolucional nestes experimentos se deu através de um processo iterativo utilizando os dados do reservatório Stanford VI-E. Os hiperparâmetros do modelo (quantidade de camadas, quantidade de filtros, tamanho da janela de convolução e pooling) foram ajustados manualmente com base na análise das curvas de aprendizagem (Figura 13) e as outras métricas definidas anteriormente, como o F1-Score. O treinamento da rede para após a função de custo do conjunto de validação convergir, ou passar a aumentar em três iterações seguidas. A arquitetura final usada nestes experimentos foi apresentada na Tabela 1. A seguir, os cenários de teste serão apresentados.

Figura 13 – Curvas de aprendizagem para o conjunto Stanford VI-E



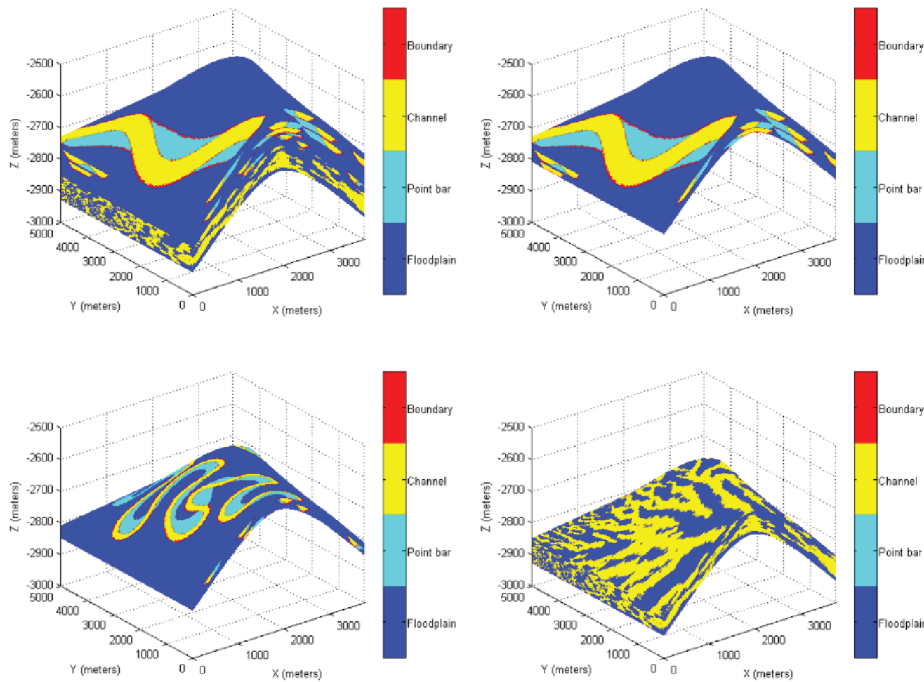
Fonte: Autor.

4.1 Reservatório Stanford VI-E

O reservatório Stanford VI-E (LEE; MUKERJI, 2012) é um modelo sintético de reservatório criado com o objetivo de testar algoritmos de modelagem, caracterização, e produção de reservatórios. É um conjunto de dados extenso com mais de 6 milhões de células contendo propriedades petrofísicas e atributos sísmicos. Os dados são disponibilizados em um volume de tamanho $150 \times 200 \times 200$, as células tem dimensões 25m nos eixos horizontais x e y e 1m no eixo vertical z . Portanto, o reservatório tem uma extensão de 3.750m na direção leste-oeste, 5.000m na direção norte-sul e 200m de profundidade.

O modelo estratigráfico do reservatório foi construído com base em um sistema de canais fluviais e é separado em três camadas com padrões de canais diferentes: (1) camada de canais delta; (2) camada de canais meandros; (3) camada de canais sinuosos. As camadas 1 e 2 são compostas por quatro fácies: *floodplain* (depósitos de argila), *pointbar* (depósitos de areia que ocorrem ao longo das bordas convexas internas), *channel* (depósitos de areia), e *boundary* (borda de argila). A camada três contém apenas as fácies *floodplain* e *channel*. Este experimento faz uso apenas das camadas 1 e 2. A Figura 14 ilustra o reservatório completo (canto superior esquerdo) e as camadas 1, 2 e 3 (superior direito, inferior esquerdo e inferior direito, respectivamente).

Figura 14 – Modelo estratigráfico do reservatório Stanford-VI.



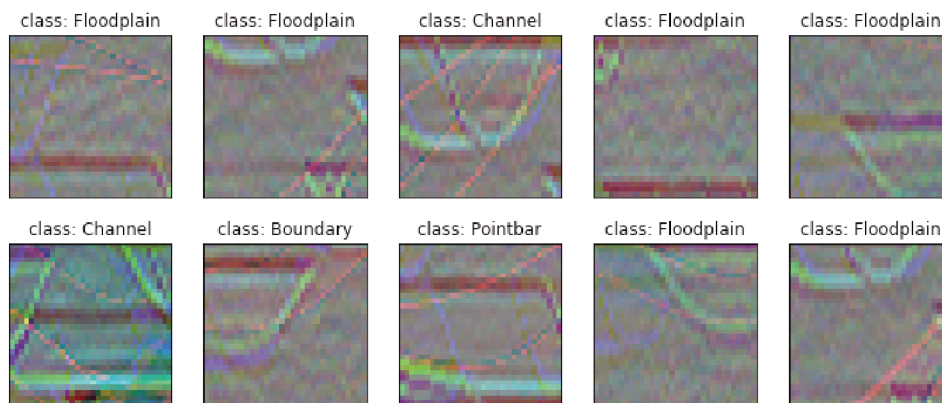
Fonte: Lee e Mukerji (2012)

O reservatório Stanford VI-E originalmente não possui dados de reflexão sísmica, necessários para alimentar o método proposto anteriormente. Portanto, foi calculada uma resposta sísmica baseada nas propriedades de impedância presente no conjunto de dados. É importante notar que essa sísmica calculada diretamente de uma propriedade da rocha tem menos ruído do que um dado real obtido pelo método sísmico.

4.1.1 Geração de Dados de Treinamento e Teste

Antes de realizar o processo de amostragem e geração de imagens de treinamento, neste caso, é preciso criar poços imaginários para impor as restrições práticas do método proposto, visto que não são definidos poços no Stanford VI-E. Para tanto, foram escolhidas 10 posições x e y aleatórias do cubo sísmico, cada uma representando a posição de um poço. Percorrendo o eixo z nessas posições, são amostrados, do volume sísmico, cubos de tamanho $32 \times 32 \times 32$. O rótulo para cada uma dessas amostras é extraído do volume de fácies do reservatório na posição correspondente ao centro da amostra. Cada uma dessas amostras é então convertida para uma imagem RGB, seguindo o método explicado no capítulo anterior, e então armazenada em um conjunto de treinamento. Na Figura 15, dez imagens de treinamento resultantes do processo aqui descrito são representadas cada qual com seu rótulo.

Figura 15 – Exemplos amostrados do conjunto de treinamento do reservatório Stanford VI-E.



Fonte: Autor.

Neste experimento, foi utilizado todo o cubo sísmico como conjunto de teste. Para isso, repete-se o processo de amostragem acima, sem as restrições de poços. Logo, são amostrados, rotulados, e transformados em imagens, cubos $32 \times 32 \times 32$ de todas as posições possíveis do volume sísmico. O conjunto de teste permite avaliar a capacidade de generalização do modelo treinado. Ou seja, quão bem a rede classifica exemplos que não foram vistos anteriormente. Entretanto, como os dados de treinamento (880 exemplos) representam apenas uma pequena fração dos dados de teste (1.769.768 exemplos), os casos em que os dois conjuntos se sobrepõe não foram removidos dos dados de teste.

As fácies sísmicas foram mapeadas para classes do problema de classificação atribuindo um código numérico para cada uma:


- *floodplain*: classe 0;
- *pointbar*: classe 1;
- *channel*: classe 2;
- *boundary*: classe 3.

4.1.2 Normalização e Balanceamento dos Dados

Ao analisar o conjunto de dados de treinamento (Figura 16), nota-se que a distribuição de exemplos favorece a classe 0 (*floodplain*), o que é esperado tendo como base as estruturas do reservatório (Figura 14). Todavia, a aprendizagem de classes desbalanceadas é um problema conhecido na área de *machine learning*. He e Garcia (2009) apresentam uma revisão do então estado da arte das soluções para esse problema. Neste experimento, a abordagem escolhida foi a geração de dados sintéticos através do algoritmo *Random*

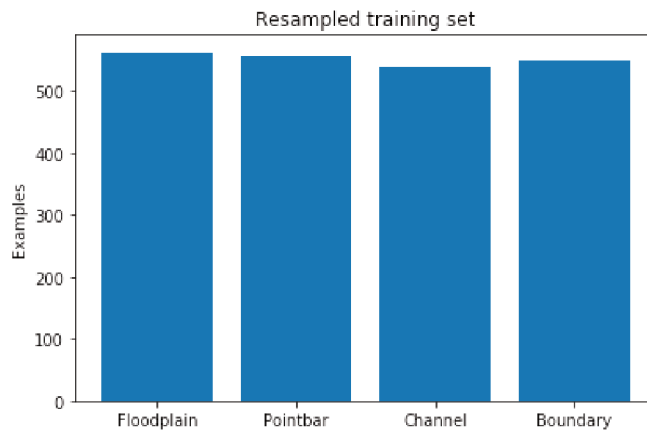
Oversampling que repete aleatoriamente exemplos das classes menos representadas. Após o balanceamento, os valores de brilho de cada canal RGB foram normalizados para o intervalo $[0, 1]$ e 20% dos dados foram reservados para o conjunto de validação. A distribuição de classes resultante pode ser vista na Figura 17.

Figura 16 – Frequência de exemplos por classe no conjunto de treinamento.



Fonte: Autor.

Figura 17 – Frequência de exemplos por classe no conjunto de treinamento após o balanceamento.



Fonte: Autor.

4.1.3 Resultados

As métricas e resultados que serão aqui discutidos são referentes ao conjunto de teste do reservatório Stanford VI-E, ou seja, toda extensão do cubo sísmico calculado a partir dos dados sintéticos do reservatório.

Após o treinamento do modelo apresentado, foram calculadas as métricas tratadas no Capítulo 3 expostas na Tabela 2. O modelo apresentou acurácia média de 0.89 que


significa uma alta taxa de verdadeiros positivos e verdadeiros negativos entre as classes. O valor de $precision_M$ indica que, em média, 60% dos pontos classificados como uma determinada fácies foram previstos corretamente. Já o valor do $recall_M$ indica que, em média, 61% dos pontos de uma fácies são classificados corretamente.

Tabela 2 – Resultado no conjunto Stanford VI-E.

Modelo	Acurácia média	$Precision_M$	$Recall_M$	$F1-Score_M$
1.a	0.8903	0.6000	0.6119	0.6027

Com a matriz de confusão, presente na Figura 18, podemos identificar as classes nas quais a rede teve maior dificuldade em aprender. Nota-se que, enquanto a classe 0 teve 93% de previsões corretas, existe grande mistura entre as classes 1, 2 e 3. No caso da confusão entre as classes 1 e 2, Lee e Mukerji (2012) explica que as duas classes são ambas areias e seus valores de impedância são muito parecidos e, portanto, suas respostas sísmicas também devem ser similares. O desempenho ruim da classe 3 pode estar relacionado a sua baixa frequência nos dados de treinamento, assim como a classe 1. É importante ressaltar que o balanceamento dos dados realizado não introduz novas informações no treinamento da rede e portanto não corrige a deficiência da amostragem original. O balanceamento apenas equilibra as métricas utilizadas durante a etapa de treinamento e validação, dando a mesma importância para todas as classes.

Figura 18 – Matriz de confusão do resultado de classificação do conjunto Stanford VI-E.




Fonte: Autor.

A Figura 19 apresenta o resultado da previsão da rede (esquerda) comparado com o modelo original (direita) nas duas primeiras camadas do reservatório Stanford VI-E.

Nessa figura, a classe 0 (*floodplain*) está transparente para destacar as estruturas fluviais do reservatório. As classes 1, 2 e 3 estão representadas pelas cores azul, verde e amarela, nessa ordem. Com a visualização 3D, é interessante notar que a classe 3, apesar da baixa precisão na matriz de confusão, ainda tem parte de sua estrutura recuperada dada sua ocorrência em finas camadas apenas nas bordas entre as classes. Visualmente, o resultado da rede também parece piorar na segunda camada do reservatório, onde os canais se tornam mais rasos e com curvas mais acentuadas.

Figura 19 – Comparação 3D da previsão com as fácies reais no reservatório Stanford VI-E.



Fonte: Autor.

Apesar de apresentar resultados animadores considerando a pouca quantidade de dados de treinamento, os dados sintéticos do reservatório não apresentam o mesmo ruído que os dados reais e a localização de poços teve que ser assumida. A seguir são apresentados os experimentos realizados nos dados reais do Mar do Norte.

4.2 Bloco F3

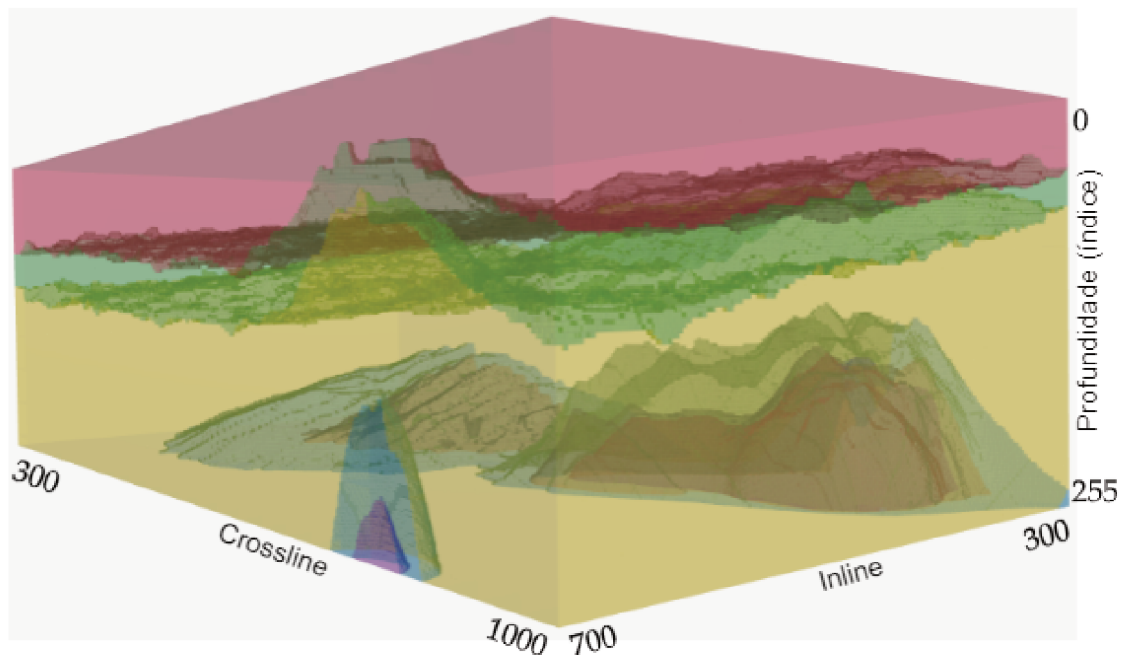
Localizado na costa dos Países Baixos, o bloco F3 possui dimensões $16\text{km} \times 24\text{km}$ e foi mapeado utilizando o método sísmico 3D para a exploração de petróleo e gás na região. No *benchmark* de Yazeed et al. (2019), parte do bloco F3 é processada, onde foram separadas, ao final do trabalho, 6 classes de fácies.

0. **Upper North:** *claystone* e arenito do Mioceno até o Quaternário.
1. **Middle North:** areias, arenitos, e *claystones* do Paleoceno até Mioceno;

2. **Lower North**: mesma constituição da classe *Middle North*;
3. **Chalk/Rijnland**: carbonatos do Cretáceo Superior e Paleoceno; formações de argila com arenitos do Cretáceo Superior;
4. **Scruff**: *claystones* do Jurássico Superior e Cretáceo Inferior;
5. **Zechstein**: evaporitos e carbonatos do Zechstein;

As classes identificadas podem ser visualizadas na Figura 20, com a fácies *Upper North* em vermelho, *Middle North* em verde, *Lower North* em amarelo, *Chalk/Rijnland* em azul, e a classe *Zechstein* em roxo.

Figura 20 – Cubo de fácies da partição Treinamento.



Fonte: Autor.

4.2.1 Geração de Dados de Treinamento

Para a geração do conjunto de treinamento e validação no bloco F3, foram seguidos dois caminhos diferentes: um focando na proposta deste trabalho de utilizar apenas as informações de poços; outro utilizando todos os dados disponíveis da partição de treinamento para melhor comparar os resultados com o *benchmark* em questão.

Na amostragem através de poços, foram utilizadas as localizações de poços reais do bloco F3, entretanto, os poços presentes na partição de treinamento são concentrados em uma pequena área. Devido a isso, um poço adicional foi assumido para incluir exemplos da classe *Zechstein* no treinamento. As localizações usadas estão listadas abaixo pelo seu *inline* e *crossline*, respectivamente:

1. Poço 'F02-01': (362, 336)
2. Poço 'F03-03': (318, 460)
3. Poço 'F03-05-S1': (452, 455)
4. Poço 'F03-06': (426, 391)
5. Poço 'F03-FB-101': (353, 430)
6. Poço 'F03-FB-106': (356, 429)
7. Poço adicional: (350, 900)

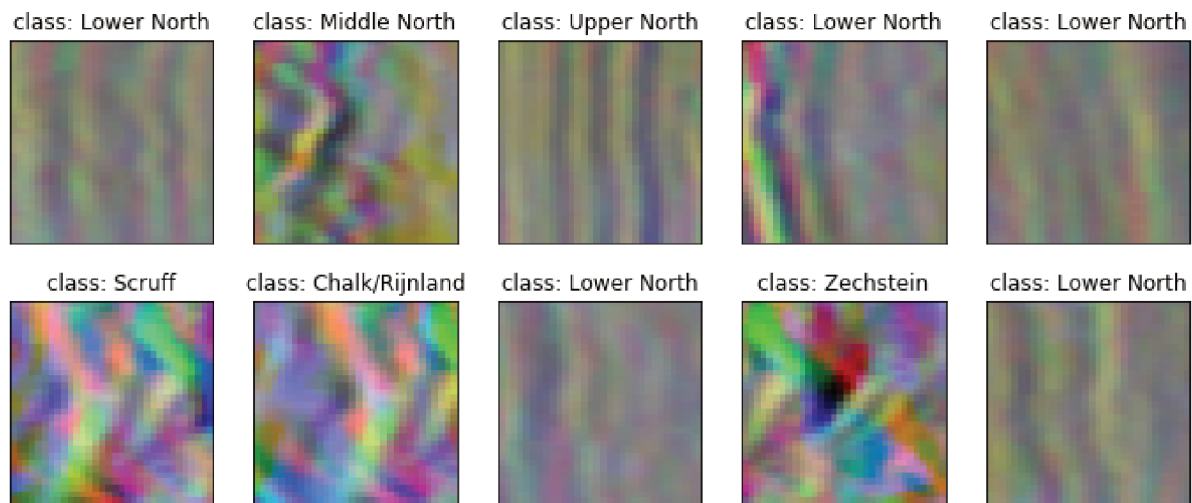
A distribuição de frequência das classes obtida está ilustrada na Figura 21. Como esperado, as classes são desbalanceadas. Logo, a mesma abordagem tomada no experimento do conjunto Stanford VI-E foi utilizada e o conjunto foi balanceado e normalizado antes do treinamento. Alguns exemplos obtidos nessa amostragem são ilustrados na Figura 22.

Figura 21 – Distribuição de frequência dos dados de treinamento do modelo 2.a.



Fonte: Autor.

Figura 22 – Exemplos de treinamento do bloco F3.



Fonte: Autor.

Para os modelos 2.b-d, a amostragem foi realizada em todo o cubo de treinamento. Devido a enorme quantidade de exemplos, foi impraticável salvar e carregar todos os exemplos em memória. Isso acontece pois imagens próximas criam uma redundância de informação, aumentando drasticamente o uso de memória comparado ao cubo original. Para resolver esse problema, implementou-se a geração e carregamento dinâmico de exemplos para o treinamento e previsão da rede, através da biblioteca Keras. Desse modo, permanecem em memória apenas os exemplos sendo processados no *batch* atual do treinamento ou previsão.

4.2.2 Resultados

Após o treinamento dos modelos, os cubos das partições Teste #1 e #2 foram recriados com as previsões de cada um dos modelos, totalizando oito novos cubos. As métricas propostas neste trabalho foram calculadas em comparação com cada cubo de teste e também na união dos dois. Os resultados são apresentados nas Tabelas 3, 4 e 5.

Nessas tabelas, é evidente que o modelo 2.a teve um desempenho pior do que foi visto no reservatório Stanford VI-E. Isso já era esperado pois o dado real é mais ruidoso, no entanto, outras características do reservatório podem ter influenciado o resultado já que os dois reservatórios têm formações de naturezas diferentes. Nos resultados dos modelos 2.b até 2.d, podemos analisar os efeitos do tamanho da imagem de entrada da rede (logo, do tamanho do cubo de amostragem). Nesses modelos, os resultados variam de formas diferentes dependendo do conjunto de teste. Yazeed et al. (2019) explica que na partição Teste #2 existe um diapiro (acidente geológico associados ao levantamento e erosão de

camadas) da classe *Zechstein*, uma estrutura não presente em nenhuma outra partição. Ao analisar os resultados na união dos conjuntos de teste, o desempenho do modelo piora com o aumento do tamanho da imagem, evidenciado pelo F1-Score que teve uma diferença aproximada de 4.5% entre os modelos 2.b e 2.d.

Tabela 3 – Resultados dos modelos na partição Teste #1.

Modelo	Acurácia média	$Precision_M$	$Recall_M$	$F1-Score_M$
2.a	0.8740	0.4831	0.5108	0.4770
2.b	0.9423	0.7442	0.7576	0.7141
2.c	0.9448	0.7407	0.7363	0.6916
2.d	0.9444	0.7070	0.6424	0.6319

Tabela 4 – Resultados dos modelos na partição Teste #2.

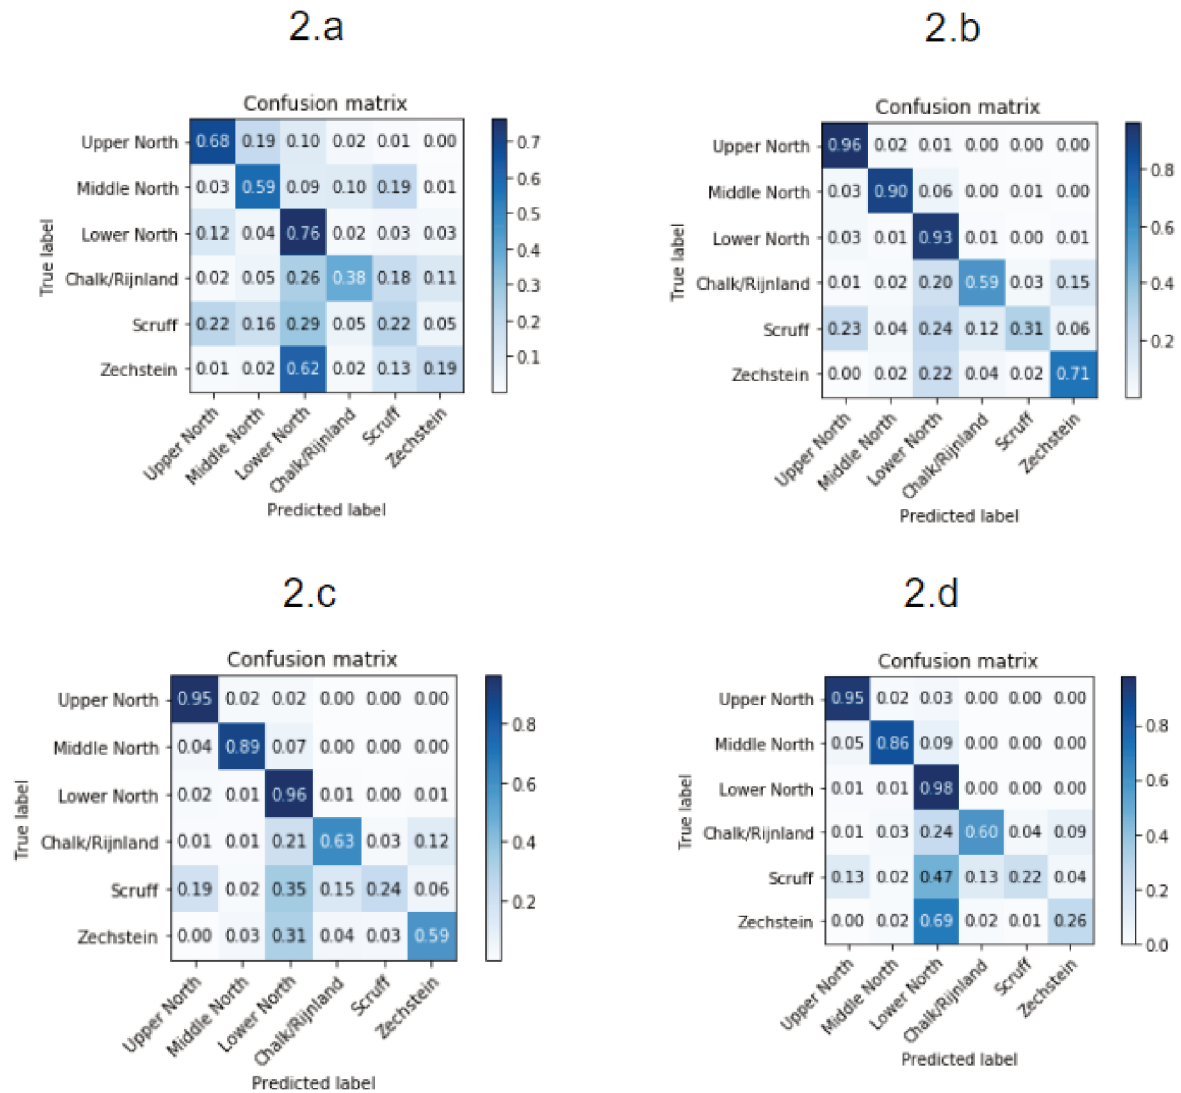
Modelo	Acurácia média	$Precision_M$	$Recall_M$	$F1-Score_M$
2.a	0.8968	0.3989	0.4515	0.3918
2.b	0.9656	0.6223	0.6685	0.6257
2.c	0.9734	0.6430	0.6528	0.6319
2.d	0.9804	0.6947	0.6391	0.6488

Tabela 5 – Resultados dos modelos nas partições Teste #1 e #2.

Modelo	Acurácia média	$Precision_M$	$Recall_M$	$F1-Score_M$
2.a	0.8845	0.4418	0.4707	0.4503
2.b	0.9530	0.7343	0.7324	0.6985
2.c	0.9579	0.7410	0.7091	0.6833
2.d	0.9609	0.7392	0.6444	0.6537

A Figura 23 apresenta as matrizes de confusão obtidas da união dos conjuntos de teste. Em todos os casos, nota-se a mistura de classes com menos representação no conjunto de dados, com a exceção da classe *Zechstein* no modelo 2.b que teve 71% de previsões corretas para essa fácies. Também é interessante observar que mesmo com a grande limitação de dados do modelo 2.a, as classes 0, 1 e 2 apresentam bons resultados, porém muitas outras se misturam, criando um resultado ruidoso. Com o aumento do tamanho da imagem, o resultado classes 1, 2 e 3 melhorou, porém em detrimento das outras classes, em especial a classe 5, caindo de 0.71 para 0.26. Como refletido na métrica F1-Score, o modelo 2.b apresentou o resultados mais balanceados entre os aqui avaliados.

Figura 23 – Matrizes de confusão para os conjuntos de teste #1 e #2



Fonte: Autor.

Como as métricas deste trabalho diferem das utilizadas no *benchmark*, também foram calculadas as mesmas métricas lá empregadas (detalhadas no trabalho referenciado) para permitir a comparação. Esses valores se encontram na Tabela 6, que pode ser comparado com a Figura 24, onde são destacados os modelos que possuem resultados similares aos do modelo 2.b deste trabalho.

Tabela 6 – Resultados dos conjuntos Teste #1 e #2 com métricas do *benchmark*.

Modelo	PA	Class Accuracy						MCA	FWIU
		Zechstein	Scruff	Rijnland/Chalk	Lower N.	Middle N.	Upper N.		
2.a	0.65	0.19	0.22	0.38	0.76	0.59	0.68	0.47	0.52
2.b	0.86	0.71	0.31	0.59	0.93	0.90	0.96	0.73	0.76
2.c	0.87	0.59	0.24	0.63	0.96	0.89	0.95	0.71	0.78
2.d	0.88	0.26	0.22	0.60	0.98	0.86	0.95	0.64	0.79

Figura 24 – Resultados dos modelos de base do *benchmark* para os conjuntos Teste #1 e #2.

Table 3: Results of both test sets

Model	Metric	PA	Class Accuracy						MCA	FWIU
			Zechstein	Scruff	Rijnland/Chalk	Lower N. S.	Middle N. S.	Upper N. S.		
Patch-based model		0.788	0.264	0.074	0.499	0.992	0.804	0.754	0.565	0.640
Patch-based + aug.		0.852	0.434	0.221	0.707	0.974	0.884	0.916	0.689	0.743
Patch-based + aug + skip		0.862	0.458	0.286	0.673	0.974	0.912	0.926	0.705	0.757
Section-based model		0.879	0.219	0.539	0.744	0.951	0.872	0.973	0.716	0.789
Section-based + aug.		0.901	0.714	0.423	0.812	0.979	0.940	0.956	0.804	0.844
Section-based + aug + skip		0.905	0.602	0.674	0.772	0.941	0.938	0.974	0.817	0.832

Fonte: Yazeed et al. (2019).

Aqui pode-se atentar que apesar das métricas PA, MCA e FWIU nas regiões destacadas serem próximas, a distribuição de *class accuracy* é bem distinta nos modelos *patch-based*, *section-based* e no modelo 2.b. A seguir, serão discutidas algumas vantagens e desvantagens do método aqui proposto já que a diferença entre os modelos apresentados vai além dos resultados apresentados.

5 Conclusões

O problema de classificação de fácies sísmicas tem grande importância no processo de caracterização de reservatórios de petróleo e gás, uma vez que ajuda a descrever as estruturas da subsuperfície, dando base às decisões econômicas de alto custo. Neste trabalho, apresentou-se um método de amostragem unindo dados de poços e de reflexões sísmicas para o treinamento de redes neurais convolucionais que realizam a classificação dessas fácies a partir do dado sísmico. Foram apresentados cinco modelos testados em dois cenários distintos: o reservatório sintético Stanford VI-E e o bloco F3 no Mar do Norte. Como parte dos objetivos iniciais deste trabalho, também foram comparados alguns modelos com trabalhos relacionados da literatura.

Com os resultados apresentados no capítulo anterior, o método proposto teve seu desempenho limitado nos dados reais quando impostas as restrições práticas da exploração de hidrocarbonetos. O uso dos dados localizados apenas em poços reduz drasticamente a quantidade de exemplos disponíveis para treinamento da rede e também limita a variabilidade das amostras, trazendo exemplos similares. Na prática, esses dados ainda poderiam ser suplementados pela criação de exemplos adicionais de outras regiões do reservatório, através da classificação manual, por exemplo. Quando a restrição de amostragem em poços foi removida a fim de comparar os modelos produzidos com outros trabalhos, foram obtidos resultados similares, com acurácias de algumas classes passando de 90%, chegando até 98%.

Como característica do método, deve-se escolher um tamanho de amostragem para a criação das imagens de entrada da rede. Comparando três modelos com tamanhos de entrada diferente, observou-se que a amostragem de tamanho $32 \times 32 \times 32$ resultou em uma classificação de fácies sísmicas mais equilibrada entre as diferentes classes. Também decorrente do processo de amostragem, o método não realiza previsões de fácies muito próximas das extremidades do volume sísmico e não foi avaliado se existe a possibilidade de contornar essa limitação.

5.1 Trabalhos Futuros

Como continuação deste trabalho, alguns caminhos possíveis são sugeridos a seguir:

- utilizar técnicas para introduzir variações nos dados de treinamento a fim de aumentar artificialmente a quantidade de exemplos disponíveis. Isso é realizado em outras aplicações de redes convolucionais através de rotações e inserção de ruído nas imagens. Deve-se analisar se isso é possível nesse domínio;

- uso de *transfer-learning*, que consiste no retreino de uma rede robusta já existente para um novo problema específico. Essa abordagem, se possível, diminui os dados de treinamento necessários para obter o mesmo desempenho de uma rede treinada desde o começo apenas com dados do problema em questão;
- testar modelos de convolução 3D buscando comparar as diferenças do desempenho do classificador e também dos custos computacionais envolvidos no uso de dados tridimensionais.

Referências

- BARNES, A. E. Redundant and useless seismic attributes. *Geophysics*, v. 72, n. 3, p. 33, 2007. Disponível em: <<http://dx.doi.org/10.1190/1.2716717>>.
- BARNES, A. E.; LAUGHLIN, K. J. Investigation of methods for unsupervised classification of seismic data. *SEG Technical Program Expanded Abstracts*, p. 2221, 2002. Disponível em: <<https://doi.org/10.1190/1.1817152>>.
- CAMPBELL, M.; HOANE, A.; HSU, F. hsiung. Deep blue. *Artificial Intelligence*, v. 134, n. 1, p. 57 – 83, 2002. ISSN 0004-3702. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0004370201001291>>.
- CHEN, Q.; SIDNEY, S. Seismic attribute technology for reservoir forecasting and monitoring. *The Leading Edge*, v. 16, n. 5, p. 445–448, 1997. Disponível em: <<https://doi.org/10.1190/1.1437657>>.
- COLÉOU, T.; POUPON, M.; AZBEL, K. Unsupervised seismic facies classification : A review and comparison of techniques and implementation. *The Leading Edge*, v. 22, n. 10, p. 942, 2003. Disponível em: <<http://dx.doi.org/10.1190/1.1623635>>.
- DOYEN, P. M. *Seismic Reservoir Characterization: An Earth Modelling Perspective*. Houten: EAGE publications, 2007. 255 pp. p. ISBN 978-90-73781-77-1.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>.
- HE, H.; GARCIA, E. A. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, v. 21, n. 9, p. 1263–1284, Sep. 2009. ISSN 1041-4347.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: PEREIRA, F. et al. (Ed.). *Advances in Neural Information Processing Systems 25*. Curran Associates, Inc., 2012. p. 1097–1105. Disponível em: <<http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>>.
- LEE, J.; MUKERJI, T. The stanford vie reservoir : A synthetic data set for joint seismic-em time-lapse monitoring algorithms. In: . [S.l.: s.n.], 2012.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, v. 5, n. 4, p. 115–133, Dec 1943. ISSN 1522-9602. Disponível em: <<https://doi.org/10.1007/BF02478259>>.
- MITCHELL, T. M. *Machine Learning*. 1. ed. New York, NY, USA: McGraw-Hill, Inc., 1997. ISBN 0070428077, 9780070428072.
- MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. *Foundations of Machine Learning*. [S.l.]: The MIT Press, 2012. ISBN 026201825X, 9780262018258.
- RAMACHANDRAN, P.; ZOPH, B.; LE, Q. V. *Searching for Activation Functions*. 2017.

- READING, H. G. *Sedimentary Environments: Processes, Facies and Stratigraphy, 3rd Edition*. 3. ed. [S.l.]: Wiley-Blackwell, 1996. ISBN 0632036273,978-0-6320-3627-1,9781444313697,144431369X.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain [j]. *Psychol. Review*, v. 65, p. 386 – 408, 12 1958.
- RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 3rd. ed. Upper Saddle River, NJ, USA: Prentice Hall Press, 2009. ISBN 0136042597, 9780136042594.
- SANCEVERO, S. S. *Estudo de Aplicação de Métodos Quantitativos em Dados Sísmicos no Processo de Caracterização Integrada de Reservatórios*. Tese (Doutorado) — Universidade Estadual de Campinas, 2007.
- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, v. 45, n. 4, p. 427 – 437, 2009. ISSN 0306-4573. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0306457309000259>>.
- TANER, M. T. *Attributes Revisited*. [S.l.], 2000.
- WALDELAND, A. U.; SOLBERG, A. Salt classification using deep learning. In: . [S.l.: s.n.], 2017.
- YAZEED, A. et al. A machine learning benchmark for facies classification. *Interpretation*, v. 7, p. 1–51, 05 2019.
- ZHAO, T. Seismic facies classification using different deep convolutional neural networks. In: . [S.l.: s.n.], 2018.
- ZHOU, Y.; CHELLAPPA, R. Computation of optical flow using a neural network. In: . [S.l.: s.n.], 1988. p. 71 – 78 vol.2.

APÊNDICE A – ARTIGO DO TCC

Classificação de Fácies Sísmicas por Redes Neurais Convolucionais

Arthur B. Guazzelli¹

¹Departamento de Informática e Estatística – Universidade Federal de Santa Catarina
(UFSC)
Florianópolis – SC – Brasil

arthur.bg@grad.ufsc.br

Abstract. *Technological advances in oil and gas reservoir characterization such as 3D seismics and seismic attributes enriched the subsurface's description made by specialists. Nevertheless, the analysis of this now huge volume of data became a complex task. This work explores the use of convolutional neural networks for seismic facies classification, one of the steps of reservoir characterization. Through a sampling method that captures spacial information of seismic data, the models produced were applied in both synthetic data of the Stanford VI-E reservoir and in a benchmark based on the F3 block, which is part of a real reservoir. Compared to other models in the same benchmark, the classifiers produced here had similar results, with over 90% class accuracy on some instances. The sampling method is also flexible to use in practical cases.*

Resumo. *Avanços tecnológicos no processo de caracterização de reservatórios de petróleo e gás como a sísmica 3D e atributos sísmicos enriqueceram a descrição da subsuperfície realizada por especialistas. No entanto, a análise dessa grande quantidade de dados se tornou uma tarefa complexa. Este trabalho faz uso de redes convolucionais para classificação de fácies sísmicas, uma das etapas que compõem a caracterização de reservatórios. Os modelos gerados foram aplicados em dados sintéticos do reservatório Stanford VI-E e em um benchmark baseado no bloco F3, parte de um reservatório real. Comparando-se com outros modelos avaliados no mesmo conjunto de dados, as redes classificadoras produzidas neste trabalho obtiveram resultados similares, passando de 90% de acurácia na classificação de algumas fácies sísmicas.*

1. Introdução

A caracterização de reservatórios de petróleo e gás se beneficiou de avanços tecnológicos como a sísmica 3D e atributos sísmicos, que fornecem informações qualitativas da geometria e dos parâmetros físicos da subsuperfície. Essas tecnologias, tornaram complexa a análise dessa grande quantidade de dados disponíveis aos intérpretes [Sancevero 2007]. A classificação de fácies sísmicas é uma das etapas que compõem a caracterização de reservatórios. Na geologia, uma fácies sísmica é definida como um corpo rochoso com características de reflexão distintas daqueles em seu entorno [Reading 1996].

Recentemente, algoritmos de *deep learning* foram propostos como alternativa para solucionar os problemas apresentados pela classificação manual e assistida—por técnicas não supervisionadas—de fácies sísmicas [U. Waldeland and Solberg 2017, Zhao 2018,

Yazeed et al. 2019]. Esses algoritmos são usados para extrair representações dos dados e realizar a classificação de fácies sísmicas de maneira automática. Este trabalho, então, propõe o desenvolvimento de um classificador de fácies sísmicas fazendo uso das técnicas de *deep learning* com o objetivo de obter um mapeamento entre dados sísmicos e valores de fácies de um reservatório.

A abordagem escolhida nesse trabalho é de utilizar as classificações de fácies em poços como alvo do algoritmo de classificação com o intuito de reduzir o ruído de treinamento e empregar os dados sísmicos tridimensionais na vizinhança da área que será classificada como entrada do algoritmo, tirando proveito da correlação espacial em todas as dimensões. Por consequência, o treinamento da rede é condicionado às regiões do reservatório com poços já perfurados, mas a classificação de fácies realizada pela rede após o treinamento pode ser aplicada em toda extensão da sísmica. A escolha de redes convolucionais como classificador se dá pela sua excelente capacidade de reconhecer e abstrair padrões espaciais dos dados de entrada.

Como classificador, é utilizada uma rede convolucional 2D—o mesmo tipo empregado na classificação de imagens como no conjunto de dados ImageNet [Krizhevsky et al. 2012]. A linguagem de programação Python foi utilizada para a implementação da proposta. As bibliotecas usadas foram: Keras, para definição, treinamento, e teste dos modelos de redes convolucionais; Tensorflow como *backend* da biblioteca Keras; Matplotlib e K3D para visualização de dados e resultados. O código produzido durante este trabalho se encontra no repositório do GitHub no endereço: <https://github.com/thurbridi/cnn-facies-classifier>.

2. Dados de Treinamento

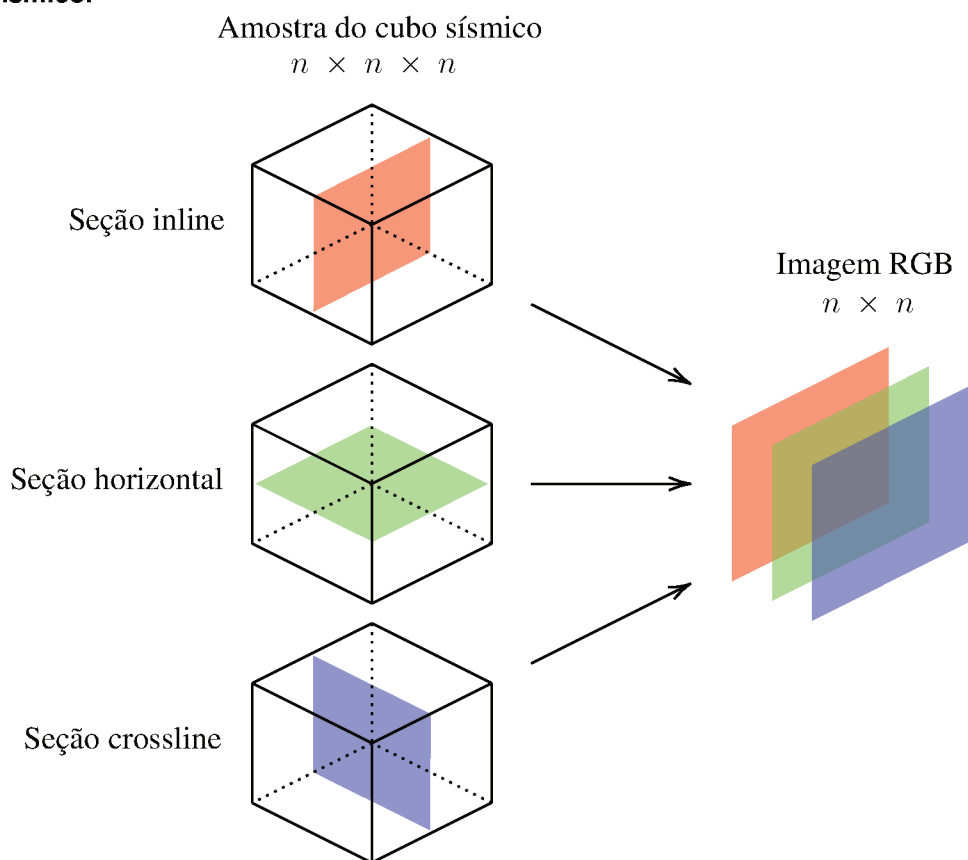
Os dados sísmicos são normalmente disponibilizados como um volume de valores de reflexão das ondas de energia originadas pela fonte durante a aquisição sísmica¹. Denomina-se esse volume como cubo sísmico, apesar de não haver nenhuma imposição que suas dimensões tenham tamanhos iguais.

Para cada exemplo usado como entrada da rede é feita uma subamostragem do cubo sísmico para um cubo de dimensões $n \times n \times n$. O objetivo da classificação é o ponto central dessa amostra, ou seja, queremos identificar a qual fácies esse ponto central pertence. O tamanho escolhido para amostragem impõe uma restrição espacial para a rede, já que o aprendizado é realizado com base em exemplos individualmente. Como o modelo utiliza a convolução 2D, é preciso transformar as informações do cubo amostrado para que se adequem ao formato bidimensional que alimenta o modelo. O objetivo é realizar essa transformação sem perder as correlações espaciais nas três dimensões do cubo e, para isso, são extraídas três seções passando pelo centro do cubo, uma para cada eixo. Essas seções são então empilhadas no formato de uma imagem RGB, com cada seção assumindo os valores de um dos canais de cor. Esse processo é ilustrado na Figura 1.

No caso dos dados usados para treinamento e validação da rede, cada exemplo deve estar associado a um rótulo que identifique a saída esperada. No método aqui pro-

¹Os dados obtidos no método sísmico ainda passam por uma série de processamentos a fim de reduzir o ruído das medições e descartar reflexões irrelevantes ao reservatório. Essa etapa é chamada de processamento sísmico mas não cabe o seu detalhamento no escopo desse trabalho.

Figura 1. Processo de geração de imagens RGB a partir de amostras do cubo sísmico.



posto, os rótulos de fácies são provenientes das informações de poços, que podem ser visualizados como uma linha, aproximadamente vertical, que atravessa o cubo sísmico. Para cada um dos valores de fácies classificadas no poço, amostramos do cubo sísmico a região em volta do valor, ou seja, deslizamos um cubo centrado ao longo da linha do poço que atravessa os dados sísmicos, realizando o processo de amostragem descrito acima e associando os valores de fácies classificadas.

3. Experimentos e Resultados

Foram avaliados 5 modelos, um no conjunto de dados Stanford VI-E e quatro no conjunto do bloco F3. Todos os modelos possuem a mesma arquitetura da Tabela 1 (com exceção das camadas de entrada e saída, que dependem do tamanho da imagem de entrada e a quantidade de classes do problema) e configurações de treinamento. Entretanto, eles divergem nos dados de treinamento em tamanho da entrada e a forma como os dados foram amostrados. A seguir, é detalhado cada um dos modelos, os modelos de número 2 foram treinados para o bloco F3, enquanto o modelo 1.a foi treinado para o reservatório Stanford VI-E.

- **Modelo 1.a:** Foi treinado para o reservatório Stanford VI-E, utilizando o método de amostragem por poços como explicado no Capítulo 3;
- **Modelo 2.a:** Utiliza o método de amostragem por poços, aqui foram usadas as localizações de poços reais do bloco F3, definidas por *inline* e *crossline* do volume,

somando seis poços reais e um poço adicional imaginário para obter exemplos de uma classe não representada nos outros seis. A rede foi treinada com imagens de tamanho 32×32 ;

- **Modelo 2.b:** Treinado com todos os dados da partição Treinamento do bloco F3. Usando imagens de tamanho 32×32 ;
- **Modelo 2.c:** Também utiliza todos os dados da partição de treinamento, porém com imagens de tamanho 48×48 ;
- **Modelo 2.d:** Também faz uso de todos os dados de treinamento, treinada com imagens 64×64

A ideia dos modelos 2.b-d é não restringir a quantidade de dados de treinamento quando comparadas às redes do *benchmark*.

Tabela 1. Arquitetura da rede utilizada para a classificação em ambos os reservatórios

Camada	Tipo	Unidades	Filtros	Kernel
1	Conv 2D Ativação (ReLU)	–	32	7×7
2	Max Pooling	–	–	2×2
3	Dropout	–	–	–
4	Conv 2D Ativação (ReLU)	–	64	5×5
5	Max Pooling	–	–	2×2
6	Dropout	–	–	–
7	Conv 2D Ativação (ReLU)	–	128	3×3
8	Max Pooling	–	–	2×2
9	Dropout	–	–	–
10	Flatten	–	–	–
11	Dense Ativação (ReLU)	200	–	–
12	Dense Ativação (SoftMax)	4 (Stanford VI-E) ou 6 (Bloco F3)	–	–

3.1. Stanford VI-E

O reservatório Stanford VI-E [Lee and Mukerji 2012] é um modelo sintético de reservatório criado com o objetivo de testar algoritmos de modelagem, caracterização, e produção de reservatórios. É um conjunto de dados extenso com mais de 6 milhões de células contendo propriedades petrofísicas e atributos sísmicos. Os dados são disponibilizados em um volume de tamanho $150 \times 200 \times 200$, as células tem dimensões 25m nos eixos horizontais x e y e 1m no eixo vertical z . Portanto, o reservatório tem uma extensão de 3.750m na direção leste-oeste, 5.000m na direção norte-sul e 200m de profundidade.

Antes de realizar o processo de amostragem e geração de imagens de treinamento, neste caso, é preciso criar poços imaginários para impor as restrições práticas do método proposto, visto que não são definidos poços no Stanford VI-E. Para tanto, foram escolhidas 10 posições x e y aleatórias do cubo sísmico, cada uma representando a posição de um poço. Percorrendo o eixo z nessas posições, são amostrados, do volume sísmico, cubos de tamanho $32 \times 32 \times 32$.

Neste experimento, foi utilizado todo o cubo sísmico como conjunto de teste. Para isso, repete-se o processo de amostragem acima, sem as restrições de poços. Logo, são amostrados, rotulados, e transformados em imagens, cubos $32 \times 32 \times 32$ de todas as posições possíveis do volume sísmico. O conjunto de teste permite avaliar a capacidade de generalização do modelo treinado. Ou seja, quão bem a rede classifica exemplos que não foram vistos anteriormente. Entretanto, como os dados de treinamento (880 exemplos) representam apenas uma pequena fração dos dados de teste (1.769.768 exemplos), os casos em que os dois conjuntos se sobrepõe não foram removidos dos dados de teste.

As fácies sísmicas foram mapeadas para classes do problema de classificação atribuindo um código numérico para cada uma:

0. *floodplain*: depósitos de argila;
1. *pointbar*: depósitos de areia que ocorrem ao longo das bordas convexas internas;
2. *channel*: depósitos de areia;
3. *boundary*: borda de argila.

Após o treinamento do modelo apresentado, foram calculadas as métricas: acurácia média, F1-Score e matriz de confusão [Sokolova and Lapalme 2009]. Os resultados estão expostos na Tabela 2. O modelo apresentou acurácia média de 0.89 que significa uma alta taxa de verdadeiros positivos e verdadeiros negativos entre as classes. O valor de $precision_M$ indica que, em média, 60% dos pontos classificados como uma determinada fácies foram previstos corretamente. Já o valor do $recall_M$ indica que, em média, 61% dos pontos de uma fácies são classificados corretamente.

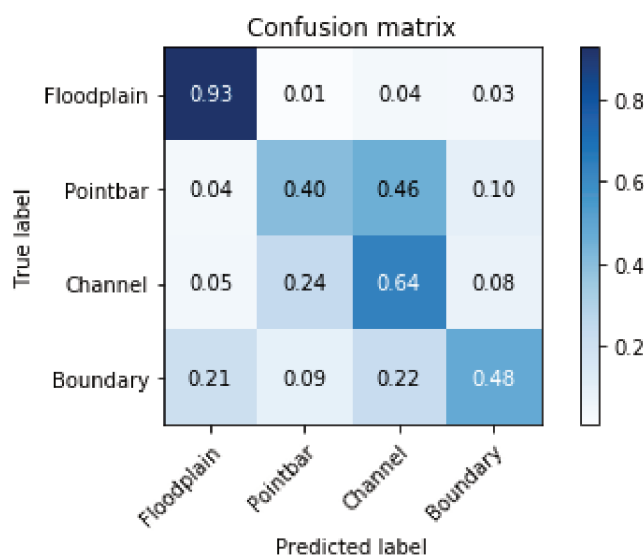
Tabela 2. Resultado no conjunto Stanford VI-E.

Modelo	Acurácia média	$Precision_M$	$Recall_M$	$F1-Score_M$
1.a	0.8903	0.6000	0.6119	0.6027

Com a matriz de confusão, presente na Figura 2, podemos identificar as classes nas quais a rede teve maior dificuldade em aprender. Nota-se que, enquanto a classe 0 teve 93% de previsões corretas, existe grande mistura entre as classes 1, 2 e 3. No caso da confusão entre as classes 1 e 2, [Lee and Mukerji 2012] explicam que as duas classes

são ambas areias e seus valores de impedância são muito parecidos e, portanto, suas respostas sísmicas também devem ser similares. O desempenho ruim da classe 3 pode estar relacionado a sua baixa frequência nos dados de treinamento, assim como a classe 1. É importante ressaltar que o balanceamento dos dados realizado não introduz novas informações no treinamento da rede e portanto não corrige a deficiência da amostragem original. O balanceamento apenas equilibra as métricas utilizadas durante a etapa de treinamento e validação, dando a mesma importância para todas as classes.

Figura 2. Matriz de confusão do resultado de classificação do conjunto Stanford VI-E.



3.2. Bloco F3

Localizado na costa dos Países Baixos, o bloco F3 possui dimensões 16km × 24km e foi mapeado utilizando o método sísmico 3D para a exploração de petróleo e gás na região. No *benchmark* de [Yazeed et al. 2019], parte do bloco F3 é processada e dividida em três partições: uma para treinamento e outras duas para teste, onde foram separadas, ao final do trabalho, 6 classes de fácies.

0. **Upper North:** *claystone* e arenito do Mioceno até o Quaternário.
1. **Middle North:** areias, arenitos, e *claystones* do Paleoceno até Mioceno;
2. **Lower North:** mesma constituição da classe *Middle North*;
3. **Chalk/Rijnland:** carbonatos do Cretácio Superior e Paleoceno; formações de argila com arenitos do Cretácio Superior;
4. **Scruff:** *claystones* do Jurássico Superior e Cretácio Inferior;
5. **Zechstein:** evaporitos e carbonatos do Zechstein;

Para a geração do conjunto de treinamento e validação no bloco F3, foram seguidos dois caminhos diferentes: um focando na proposta deste trabalho de utilizar apenas as informações de poços; outro utilizando todos os dados disponíveis da partição de treinamento para melhor comparar os resultados com o *benchmark* em questão.

Na amostragem através de poços, foram utilizadas as localizações de poços reais do bloco F3, entretanto, os poços presentes na partição de treinamento são concentrados

em uma pequena área. Devido a isso, um poço adicional foi assumido para incluir exemplos da classe *Zechstein* no treinamento. As localizações usadas estão listadas abaixo pelo seu *inline* e *crossline*, respectivamente:

1. Poço 'F02-01': (362, 336)
2. Poço 'F03-03': (318, 460)
3. Poço 'F03-05-S1': (452, 455)
4. Poço 'F03-06': (426, 391)
5. Poço 'F03-FB-101': (353, 430)
6. Poço 'F03-FB-106': (356, 429)
7. Poço adicional: (350, 900)

Para os modelos 2.b-d, a amostragem foi realizada em todo o cubo de treinamento. Devido a enorme quantidade de exemplos, foi impraticável salvar e carregar todos os exemplos em memória. Isso acontece pois imagens próximas criam uma redundância de informação, aumentando drasticamente o uso de memória comparado ao cubo original. Para resolver esse problema, implementou-se a geração e carregamento dinâmico de exemplos para o treinamento e previsão da rede, através da biblioteca Keras. Desse modo, permanecem em memória apenas os exemplos sendo processados no *batch* atual do treinamento ou previsão.

Após o treinamento dos modelos, os cubos das partições Teste #1 e #2 foram recriados com as previsões de cada um dos modelos, totalizando oito novos cubos. As métricas propostas neste trabalho foram calculadas em comparação com cada cubo de teste e também na união dos dois. Os resultados são apresentados nas Tabelas 3, 4 e 5.

Nessas tabelas, é evidente que o modelo 2.a teve um desempenho pior do que foi visto no reservatório Stanford VI-E. Isso já era esperado pois o dado real é mais ruidoso, no entanto, outras características do reservatório podem ter influenciado o resultado já que os dois reservatórios têm formações de naturezas diferentes. Nos resultados dos modelos 2.b até 2.d, podemos analisar os efeitos do tamanho da imagem de entrada da rede (logo, do tamanho do cubo de amostragem). Nesses modelos, os resultados variam de formas diferentes dependendo do conjunto de teste. [Yazeed et al. 2019] explica que na partição Teste #2 existe um diapiro (acidente geológico associados ao levantamento e erosão de camadas) da classe *Zechstein*, uma estrutura não presente em nenhuma outra partição. Ao analisar os resultados na união dos conjuntos de teste, o desempenho do modelo piora com o aumento do tamanho da imagem, evidenciado pelo F1-Score que teve uma diferença aproximada de 4.5% entre os modelos 2.b e 2.d.

Tabela 3. Resultados dos modelos na partição Teste #1.

Modelo	Acurácia média	Precision_M	Recall_M	F1-Score_M
2.a	0.8740	0.4831	0.5108	0.4770
2.b	0.9423	0.7442	0.7576	0.7141
2.c	0.9448	0.7407	0.7363	0.6916
2.d	0.9444	0.7070	0.6424	0.6319

A Figura 3 apresenta as matrizes de confusão obtidas da união dos conjuntos de teste. Em todos os casos, nota-se a mistura de classes com menos representação no conjunto de dados, com a exceção da classe *Zechstein* no modelo 2.b que teve 71% de previsões corretas para essa fácies. Também é interessante observar que mesmo com a grande

Tabela 4. Resultados dos modelos na partição Teste #2.

Modelo	Acurácia média	$Precision_M$	$Recall_M$	$F1-Score_M$
2.a	0.8968	0.3989	0.4515	0.3918
2.b	0.9656	0.6223	0.6685	0.6257
2.c	0.9734	0.6430	0.6528	0.6319
2.d	0.9804	0.6947	0.6391	0.6488

Tabela 5. Resultados dos modelos nas partições Teste #1 e #2.

Modelo	Acurácia média	$Precision_M$	$Recall_M$	$F1-Score_M$
2.a	0.8845	0.4418	0.4707	0.4503
2.b	0.9530	0.7343	0.7324	0.6985
2.c	0.9579	0.7410	0.7091	0.6833
2.d	0.9609	0.7392	0.6444	0.6537

limitação de dados do modelo 2.a, as classes 0, 1 e 2 apresentam bons resultados, porém muitas outras se misturam, criando um resultado ruidoso. Com o aumento do tamanho da imagem, o resultado classes 1, 2 e 3 melhorou, porém em detrimento das outras classes, em especial a classe 5, caindo de 0.71 para 0.26. Como refletido na métrica F1-Score, o modelo 2.b apresentou o resultados mais balanceados entre os aqui avaliados.

Como as métricas deste trabalho diferem das utilizadas no *benchmark*, também foram calculadas as mesmas métricas lá empregadas (detalhadas no trabalho referenciado) para permitir a comparação. Esses valores se encontram na Tabela 6, que pode ser comparado com a Figura 4, onde são destacados os modelos que possuem resultados similares aos do modelo 2.b deste trabalho.

Tabela 6. Resultados dos conjuntos Teste #1 e #2 com métricas do *benchmark*.

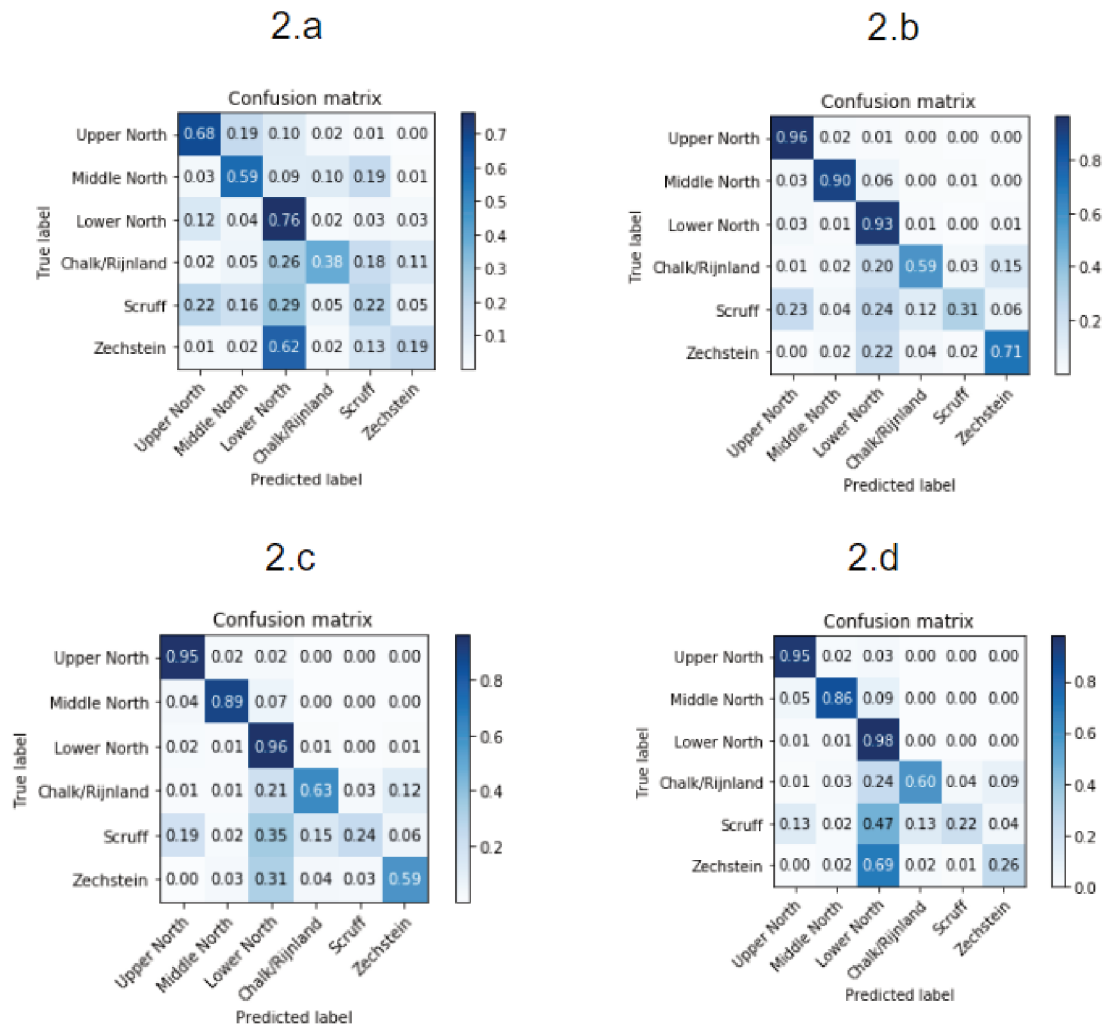
Modelo	PA	Class Accuracy						MCA	FWIU
		Zechstein	Scruff	Rijnland/Chalk	Lower N.	Middle N.	Upper N.		
2.a	0.65	0.19	0.22	0.38	0.76	0.59	0.68	0.47	0.52
2.b	0.86	0.71	0.31	0.59	0.93	0.90	0.96	0.73	0.76
2.c	0.87	0.59	0.24	0.63	0.96	0.89	0.95	0.71	0.78
2.d	0.88	0.26	0.22	0.60	0.98	0.86	0.95	0.64	0.79

Aqui pode-se atentar que apesar das métricas PA, MCA e FWIU nas regiões destacadas serem próximas, a distribuição de *class accuracy* é bem distinta nos modelos *patch-based*, *section-based* e no modelo 2.b. A seguir, serão discutidas algumas vantagens e desvantagens do método aqui proposto já que a diferença entre os modelos apresentados vai além dos resultados apresentados.

4. Conclusões

O problema de classificação de fácies sísmicas tem grande importância no processo de caracterização de reservatórios de petróleo e gás, uma vez que ajuda a descrever as estruturas da subsuperfície, dando base às decisões econômicas de alto custo. Neste trabalho, apresentou-se um método de amostragem unindo dados de poços e de reflexões sísmicas para o treinamento de redes neurais convolucionais que realizam a classificação dessas

Figura 3. Matrizes de confusão para os conjuntos de teste #1 e #2



fácies a partir do dado sísmico. Foram apresentados cinco modelos testados em dois cenários distintos: o reservatório sintético Stanford VI-E e o bloco F3 no Mar do Norte. Como parte dos objetivos iniciais deste trabalho, também foram comparados alguns modelos com trabalhos relacionados da literatura.

Com os resultados apresentados na seção anterior, o método proposto teve seu desempenho limitado nos dados reais quando impostas as restrições práticas da exploração de hidrocarbonetos. O uso dos dados localizados apenas em poços reduz drasticamente a quantidade de exemplos disponíveis para treinamento da rede e também limita a variabilidade das amostras, trazendo exemplos similares. Na prática, esses dados ainda poderiam ser suplementados pela criação de exemplos adicionais de outras regiões do reservatório, através da classificação manual, por exemplo. Quando a restrição de amostragem em poços foi removida a fim de comparar os modelos produzidos com outros trabalhos, foram obtidos resultados resultados similares, com acurácias de algumas classes passando de 90%, chegando até 98%.

Figura 4. Resultados dos modelos de base do *benchmark* para os conjuntos Teste #1 e #2.

Table 3: Results of both test sets

Model	Metric	PA	Class Accuracy					MCA	FWIU	
			Zechstein	Seruff	Rijnland/Chalk	Lower N. S.	Middle N. S.			Upper N. S.
Patch-based model		0.788	0.264	0.074	0.499	0.992	0.804	0.754	0.565	0.640
Patch-based + aug.		0.852	0.434	0.221	0.707	0.974	0.884	0.916	0.689	0.743
Patch-based + aug + skip		0.862	0.458	0.286	0.673	0.974	0.912	0.926	0.705	0.757
Section-based model		0.879	0.219	0.539	0.744	0.951	0.872	0.973	0.716	0.789
Section-based + aug.		0.901	0.714	0.423	0.812	0.979	0.940	0.956	0.804	0.844
Section-based + aug + skip		0.905	0.602	0.674	0.772	0.941	0.938	0.974	0.817	0.832

Fonte: [Yazeed et al. 2019].

Como característica do método, deve-se escolher um tamanho de amostragem para a criação das imagens de entrada da rede. Comparando três modelos com tamanhos de entrada diferente, observou-se que a amostragem de tamanho $32 \times 32 \times 32$ resultou em uma classificação de fácies sísmicas mais equilibrada entre as diferentes classes. Também decorrente do processo de amostragem, o método não realiza previsões de fácies muito próximas das extremidades do volume sísmico e não foi avaliado se existe a possibilidade de contornar essa limitação.

Referências

- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc.
- Lee, J. and Mukerji, T. (2012). The stanford vie reservoir : A synthetic data set for joint seismic-em time-lapse monitoring algorithms.
- Reading, H. G. (1996). *Sedimentary Environments: Processes, Facies and Stratigraphy, 3rd Edition*. Wiley-Blackwell, 3 edition.
- Sancevero, S. S. (2007). *Estudo de Aplicação de Métodos Quantitativos em Dados Sísmicos no Processo de Caracterização Integrada de Reservatórios*. PhD thesis, Universidade Estadual de Campinas.
- Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4):427 – 437.
- U. Waldeland, A. and Solberg, A. (2017). Salt classification using deep learning.
- Yazeed, A., Patrycja, M., Motaz, A., and Ghassan, A. (2019). A machine learning benchmark for facies classification. *Interpretation*, 7:1–51.
- Zhao, T. (2018). Seismic facies classification using different deep convolutional neural networks.