



# **UNIVERSIDADE FEDERAL DO MARANHÃO**

## **Programa de Pós-Graduação em Ciência da Computação**

**Domingos Alves Dias Junior**

***Deteccção de potenciais acumulações de gás em imagens sísmicas 2D usando abordagem espaço-temporal, PSO e convolucional LSTM***

**São Luís  
2023**

Domingos Alves Dias Junior

**Detecção de potenciais acumulações de gás em imagens sísmicas 2D usando abordagem espaço-temporal, PSO e convolucional LSTM**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Ciência da Computação, ao Programa de Pós-Graduação em Ciência da Computação, da Universidade Federal do Maranhão.

Programa de Pós-Graduação em Ciência da Computação

Universidade Federal do Maranhão

Orientador: Prof. Dr. Aristófanés Corrêa Silva

Coorientador: Prof. Dr. Anselmo Cardoso de Paiva

São Luís - MA

2023

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).  
Diretoria Integrada de Bibliotecas/UFMA

Alves Dias Junior, Domingos.

Detecção de potenciais acumulações de gás em imagens sísmicas 2D usando abordagem espaço-temporal, PSO e convolucional LSTM / Domingos Alves Dias Junior. - 2023.  
76 p.

Coorientador(a): Anselmo Cardoso de Paiva.

Orientador(a): Aristófanês Corrêa Silva.

Dissertação (Mestrado) - Programa de Pós-graduação em Ciência da Computação/ccet, Universidade Federal do Maranhão, São Luís, 2023.

1. Bacia do Parnaíba. 2. ConvLSTM. 3. Dados Sísmicos. 4. Espaço Temporal. 5. Indicadores Diretos de Hidrocarbonetos. I. Cardoso de Paiva, Anselmo. II. Corrêa Silva, Aristófanês. III. Título.

Domingos Alves Dias Junior

# **Detecção de potenciais acumulações de gás em imagens sísmicas 2D usando abordagem espaço-temporal, PSO e convolucional LSTM**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Ciência da Computação, ao Programa de Pós-Graduação em Ciência da Computação, da Universidade Federal do Maranhão.

---

**Prof. Dr. Aristófanês Corrêa Silva**

Orientador

Universidade Federal do Maranhão

---

**Prof. Dr. Anselmo Cardoso de Paiva**

Coorientador

Universidade Federal do Maranhão

---

**Prof. Dr. João Dallyson Sousa de Almeida**

Examinador Interno

Universidade Federal do Maranhão

---

**Prof. Dr. António Manuel Triguieros da Silva Cunha**

Examinador Externo

Universidade de Trás-os-Montes e

Alto Douro

São Luís - MA

2023

*À todos que contribuíram com essa jornada.*

# Agradecimentos

Primeiramente a Jesus que sempre esteve ao meu lado, minha bússola guia. Aquele que me inspira a ser o melhor ser humano que posso ser, à medida que sigo seus passos e ensinamentos. Sem Ele, nada seria possível e minha vida seria um eterno vazio.

Agradeço à minha família por todo amor, apoio e confiança que me proporcionaram, especialmente aos meus pais. À minha mãe, que sempre me incentivou a estudar, que me deu incentivo nos momentos difíceis, quando estava desanimado e cansado. Ao meu pai que, apesar de todas as adversidades, me fortaleceu e foi muito significativo para mim.

Agradeço à Dra. Luana Batista por todo companheirismo proporcionado dentro e fora da minha vida acadêmica, por ser a minha maior incentivadora e ombro amigo de todas as horas. Parte dessa conquista é dela. Não tenho palavras para descrever o quanto sou grato e o quanto a amo.

Aos meus amigos Petterson Diniz, Thayane Simões e Johnatan Carvalho, que fizeram meus dias de pesquisa muito mais divertidos e que contribuíram para minha formação.

Ao professor Aristófanés Corrêa, pela orientação, apoio e confiança.

Ao professor Anselmo Cardoso, pelas oportunidades proporcionadas.

Ao Núcleo de Computação Aplicada, local onde tive o meu primeiro contato com a pesquisa científica na universidade.

Agradeço à Universidade Federal do Maranhão pela oportunidade de fazer a pós-graduação. E a FAPEMA pelo apoio financeiro durante o mestrado.

Agradeço a todos que de alguma forma contribuíram para minha formação acadêmica.

Muito obrigado, que Deus os abençoe!

*“Levanto os meus olhos para os montes e pergunto:  
De onde me vem o socorro?  
O meu socorro vem do Senhor, que fez os céus e a terra.”  
(Salmos 121:1-2)*

# Resumo

A reflexão sísmica é um dos métodos geofísicos mais utilizados na indústria de petróleo e gás (*oil and gas* - O&G) para prospecção de hidrocarbonetos. Em particular, para alguns campos terrestres brasileiros, esse método tem sido usado para estimar a localização e o volume das acumulações de gás. No entanto, a análise e interpretação dos dados sísmicos é demorada devido à grande quantidade de informações e à natureza ruidosa das aquisições. Para auxiliar os geocientistas, essas tarefas, ferramentas computacionais alimentadas no aprendizado da máquina têm sido propostas para detecção de potenciais acumulações de gás. Neste estudo é proposto um método organizado em duas etapas: (1) pré-processamento aplicado à base de imagens (delimitação da região de interesse, agrupamento das regiões de imagens sísmicas, geração de amostra espaço-temporais e otimização das amostras); e (2) detecção de acumulações de gás com base no modelo *Convolutional Long Short-Term Memory* (ConvLSTM). Experimentos foram realizados em imagens sísmicas de reflexão provenientes dos campos de exploração pertencentes à bacia do Paranaíba. Deste modo, os melhores cenários obtidos foram 58,11% de F1-score, 83,36% de sensibilidade, 44,63% de precisão, 98,43% de especificidade e 99,29% de acurácia no campo de exploração preto. No campo real foram alcançados 60,4% de F1-score, 77,79% de sensibilidade, 49,36% de precisão, 98,62% de especificidade e 99,38% de acurácia. No campo branco, foram obtidos 60,14% de F1-score, 77,89% de sensibilidade, 48,98% de precisão, 96,93% de especificidade e 99,66% de acurácia. Finalmente, foram obtidos para o campo vermelho 85,51%, 98,88%, 75,33%, 99,3% e 99,35% de F1-score, sensibilidade, precisão, especificidade e acurácia, respectivamente. Em geral, os resultados fornecem fortes evidências de que o método proposto é uma ferramenta com potencial para detectar potenciais acumulações de gás.

**Palavras-chave:** Dados Sísmicos, Espaço-temporal, ConvLSTM, Bacia do Paranaíba, Indicadores Diretos de Hidrocarbonetos

# Abstract

Seismic reflection is one of the geophysical methods most used in the oil and gas (O&G) industry for hydrocarbon prospecting. In particular, for some Brazilian onshore fields, such a method has been used for estimating the location and volume of gas accumulations. However, the analysis and interpretation of seismic data are time-consuming due to the large amount of information and the noisy nature of the acquisitions. Then, to support geoscientists in those tasks, computational tools powered by machine learning have been proposed to detect potential gas accumulations. In this study, we proposed a method organized into two stages: (1) pre-processing applied to the image database (delimitation of the region of interest, clustering regions of seismic images, generation of space-time samples, and sample optimization); and (2) detection of gas accumulations based on the Convolutional Long Short-Term Memory (ConvLSTM) model. Experiments were performed on seismic reflection images from exploration fields belonging to the Paranaíba basin. Then, the best scenarios achieved an F1-score of 58.11%, a sensitivity of 83.36%, a precision 44.63% , a specificity of 98.43% and an accuracy of 99.29% in the Preto exploration field . Then, the Real field achieved an F1-score of 60.4%, a sensitivity of 77.79% , a precision of 49,36%, a specificity of 98,62% and an accuracy of 99,38%. Besides, the Branco field achieved an F1-score 60.14% , a sensitivity of 77.89% , a precision of 48.98%, specificity of 96,93% and an accuracy of 99,66%. Finally, 85.51%, 98.88%, 75.33%, 99.30% and 99.35% of F1-score, sensitivity, precision, specificity and accuracy were obtained for the Vermelho field, respectively. In summary, the results provide strong evidence that the proposed method is a tool with potential to detect potential gas accumulations.

**Keywords:** Seismic Data, Spatio-temporal, ConvLSTM, Parnaíba Basin, Direct Hydrocarbon Indicators

# Lista de ilustrações

Figura 1 – Processo de aquisição sísmica terrestre. . . . .	23
Figura 2 – Ilustração de uma imagem sísmica 2D. O eixo y representa o tempo em milissegundos e o eixo x representa a distância em metros. Na cor vermelha a região de gás sísmico. . . . .	23
Figura 3 – Exemplo de uma arquitetura básica CNN. . . . .	25
Figura 4 – Representação de uma RNN e uma rede <i>feed-forward</i> . . . . .	27
Figura 5 – Célula básica de uma arquitetura LSTM. . . . .	28
Figura 6 – Célula básica de uma arquitetura ConvLSTM. . . . .	29
Figura 7 – Arquitetura CNN. . . . .	31
Figura 8 – Etapas do K-Means. a) $k = 3$ e os centroides são gerados aleatoriamente com os dados do domínio; b) grupos são gerados com base na distância; c) o novo centroide de cada grupo é atualizado; d) passos b e c são repetidos até a convergência. . . . .	34
Figura 9 – Movimentação de partículas do PSO. . . . .	35
Figura 10 – Etapas do método proposto. . . . .	38
Figura 11 – Área de interesse. a) imagem sísmica com marcação do especialista; b) ROI. . . . .	39
Figura 12 – Método proposto para agrupar regiões de imagens sísmicas. . . . .	40
Figura 13 – Geração de amostras espaço-temporais. . . . .	43
Figura 14 – Procedimento para geração dos <i>patches</i> usando o PSO. . . . .	45
Figura 15 – Arquitetura do modelo proposto. . . . .	46
Figura 16 – Parque dos Gaviões . . . . .	48
Figura 17 – Exemplo de imagens sísmicas. O eixo y representa o tempo em milissegundos e o eixo x representa a distância em metros. . . . .	49
Figura 18 – Estudo de caso 1 - Base Gavião. (a) Preto, (b) Real, (c) Branco, e (d) Vermelho. Na cor vermelha, representa falsos positivos. Em azul, os verdadeiros positivos. Em verde, falsos negativos. . . . .	57
Figura 19 – Estudo de caso 2 - Base Gavião. (a) Preto, (b) Real, (c) Branco, e (d) Vermelho. Na cor vermelha, representa falsos positivos. Em azul, os verdadeiros positivos. Em verde, falsos negativos. . . . .	58

# Lista de tabelas

Tabela 1 – Resumo dos trabalhos relacionados. . . . .	19
Tabela 2 – Total de características extraídas em cada modelo de CNN. . . . .	49
Tabela 3 – Melhores grupos e seus coeficientes de silhueta encontrados para os modelos usando o método da silhueta. . . . .	50
Tabela 4 – Número de imagens sísmicas por campo de exploração. . . . .	50
Tabela 5 – Número de <i>patches</i> de treino por campo de exploração. . . . .	51
Tabela 6 – Número de <i>patches</i> de validação por campo de exploração. . . . .	51
Tabela 7 – Resultados por campo de exploração sem a etapa de agrupamento. . .	52
Tabela 8 – Resultados por campo de exploração com a etapa de agrupamento. . .	52
Tabela 9 – Resultados da comparação do método proposto com outros modelos sem a etapa agrupamento. . . . .	54
Tabela 10 – Resultados da comparação do método proposto com outros modelos com a etapa agrupamento. . . . .	54
Tabela 11 – Resultados do estudo de caso 1. . . . .	56
Tabela 12 – Resultados do estudo de caso 2. . . . .	57
Tabela 13 – Comparação com os trabalhos relacionados. . . . .	59
Tabela 14 – Produções científicas relacionadas ao tema da pesquisa proposta. . . .	64
Tabela 15 – Produções científicas não relacionadas ao tema da pesquisa proposta. .	65

# Lista de abreviaturas e siglas

Acc	Acurácia
AUC	<i>Area Under the ROC Curve</i>
CAD	<i>Computer Aided Detection</i>
CNN	<i>Convolutional Neural Network</i>
ConvLSTM	<i>Convolutional Long Short-Term Memory</i>
DHIs	<i>Direct Hydrocarbon Indicators</i>
Esp	Especificidade
F1	F1-score
FN	Falso Negativo
FP	Falso Positivo
LSTM	<i>Long Short-Term Memory</i>
mD	<i>Milidarcy</i>
MLP	<i>Multilayer Perceptron</i>
O&G	<i>Oil and gas</i>
Prec	Precisão
PSO	<i>Particle Swarm Optimization</i>
ReLU	<i>Rectified Linear Units</i>
ResNet	<i>Residual Network</i>
RNAs	Redes Neurais Artificiais
Sen	Sensibilidade
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
VGG	<i>Visual Geometry Group</i>

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
<b>1.1</b>	<b>Objetivo Geral</b>	<b>15</b>
1.1.1	Objetivos Específicos	15
<b>1.2</b>	<b>Organização do Trabalho</b>	<b>16</b>
<b>2</b>	<b>TRABALHOS RELACIONADOS</b>	<b>17</b>
<b>2.1</b>	<b>Considerações Finais</b>	<b>19</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>20</b>
<b>3.1</b>	<b>Gás Natural</b>	<b>20</b>
<b>3.2</b>	<b>Sísmica</b>	<b>21</b>
<b>3.3</b>	<b>Aprendizado Profundo</b>	<b>24</b>
3.3.1	Redes Neurais Convolucionais	25
3.3.2	Redes Neurais Recorrentes	26
3.3.2.1	<i>Convolutional Long Short-Term Memory</i>	27
<b>3.4</b>	<b>Extração de <i>Deep Features</i></b>	<b>30</b>
3.4.1	VGG-16, ResNet-50 e EfficientNet-B7	30
<b>3.5</b>	<b>Agrupamento</b>	<b>32</b>
3.5.1	K-Means	32
<b>3.6</b>	<b>Algoritmo Evolutivo</b>	<b>33</b>
3.6.1	<i>Particle Swarm Optimization (PSO)</i>	34
<b>3.7</b>	<b>Métricas de Desempenho</b>	<b>36</b>
<b>3.8</b>	<b>Considerações Finais</b>	<b>37</b>
<b>4</b>	<b>MÉTODO PROPOSTO</b>	<b>38</b>
<b>4.1</b>	<b>Pré-processamento</b>	<b>38</b>
4.1.1	Região de Interesse (ROI)	39
4.1.2	Agrupamento de Regiões de Imagens Sísmicas 2D	40
4.1.3	Geração de Amostras Espaço-temporais	42
4.1.4	Otimização das Amostras usando PSO	43
<b>4.2</b>	<b>Detecção de Potenciais Acumulações de Gás usando Arquitetura ConvLSTM</b>	<b>45</b>
<b>4.3</b>	<b>Considerações Finais</b>	<b>46</b>
<b>5</b>	<b>RESULTADOS</b>	<b>47</b>
<b>5.1</b>	<b>Base de Imagens Sísmica 2D</b>	<b>47</b>

5.1.1	Agrupamento de Regiões de Imagens Sísmicas 2D . . . . .	48
5.1.2	Preparação da Base de Imagens e Configuração Experimental . . . . .	50
<b>5.2</b>	<b>Resultados por Campo . . . . .</b>	<b>52</b>
<b>5.3</b>	<b>Comparação com Outras Abordagens . . . . .</b>	<b>53</b>
<b>5.4</b>	<b>Considerações Finais . . . . .</b>	<b>55</b>
<b>6</b>	<b>DISCUSSÃO . . . . .</b>	<b>56</b>
6.1	Estudos de Caso . . . . .	56
6.2	Comparação com Trabalhos Relacionados . . . . .	58
6.3	Aspectos Importantes do Método Proposto . . . . .	60
6.4	Considerações Finais . . . . .	62
<b>7</b>	<b>CONCLUSÃO . . . . .</b>	<b>63</b>
7.1	Contribuições . . . . .	63
7.2	Trabalhos Futuros . . . . .	64
7.3	Produções Científicas . . . . .	64
	<b>REFERÊNCIAS . . . . .</b>	<b>66</b>

# 1 Introdução

A história da cultura humana pode ser vista como o desenvolvimento progressivo de novas fontes de energia e suas tecnologias de conversão associadas. Esses desenvolvimentos aumentaram o conforto, a longevidade e a riqueza dos humanos, bem como seus números. As principais fontes de energia da antiguidade eram todas derivadas diretamente do sol: músculos humanos, energia por esforço animal, madeira, água corrente e vento (HALL et al., 2003).

A revolução industrial fez uso inicialmente de tecnologias estacionárias movidas a energia eólica e água, que ao passar dos anos foram sucessivamente substituídas por hidrocarbonetos fósseis. O carvão era o combustível de escolha no século XIX e início do século XX, mas foi gradualmente substituído pelo petróleo logo após a Segunda Guerra Mundial (HALL et al., 2003). Nas últimas três décadas, houve um aumento gradual na participação do gás natural na matriz energética global. No entanto, é importante destacar que os três principais combustíveis fósseis - carvão, petróleo e gás natural - ainda representam mais de 85% da energia primária utilizada em todo o mundo, e essa proporção não mudou significativamente ao longo do tempo. Em contraste, outras fontes de energia, como a nuclear, hídrica e renovável, ainda desempenham um papel muito menor na matriz energética global (ECONOMIDES; WOOD, 2009).

Além de todas as fontes de energia de hidrocarbonetos, o gás natural é a mais limpa e rica em hidrogênio e possui alta eficiência de conversão de energia para geração de energia. Existem muitos recursos de gás natural descobertos, mas os recursos inexplorados ainda são abundantes (KIDNAY; PARRISH, 2006). O setor de exploração de gás natural está preparado para um crescimento considerável nas próximas duas décadas (2020 e 2030) e acredita-se que ultrapassará o petróleo como combustível principal (ECONOMIDES; WOOD, 2009).

Hidrocarbonetos são compostos à base de carbono e hidrogênio. Suprimentos de energia, como o gás natural, estão presentes em hidrocarbonetos. A presença de hidrocarbonetos varia no espaço e no tempo, pois importantes regiões produtoras já esgotaram suas reservas e novas são descobertas em outras áreas (TEIXEIRA et al., 2009). As técnicas de reflexão sísmica são comumente usadas no setor de gás para investigações geofísicas (COX, 1999) para localizar e avaliar a quantidade desses depósitos.

A reflexão sísmica é um dos métodos geofísicos mais utilizados na indústria de petróleo e gás (O&G). Consiste em gerar uma onda de energia massiva na superfície através da detonação controlada de explosivos para capturar o retorno dessa onda após se propagar pelo solo (MORTON-THOMPSON; WOODS et al., 1993). Por meio da reflexão sísmica é

possível extrair informações relacionadas a estruturas geológicas, litologia e propriedades de rochas (POCHET et al., 2018; DI; WANG; ALREGIB, 2018b; CHEVITARESE et al., 2018b). Além disso, esse método também tem sido usado para estimar a localização e o volume das acumulações de gás, contribuindo para a redução dos riscos exploratórios.

No entanto, a reflexão sísmica produz uma grande quantidade de informações, exigindo tempo e esforço consideráveis de equipes especializadas para interpretar os dados sísmicos. A interpretação desses dados sísmicos é um desafio árduo devido à sua baixa resolução e ruído. Além disso, é comum que os membros da equipe discordem da interpretação e considerem que partes dos dados podem ser reinterpretadas (PATEL et al., 2008). Inclusive, o tempo destinado à interpretação dos dados não é compatível com os prazos curtos impostos pela indústria e o volume de dados que precisam ser analisados (SANTOS, 2019).

Nas mais diversas áreas de pesquisa, nas quais são utilizados grandes volumes de dados, com um curto período de tempo, técnicas de aprendizado de máquina são usadas para solucionar os mais diversos problemas. Em campos como processamento de linguagem natural (COLLOBERT; WESTON, 2008), processamento de imagens (KRIZHEVSKY; SUTSKEVER; HINTON, 2012) e processamento de sinal (ROY; KIRAL-KORNEK; HARRER, 2018), essa técnica vem crescendo e produzindo resultados cada vez mais expressivos, eficientes e confiáveis.

Em geofísica, o uso de técnicas de aprendizado de máquina enfrenta dificuldades que não são encontradas nas demais áreas mencionadas acima. Há grande dificuldade em comprovar a existência ou não de reservatórios de gás, pois o processo de perfuração de poços é muito caro, o que torna o número de dados confiáveis pequeno, pois não há certeza da existência de reservatórios até serem perfurados. Devido a essa limitação na quantidade de dados rotulados, o treinamento se torna bastante desafiador. Por exemplo, para detectar assinaturas de gás (SANTOS, 2019), requer que muitas amostras sejam rotuladas como região de gás ou não. No entanto, esta informação, na maioria dos casos, não está disponível.

Técnicas para gerar dados sintéticos podem ser usadas para aumentar a quantidade de dados rotulados. A vantagem de aplicar esse tipo de estratégia é evitar que o modelo aprenda possíveis ruídos contidos nos dados, bem como aumentar a robustez do modelo construído com dados levemente distorcidos. Em sísmica, existem trabalhos focados em gerar bases sintéticas para simular falhas sísmicas (ARAYA-POLO et al., 2017; WU et al., 2020), mas para gerar dados sísmicos que simulem a detecção de potenciais acumulações de gás é significativamente mais complexo (SANTOS, 2019). Outra maneira de lidar com a escassez de dados sísmicos é usar uma abordagem baseada em *patches* em vez da imagem completa (KARIMI; WARD, 2016), na qual é possível gerar uma quantidade maior de amostras para o treinamento. Assim, é possível alimentar uma rede neural com

uma quantidade substancialmente maior de dados sem ter que fazer novas anotações de reservatórios de gás.

Por essas razões, a tarefa de detectar potenciais acumulações de gás em imagens sísmica torna-se significativamente complexa e desafiadora. Dessa forma, métodos automáticos e robustos podem ser cruciais para superar essas dificuldades. Portanto, o problema abordado nesta pesquisa consiste em propor um método automático capaz de detectar potenciais acumulações de gás em imagens sísmicas usando abordagens espaço-temporal.

As principais contribuições deste trabalho são resumidas a seguir: (a) este estudo propõe um método automatizado para detecção de gás em sísmica de reflexão; (b) desenvolvimento de um método automático para encontrar padrões de características existentes na base de imagens e organizá-la em grupos; (c) método com abordagem espaço-temporal a partir de imagens sísmicas 2D; (d) modelo ConvLSTM em arquitetura codificador-decodificador para aprendizado de dependências espaço-temporal. Com isso, as técnicas poderão ainda ser incorporadas a um sistema do tipo Detecção Auxiliada por Computador (*Computer Aided Detection* - CAD) e, portanto, contribuir para o aumento da produtividade e melhoria na tarefa de detecção de gás em imagens sísmicas de reflexão.

## 1.1 Objetivo Geral

O objetivo geral deste trabalho é desenvolver um método para detectar potenciais acumulações de gás natural em imagens sísmicas, usando principalmente uma técnica de agrupamento de regiões sísmicas, uma Rede Neural Convolutiva (*Convolutional Neural Networks* - CNN) combinando as operações de convolução com células de *Long Short Term Memory* (ConvLSTM) e o algoritmo *Particle Swarm Optimization* (PSO) para otimizar os hiperparâmetros de modelagem da sequência espaço-temporal sísmica.

### 1.1.1 Objetivos Específicos

Destacam-se como objetivos específicos deste trabalho:

- Desenvolver um método automático que visa encontrar padrões de características existentes na base de imagens para organizá-la em grupos, de forma a garantir um modelo de aprendizagem profunda mais equilibrado e generalizado;
- Utilizar técnicas de aprendizado profundo no contexto de sísmica e séries temporais;
- Avaliar o método proposto por meio de métricas comumente usadas em trabalhos de imagens sísmicas;

- Aplicar o algoritmo de otimização PSO na etapa de preparação dos dados sísmicos na escolha de *patches* adequados para transportar informações espaço-temporais significativas;
- Comparar e avaliar o método proposto com outras abordagens da literatura.

## 1.2 Organização do Trabalho

Os demais capítulos deste trabalho foram organizados em:

- O Capítulo 2 apresenta um resumo dos trabalhos relacionados à tarefa de detecção de potenciais acumulações de gás em imagens sísmica.
- O Capítulo 3 trata dos conceitos fundamentais necessários para a compreensão do método proposto.
- O Capítulo 4 apresenta uma visão geral do método proposto e detalha cada uma de suas etapas.
- O Capítulo 5 mostra e discute os resultados alcançados no método proposto.
- O Capítulo 6 detalha vários estudos de casos e realiza uma análise comparativa com os trabalhos relacionados nesta pesquisa. Além disso, discute as vantagens e limitações encontradas no método proposto.
- Finalmente, o Capítulo 7 apresenta as considerações finais e as perspectivas de trabalhos futuros.

## 2 Trabalhos Relacionados

Na literatura existem trabalhos que tratam do mesmo problema abordado nesta dissertação. Isto é, métodos desenvolvidos para auxiliar especialistas na detecção de potenciais acumulações de gás em imagem sísmicas. Nesta Seção, são apresentados resumos dos trabalhos pesquisados relacionados a dados sísmicos.

Com o desenvolvimento da inteligência artificial, alguns trabalhos propuseram métodos para extrair feições sísmicas baseadas em técnicas de aprendizado de máquina. Métodos que usam aprendizagem profunda são capazes de aprender dinamicamente novos atributos relevantes durante seu treinamento, diferentemente dos métodos clássicos, nos quais é necessário extrair características. Devido a essa capacidade, métodos que usam aprendizagem profunda vêm sendo aplicados em diversas áreas e apresentando resultados expressivos. Por exemplo, CNNs foram usadas para detecção de falhas sísmicas (ARAYA-POLO et al., 2017; POCHEM et al., 2018; DI; WANG; ALREGIB, 2018b; GUITTON; WANG; TRAINOR-GUITTON, 2017), classificação de fácies sísmicas (ZHAO, 2018; CHEVITARESE et al., 2018a; CHEVITARESE et al., 2018b; WRONA et al., 2018), para identificar características geológicas de atributos sísmicos (HUANG; DONG; CLEE, 2017) e detecção e delineamento de domos de sal (DI; WANG; ALREGIB, 2018a). Além destes, diversos estudos foram desenvolvidos para detectar potenciais acumulações de gás, conforme descrito a seguir.

Devido à natureza ruidosa da aquisição de dados de gás natural, erros e divergências estão sujeitas entre os especialistas. Recentemente, o trabalho proposto por Cipriano et al. (2022) apresenta um método para detecção e delimitação automática da região do gás natural em imagens sísmicas (2D) utilizando MLP-Mixer e U-Net. O método proposto obteve resultados competitivos com F1-score de 84,18%, acurácia de 99,6%, sensibilidade de 86,85%, especificidade de 99,79%, usando a base de imagens sísmica denominada Netherlands F3-Block (SILVA et al., 2019).

Diniz et al. (2022) propuseram um método que utiliza uma Rede Neural Transformadora Profunda (Time2Vec Transformer) para detectar a probabilidade da existência de *Direct Hydrocarbon Indicators* (DHIs) em imagens sísmicas do Parque dos Gaviões. O método proposto foi capaz de detectar DHIs que demandam muito tempo e esforço humano em menos tempo e com maior precisão. Os melhores resultados obtiveram acurácia de 98,87%, sensibilidade de 96,12%, especificidade de 98,92% e área sob a curva ROC (*Area Under the ROC Curve* - AUC) de 97,52%.

Andrade et al. (2021a) apresentaram uma abordagem que usa a arquitetura *Long Short-Term Memory* (LSTM) codificador-decodificador estabelecida para modelar o pro-

blema de segmentação de gás natural. Além disso, foram mostradas algumas hipóteses sobre como minimizar os efeitos da qualidade da imagem por etapas de normalização e agrupamento de conjuntos de dados para melhorar a precisão do treinamento do modelo. A abordagem usa a base de imagens sísmica do Parque dos Gaviões, mas não informaram os resultados obtidos das métricas.

No trabalho de Santos et al. (2020) foi proposto o uso de técnicas de transferência de aprendizado para expandir o classificador existente e aplicá-lo a diferentes tipos de levantamentos sísmicos do Parque dos Gaviões. Além disso, para verificar essa metodologia baseada em rastreamento sísmico, outras redes baseadas em diferentes arquiteturas foram desenvolvidas usando um codificador-decodificador aprimorado LSTM (ANDRADE et al., 2021b). No melhor cenário, o método proposto obteve 97,62% de acurácia, 90,28% de sensibilidade, 97,67% de especificidade e 98,84% de AUC.

Outro método é apresentado por Santos (2019). O autor propôs uma nova metodologia para detectar DHIs usando dados sísmicos e uma rede neural LSTM unidimensional baseada em uma escala de traço sísmico. Nesse estudo, cada traço sísmico da base de imagens Netherlands F3-Block é dividido em *patches* que são a entrada da rede LSTM juntamente com a rotulagem de cada *patch*. A rede gera um mapa de probabilidades para encontrar gás em cada região da imagem sísmica. Os resultados alcançados avaliados pelos índices de sensibilidade, especificidade, acurácia e AUC foram 97,1%, 96,83%, 97,1% e 99,2%, respectivamente.

Em geral, os trabalhos relacionados descritos neste capítulo, apresentam diferentes abordagens e têm produzido resultados cada vez mais expressivos para solucionar o problema de detecção de potenciais acumulações de gás. É importante destacar que todos os estudos usaram aprendizado profundo em seus experimentos. A vantagem de usar essa técnica é que não há necessidade de engenharia de características para determinar as melhores para que um classificador seja capaz de distinguir as classes. Caberá à rede, ao usar camadas convolucionais, recorrentes ou de atenção, identificar as características mais eficazes para resolver o problema. No entanto, os trabalhos relacionados desenvolveram métodos para detectar regiões de potencial acúmulo de gás usando apenas características temporais ou espaciais, sem fazer uso combinado dessas duas características presentes na imagem sísmica 2D. Sendo assim, esses métodos podem não atingir sua generalização completa. Portanto, o método proposto visa combinar as informações temporais e espaciais a fim de obter um modelo mais eficiente e robusto para os mais diversos cenários sísmicos.

A Tabela 1 apresenta um resumo dos trabalhos relacionados descritos, nos quais são apresentadas informações sobre as técnicas de detecção, a base de imagens e os resultados obtidos.

Em resumo, pode-se observar que existem poucos trabalhos relacionados na literatura que abordam o problema de detecção de potenciais acumulações de gás natural em

Tabela 1 – Resumo dos trabalhos relacionados.

Técnicas	Base de imagens	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
MLP-Mixer e U-Net (CIPRIANO et al., 2022)	Netherlands F3-Block	84,18	86,85	83,82	99,79	99,6
Time2Vec Transformer (DINIZ et al., 2022)	Parque dos Gaviões	-	96,12	-	98,92	98,87
LSTM (ANDRADE et al., 2021a)	Parque dos Gaviões	-	-	-	-	-
LSTM (SANTOS et al., 2020)	Parque dos Gaviões	-	90,28	-	97,67	97,62
LSTM (SANTOS, 2019)	Netherlands F3-Block	-	97,1	-	96,83	97,1

imagens sísmicas 2D. Destaca-se, portanto, que esta tarefa é extremamente difícil, mesmo para geofísicos, de identificar visualmente estruturas que possam conter acumulações de gás natural (PATEL et al., 2008). Neste estudo, propõe-se um método promissor para detectar potenciais acumulações de gás usando abordagem espaço-temporal, ConvLSTM e PSO para auxiliar geofísicos.

## 2.1 Considerações Finais

Neste capítulo, foi feita uma revisão das produções científicas relevantes relacionadas à detecção de potenciais acumulações de gás natural em imagens sísmicas. Cada um dos métodos e seus resultados foram brevemente apresentados. Além disso, foram feitas considerações sobre as abordagens apresentadas, a fim de obter um panorama do que vem sendo produzido pela comunidade científica em relação ao tema em questão.

No próximo capítulo, a fundamentação teórica necessária para o desenvolvimento deste trabalho será apresentada.

## 3 Fundamentação Teórica

Neste capítulo, são abordados os tópicos essenciais para o entendimento das técnicas usadas na elaboração do método de detecção de potenciais acumulações de gás. As Seções a seguir tratam de conceitos sobre gás natural, sísmica, aprendizado profundo (redes neurais convolucionais e redes neurais recorrentes) e as métricas de desempenho para validar os resultados dos experimentos.

### 3.1 Gás Natural

O gás natural é uma substância composta por hidrocarbonetos que permanecem em estado gasoso em condições atmosféricas normais. É composto essencialmente pelos hidrocarbonetos metano ( $CH_4$ ) e etano ( $C_2H_6$ ) e, em menores proporções, o propano ( $C_3H_8$ ), butano ( $C_4H_{10}$ ) e pentano ( $C_5H_{12}$ ). Ocasionalmente, pequenos traços de hidrocarbonetos aromáticos leves, como benzeno ( $C_6H_6$ ) e tolueno ( $C_7H_8$ ), também podem estar presentes (DAKE, 1983; KENT, 2003; XAVIER et al., 2001). Esta composição pode variar devido à condição do reservatório de gás natural (BARBOSA; PEYERL, 2020).

O gás natural é o combustível fóssil mais limpo e eficiente. É um recurso não renovável que se forma quando camadas de matéria orgânica se decompõem em condições anaeróbicas e são submetidas a intenso calor e pressão no subsolo ao longo de milhões de anos (DARABOINA; PACHITSAS; SOLMS, 2015). Portanto, a origem do combustível fóssil é a decomposição de matéria orgânica enterrada, que fica armazenada nos poros das rochas dos reservatórios e aprisionada por rochas capsuladas que não permitem o trânsito de hidrocarbonetos do reservatório para a superfície (BARBOSA; PEYERL, 2020).

O gás natural é produzido tanto em associação com o petróleo (gás associado) como de forma independente (gás não associado). Ele começou a ser progressivamente incorporado à matriz energética dos países apenas nas décadas de 40 a 50, impulsionado principalmente pelos avanços nas tecnologias de condicionamento e transporte (QUINTELLA, 2014). Devido às suas propriedades físicas e químicas e à contínua evolução tecnológica, o gás natural pode ser usado nos diversos setores da atividade econômica, na produção de energia, como matéria-prima nas indústrias petroquímicas (plásticos, tintas, fibras sintéticas e borracha) e fertilizantes (ureia, amônia e seus derivados), comércio, habitação, setor de transporte, entre outros (ALMEIDA; FERRARO, 2013; KENT, 2003).

Há várias vantagens do uso de gás natural, como menor impacto ambiental entre os combustíveis fósseis (como o petróleo e o carvão mineral), ou seja, quase zero particulado e baixa emissão de dióxido de carbono ( $CO_2$ ), pode apresentar vantagem econômica em

relação ao preço de outros combustíveis, não requer locais de armazenamento e há grande segurança energética em toda a sua distribuição contínua (BARBOSA; PEYERL, 2020). Devido a esses fatores, há uma crescente demanda de gás natural no mundo, que se intensificou nos últimos anos devido à possibilidade de transporte desse combustível no estado líquido (BP, 2019). Outra razão para a crescente demanda são as preocupações com as mudanças climáticas e o uso de combustíveis de baixa emissão (FOREEST, 2010).

O uso de gás natural correspondeu a cerca de 13,3% da oferta de energia no Brasil em 2021 (EPE, 2022). Esse montante é absorvido principalmente pelos setores industrial e de energia. Na indústria, o gás natural funciona como matéria-prima e como fonte de energia para processos térmicos. As áreas mais consumidoras são aço, cerâmica e alimentos. Os demais setores (automotivo, residencial e comercial) são os menos consumidos devido à falta de infraestrutura e maior competitividade de outros combustíveis (MME, 2022). Assim, a crescente produção e demanda por gás natural no Brasil têm mostrado que este combustível fóssil tenderá a ter uma maior participação na matriz energética nos próximos anos (BARBOSA; PEYERL, 2020).

## 3.2 Sísmica

Geofísica é o estudo da física da Terra e seu ambiente no espaço. Uma ênfase é a exploração do interior da Terra usando propriedades físicas medidas na superfície da Terra ou acima dela, juntamente com modelos matemáticos para prever essas propriedades (WHEELER; CHEADLE, 2014). Os geofísicos adquirem, processam e interpretam dados coletados por instrumentos especiais para obter informações sobre a estrutura e composição de rochas em subsuperfície. Partes dos conhecimentos adquiridos sobre o interior da Terra vem de observações geofísicas. Exemplos disso são a existência e as propriedades da crosta, manto e núcleo da Terra que foram inicialmente determinadas por meio de observações de ondas sísmicas geradas por terremotos (THOMAS et al., 2004; ELIAS; ALDERTON, 2020).

As ondas sísmicas são movimentos vibratórios das partículas das rochas que se transmitem segundo superfícies concêntricas devido à libertação súbita de energia no foco sísmico. As ondas se propagam através da Terra, geralmente como consequência de um sismo, ou devido a uma explosão. Sismógrafos, sismógrafos e geofones são usados para analisar e quantificar essas ondas. Hidrofones também podem ser usados em estudos sísmicos de jazidas de petróleo (EEB, 2022; ELIAS; ALDERTON, 2020). Existem dois tipos de ondas sísmicas, ondas primárias e ondas secundárias. As ondas primárias (ondas P ou ondas de pressão) são ondas de compressão longitudinais semelhantes ao movimento de uma mola. As ondas secundárias (ondas S ou ondas transversais), são mais lentas que as ondas P e seu movimento é perpendicular à direção do curso da onda, semelhante ao

movimento de sacudir vigorosamente uma corda (EOF, 2022). Ondas sísmicas geradas artificialmente registradas durante pesquisas sísmicas são usadas para coletar dados em prospecção e engenharia de O&G (EEB, 2022).

Métodos sísmicos de refração e métodos sísmicos de reflexão são as duas principais categorias de métodos sísmicos. O método de refração envolve apenas a captura de ondas refratadas com um ângulo crítico e tem aplicações na área de sismologia. Essa técnica permitiu revelar a estrutura interna do planeta. No entanto, sua aplicação na área petrolífera é bastante restrita, embora tenha sido amplamente utilizada até meados da década de 50. Por outro lado, o método de reflexão é a técnica mais avançada em geofísica atualmente, graças à sua aplicação em larga escala na indústria de O&G. Com esse método, rende mais de 90% dos investimentos em prospecção, pois proporciona uma alta definição das feições geológicas em subsuperfícies propícias à acumulação de gás, a um custo menor (THOMAS et al., 2004; SELLEY; COCKS; PLIMER, 2005).

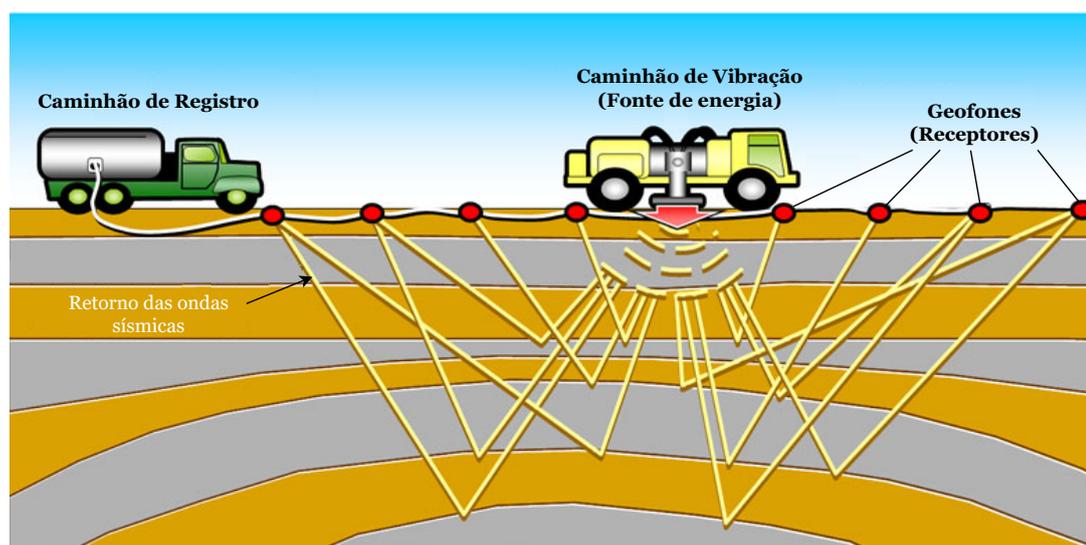
O levantamento sísmico no método de reflexão inicia-se com a geração de ondas elásticas, por meio de fontes artificiais, que se propagam pelo interior da Terra. Essas ondas são refletidas ou refratadas nas interfaces que separam rochas de diferentes estruturas e retornam à superfície onde são capturadas na forma de séries temporais, muitas vezes chamadas de traços sísmicos (THOMAS et al., 2004; ELIAS; ALDERTON, 2020). Para isso, deve haver uma fonte e um conjunto de receptores. A fonte é responsável por gerar um pulso ou uma detonação que se propagará pelas camadas geológicas e será refletida ou refratada, até retornar à superfície com informações valiosas para pesquisas em O&G. Os receptores são responsáveis por registrar as reflexões dos pulsos gerados pelas fontes, e podem ser de dois tipos: eletromagnéticos (chamados geofones) que são utilizados para registros em terra; e de pressão (chamados hidrofones) que usados para levantamentos na água (SELLEY; COCKS; PLIMER, 2005).

Considerando o método de reflexão, a aquisição consiste em gerar uma perturbação mecânica em um ponto da superfície e registrar as reflexões nos canais de recepção. A perturbação pode ser gerada por dinamites ou vibradores, na captura em terra, ou por canhões de ar em levantamentos marítimos. A duração dos pulsos é muito curta, da ordem de 200 milissegundos. Os receptores estão dispostos em linha reta e equidistantes a uma distância que varia de 20 a 50 metros. O número de receptores é muito grande, pode ser centenas, o que significa que o receptor mais distante está a quilômetros de distância da fonte (THOMAS et al., 2004; KROHN, 2008; SELLEY; COCKS; PLIMER, 2005).

A Figura 1 esquematiza um levantamento sísmico terrestre. Em resumo, um caminhão vibrador produz ondas que se propagam no subsolo. Ondas descendentes são refletidas por interfaces e se propagam para cima. As ondas de propagação ascendente são registradas por geofones. Neste trabalho, a coleta de dados sísmicos foi adquirida pelo processo de reflexão sísmica. A Figura 2 ilustra uma imagem sísmica 2D obtida pelo

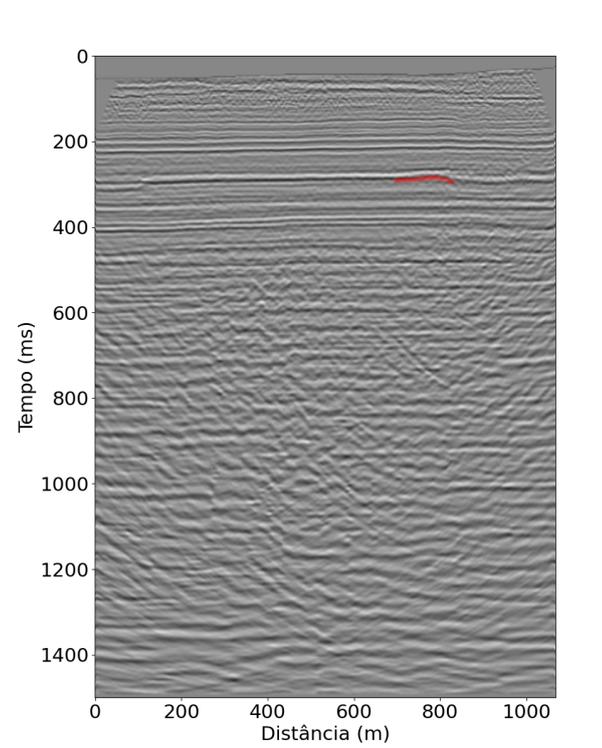
processo de reflexão sísmica.

Figura 1 – Processo de aquisição sísmica terrestre.



Fonte: Adaptado de (PAPATHANASAKI, 2020).

Figura 2 – Ilustração de uma imagem sísmica 2D. O eixo y representa o tempo em milissegundos e o eixo x representa a distância em metros. Na cor vermelha a região de gás sísmico.



Fonte: (MIRANDA et al., 2018).

### 3.3 Aprendizado Profundo

No processo de aprendizagem, humanos e animais são levados a primeiro interpretar e compreender conceitos simples para aprender conceitos mais complexos a partir de conceitos observados anteriormente ao longo de suas vidas (FERNANDES, 2013). Esse processo de aprendizado, conhecido como aprendizado profundo, sugere que o cérebro é hierarquicamente dividido em diferentes responsabilidades (HUBEL; WIESEL, 1998). O aprendizado profundo é um campo em rápida evolução, com novas arquiteturas sendo desenvolvidas com novos algoritmos de aprendizado para suportar a necessidade de construir máquinas eficientes semelhantes a humanos em diferentes domínios de aplicação (SENGUPTA et al., 2020).

O aprendizado profundo é um ramo da inteligência artificial e aprendizado de máquina que usa uma arquitetura hierárquica para aprender uma abstração abstrata de um conjunto de imagens. Essa é uma abordagem em evolução que é amplamente utilizada em áreas tradicionais de inteligência artificial, como análise semântica, aprendizado de transferência, processamento de linguagem natural e visão computacional (HURTADO; VALADA, 2022). Existem três fatores importantes para o crescimento do aprendizado profundo: o aumento da capacidade de processamento dos *chips* gráficos, os avanços consideráveis nos algoritmos de aprendizado de máquina e o custo significativamente reduzido do *hardware* de computação (GUO et al., 2016).

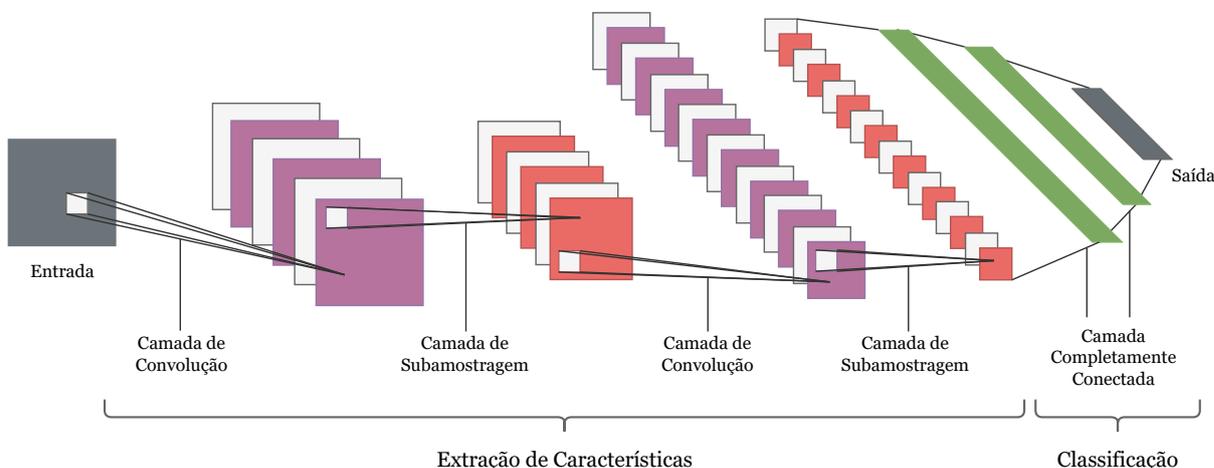
Técnicas de aprendizado profundo têm várias camadas de processamento não linear para reconhecimento de padrões semelhantes ao cérebro (LECUN; BENGIO; HINTON, 2015). Essas técnicas permitem a extração automática de características de conjuntos de treinamento sem a necessidade de várias técnicas de processamento de imagem ou reconhecimento de padrões, ao contrário das Redes Neurais Artificiais (RNAs) convencionais (HUA et al., 2015; MCCULLOCH; PITTS, 1943). Como resultado, as etapas de extração, seleção e classificação de características são abstraídas no próprio modelo com pouca intervenção humana (HUA et al., 2015; CHENG et al., 2016).

Atualmente, existem inúmeras técnicas de aprendizagem profundas disponíveis na literatura, como as redes neurais convolucionais, redes neurais recorrentes, redes de crença profundas, redes de memória de longo prazo e auto-codificadores esparsos empilhados. Diferentes arquiteturas têm diferentes benefícios dependendo da aplicação e das características dos dados envolvidos. Por exemplo, as redes neurais convolucionais são preferidas na visão computacional e as redes neurais recorrentes são preferidas na modelagem de sequências e séries temporais (SENGUPTA et al., 2020).

### 3.3.1 Redes Neurais Convolucionais

A Rede Neural Convolutiva (*Convolutional Neural Network* - CNN) (LECUN et al., 1998) é uma arquitetura de aprendizado profundo originalmente projetada para análise de imagens. As CNNs destinam-se especificamente a lidar com uma variedade de formas (1D, 2D e 3D). Portanto, são amplamente empregadas em reconhecimento visual, análise de imagens médicas, segmentação de imagens, processamento de linguagem natural e etc (LECUN et al., 1998; SARKER, 2021a). Geralmente, a CNN usa em sua arquitetura três tipos de camadas: (1) convolução, (2) subamostragem e (3) totalmente conectada (LECUN et al., 1998; NISHA; MEERAL, 2021). A arquitetura básica de uma CNN é mostrada na Figura 3.

Figura 3 – Exemplo de uma arquitetura básica CNN.



Fonte: Adaptado de (LIU et al., 2017).

Nas camadas de convolução, importantes características de baixo nível da imagem de entrada podem ser extraídas, como textura simples e bordas (LECUN; BENGIO; HINTON, 2015). A operação de convolução utilizando filtros múltiplos é capaz de extrair características (mapa de características) do conjunto de dados, através do qual suas informações espaciais correspondentes podem ser preservadas. A operação de subamostragem é usada para reduzir a dimensionalidade dos mapas de características da convolução (ZHU et al., 2018), mantendo as informações relevantes. Finalmente, a camada totalmente conectada conecta a rede à camada discriminante (camada de saída), que fornece a saída desejada (LECUN; BENGIO; HINTON, 2015). A seguir, são apresentados mais detalhes de cada camada.

O propósito da camada convolutiva é obter características significativas da imagem. A camada convolutiva convolve a imagem de entrada com um conjunto de *kernels* ou filtros e parâmetros apreensíveis (SARKER, 2021b). Os filtros são definidos por uma pequena área (por exemplo,  $3 \times 3$ ,  $5 \times 5$ ,  $7 \times 7$  *pixels*) e cada neurônio é conectado apenas aos neurônios próximos à camada anterior. Para cada filtro aplicado à

imagem de entrada, pode haver um neurônio conectado à saída de um subconjunto de neurônios da camada anterior. Os pesos são compartilhados entre os neurônios, fazendo com que os filtros aprendam os padrões frequentes que ocorrem em qualquer parte da imagem (LECUN; KAVUKCUOGLU; FARABET, 2010; GUO et al., 2016). Ao final do treinamento da rede, cada filtro será responsável por detectar uma característica específica da imagem (HAFEMANN, 2014).

Como mencionado, a camada de subamostragem reduz a dimensionalidade dos mapas de características. Normalmente, são posteriores às camadas de convolução. Essa camada calcula o valor médio (*average pooling*) ou máximo (*max-pooling*) dos mapas de características, e ajuda a gerar características mais abstratas (LeCun; Kavukcuoglu; Farabet, 2010; NISHA; MEERAL, 2021). Há também operações de *upsampling*. Basicamente, elas dobram a resolução dos mapas de características da camada anterior por operações de interpolação (LONG; SHELHAMER; DARRELL, 2015). No entanto, todos esses parâmetros são configuráveis.

Após extrair as características das imagens de entrada com as camadas de convolução e subamostragem, os mapas de características podem ser usados como entrada para as camadas totalmente conectadas. Os neurônios na camada totalmente conectada se conectam a todas as ativações na camada anterior, semelhante à estrutura *Multilayer Perceptron* (MLP) (PHAM et al., 2019). Portanto, as camadas totalmente conectadas classificam as características extraídas nas camadas anteriores para produzir a saída final (SRINIVAS; MOHAN, 2013).

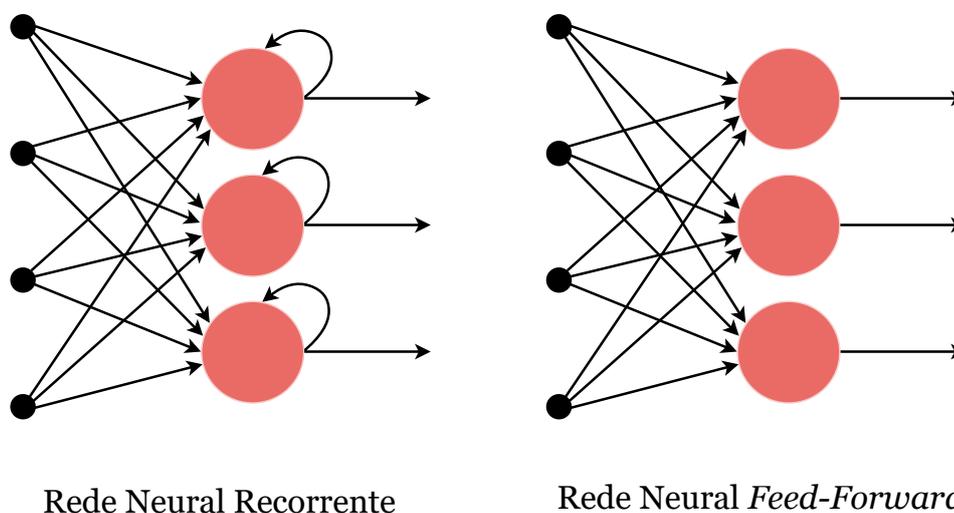
### 3.3.2 Redes Neurais Recorrentes

As redes neurais tradicionais assumem que os conjuntos de dados usados para o treinamento do modelo são independentes uns dos outros. No entanto, é uma desvantagem quando se trata de analisar dados onde as dependências sequenciais são importantes, como clima (HAN et al., 2021), tradução de texto (SINGH et al., 2020) e análise de sinais (MA et al., 2021). Para resolver isso, são usadas Redes Neurais Recorrentes (*Recurrent Neural Network* - RNN) (ELMAN, 1990).

RNN é uma rede neural popular, que emprega dados sequenciais ou de séries temporais e alimenta a saída da etapa anterior como entrada para o estágio atual (DUPOND, 2019; MANDIC; CHAMBERS, 2001). Assim como uma rede *feed-forward*, as redes recorrentes aprendem com a entrada de treinamento. No entanto, distinguem-se por sua “memória”, o que lhes permite impactar a entrada e a saída atuais por meio do uso de informações de entradas anteriores. Ou seja, esse tipo de estrutura reconecta a saída de um neurônio na camada oculta como um fluxo de alimentação para o mesmo neurônio da camada oculta. Ao contrário das redes neurais profundas típica, que assume que as entradas e saídas são independentes uma da outra (SARKER, 2021a). A Figura 4 ilustra

uma representação de uma RNN e uma rede *feed-forward*.

Figura 4 – Representação de uma RNN e uma rede *feed-forward*.



Fonte: Adaptado de (SINGH; KUZHAGALIYEVA; SARATHY, 2022).

Portanto, a RNN é uma extensão de uma rede neural *feed-forward* convencional que se concentra na modelagem do domínio temporal. Em sua estrutura, as RNNs possuem uma matriz de parâmetros adicional para conexões entre passos de tempo que promove o treinamento no domínio temporal e a exploração da natureza sequencial da entrada. As RNNs são treinadas para gerar saídas em que as previsões em cada etapa de tempo são baseadas na entrada atual e nas informações das etapas de tempo anteriores. RNNs são aplicáveis à análise de entrada no domínio da série temporal (SINGH; KUZHAGALIYEVA; SARATHY, 2022). A razão pela qual RNN pode lidar com séries temporais é que RNN tem um estado oculto recorrente cuja ativação em cada momento é dependente daquela do momento anterior (CHENG; ZHAO, 2019).

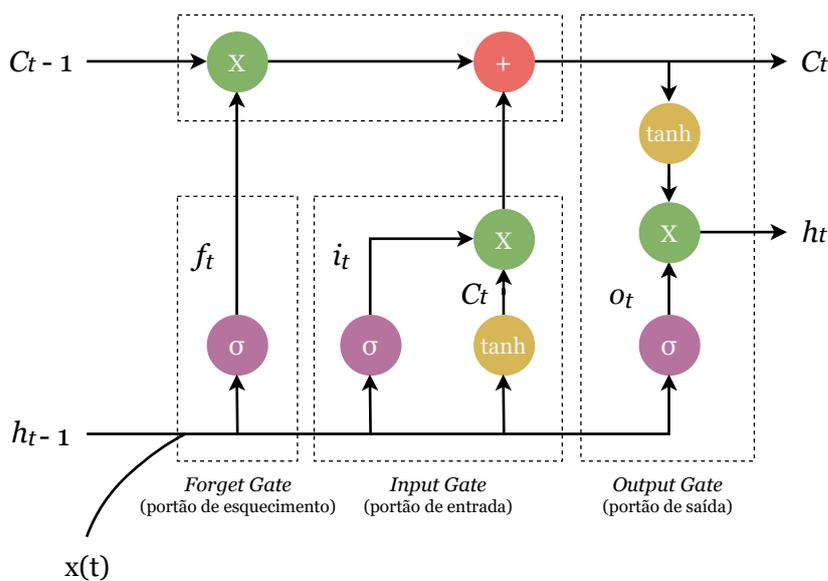
Em resumo, seu objetivo é imitar o comportamento do cérebro humano de manter uma memória sobre o passado, isto é, um dado de uma entrada anterior serve para entender os dados atuais. Dessa forma, ele pode ser usado para lidar com sequências de comprimento variável, na qual os dados têm uma relação temporal entre si.

### 3.3.2.1 Convolutional Long Short-Term Memory

ConvLSTM é uma arquitetura de rede recorrente muito semelhante à arquitetura LSTM (HOCHREITER; SCHMIDHUBER, 1997). A representação dos dados de entrada e o operador de convolução são as duas principais diferenças entre essas arquiteturas. A LSTM é projetada para analisar dados unidimensionais (1D), a ConvLSTM permite a representação de dados bidimensionais (2D) e tridimensionais (3D) (SHI et al., 2015a; HOCHREITER; SCHMIDHUBER, 1997). Uma arquitetura LSTM consiste em um conjunto de células de

memória conectadas recursivamente. Além disso, uma célula LSTM é composta pelo estado oculto e estruturas conhecidas como “portões”. Os portões são responsáveis por controlar a passagem de informações entre as células de memória que compõem a arquitetura LSTM (SHI et al., 2015a). Uma célula básica da arquitetura LSTM é apresentada na Figura 5.

Figura 5 – Célula básica de uma arquitetura LSTM.



Fonte: Adaptado de (BARBOSA et al., 2021).

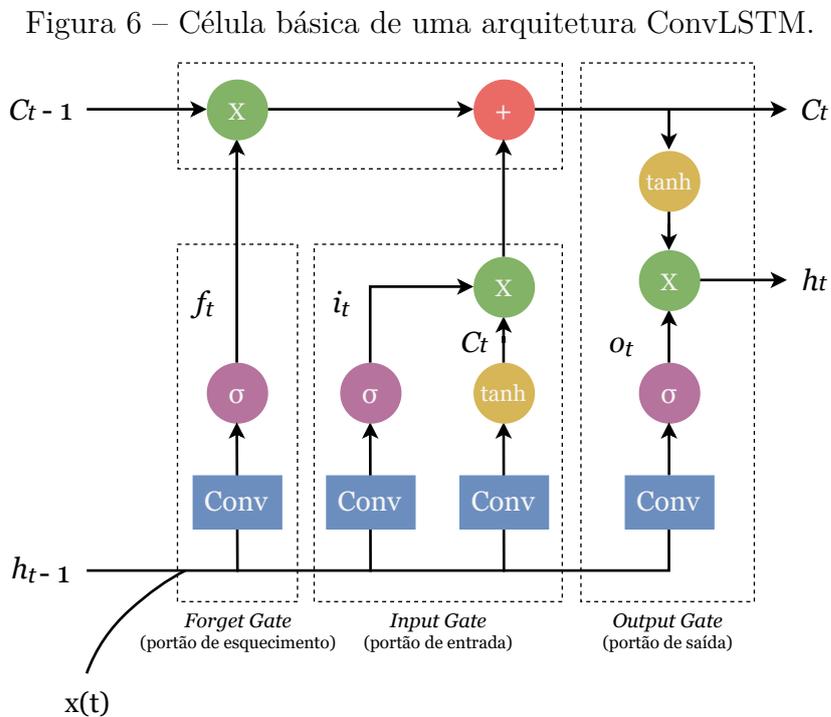
Existem três tipos de portões, sendo o primeiro o *Forget Gate* (portão de esquecimento) que decide quais informações devem ser descartadas, ou seja, esquecidas pela célula de memória. As duas entradas, que são as novas informações em um determinado momento ( $x_t$ ) e a previsão da célula anterior ( $h_{t-1}$ ), são alimentadas na porta e multiplicadas com matrizes de peso seguidas pela adição de polarização. Posteriormente, o resultado é passado por uma função de ativação que fornece uma saída binária. Se um determinado estado de célula a saída for 0, a informação é esquecida, se a saída for 1, a informação é retida para uso futuro. As possibilidades úteis serão armazenadas na célula (HOCHREITER; SCHMIDHUBER, 1997).

O segundo é o *Input Gate* (portão de entrada), que é responsável por adicionar informações ao estado da célula de memória. A partir das entradas  $h_{t-1}$  e  $x_t$ , a informação é regulada por meio da função “sigmoide”, que filtra os valores a serem lembrados de forma semelhante ao *Forget Gate*. Dessa forma, um vetor é criado usando a função “tanh” (tangente) que dá uma saída de -1 a +1, que contém todos os valores possíveis de  $h_{t-1}$  e  $x_t$ . Por fim, os valores do vetor e os valores regulados são multiplicados para obter a informação útil (HOCHREITER; SCHMIDHUBER, 1997).

Finalmente, o *Output Gate* (portão de saída) extrai informações úteis do estado da

célula de memória atual, direcionando-a para a próxima célula de memória. O operador  $\otimes$  refere-se ao produto Hadamard (YANG; XU, 2004). A função “tanh” é aplicada primeiro à célula para criar um vetor. Em seguida, a informação é regulada usando a função “sigmoide” e filtrada pelos valores a serem lembrados usando as entradas  $h_{t-1}$  e  $x_t$ . A previsão final será resultado da multiplicação do resultado do *Output Gate* e das possibilidades normalizadas que são fornecidas pela célula e pelo *Input Gate*. Como as possibilidades coletadas possuem valores que podem variar de mais de 1 a menos de -1, a função de ativação “tanh” é utilizada para normalização (HOCHREITER; SCHMIDHUBER, 1997).

Ao adicionar um operador de convolução às estruturas iniciais da arquitetura LSTM obtém-se uma célula ConvLSTM. Isto faz com que os dados que fluem pela célula sejam da forma de uma imagem, e não apenas um vetor 1D, como em uma simples LSTM. Portanto, ConvLSTM é uma rede neural de convolução CNN combinada com a rede LSTM. Em que, em vez de apenas a entrada de sequência de dados, sua entrada é uma sequência de dados da rede neural de convolução CNN que é mais adequada para imagens e vídeos. Neste caso, o estado futuro de uma célula é definido pelas entradas e estados passados de seus vizinhos. Essa combinação garante que o ConvLSTM seja uma ferramenta poderosa para capturar correlações espaço-temporais locais subjacentes (SHI et al., 2015a; SHI et al., 2015b). A Figura 6 ilustra uma célula básica da arquitetura ConvLSTM.



Fonte: Adaptado de (BARBOSA et al., 2021).

Uma vez que a rede esteja treinada em um nível satisfatório, a rede pode ser usada como uma ferramenta para classificar novos dados. Neste trabalho, a arquitetura

ConvLSTM baseada nos conceitos de CNN e RNN é usada para detectar potenciais acumulações de gás, mostrando-se uma ferramenta poderosa para análise espaço-temporal.

Neste trabalho, a ConvLSTM será o modelo principal para detecção das regiões com potenciais acumulações de gás devido a sua capacidade de aprender dependências espaço-temporais.

## 3.4 Extração de *Deep Features*

A tarefa de extrair características de uma imagem exige um alto nível de habilidade, o que requer muito tempo e esforço. Além de ser uma tarefa árdua, as características obtidas são, por vezes, específicas e restritas ao domínio do problema em questão. Como resultado, as soluções podem não ser suficientemente generalistas para representar problemas de outros domínios. Com o desenvolvimento de modelos de redes neurais profundas, tornou-se possível extrair características de forma automatizada (LECUN; BENGIO; HINTON, 2015).

Os extratores de características são as camadas da CNN. As camadas mais profundas aprendem a reconhecer o objeto na imagem, enquanto as camadas inferiores aprendem as características fundamentais (como contornos e arestas), as camadas intermediárias extraem informações como cor e forma e assim por diante. Além disso, essas redes apresentam uma camada totalmente conectada, que gera probabilidades finais para determinar a classe da imagem, ou seja, atua como um classificador (MOHAMED et al., 2020). A arquitetura CNN é ilustrada na Figura 7.

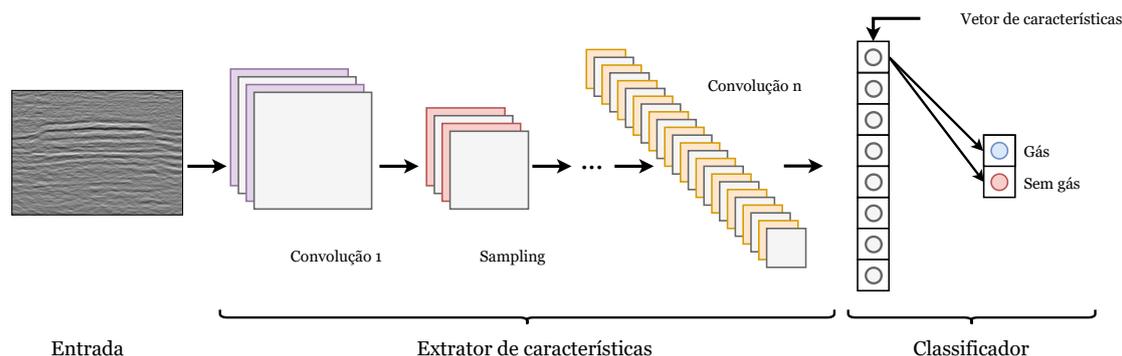
Neste trabalho, a técnica usada para extrair características é conhecida como “*deep features*”. As *deep features* consistem em remover a camada totalmente conectada de uma CNN convencional para obter um vetor de características como saída da rede (JÚNIOR et al., 2021). Assim, a CNN é convertida em um extrator automatizado de características. Essa abordagem segue o princípio da Figura 7. No entanto, mantém apenas o vetor de características para aplicar nas etapas posteriores.

Três arquiteturas de rede foram selecionadas para conduzir os experimentos extraíndo as características: VGG-16 (SIMONYAN; ZISSERMAN, 2014), ResNet-50 (HE et al., 2016a) e EfficientNet-B7 (TAN; LE, 2019). Nas próximas Subseções essas redes são detalhadas.

### 3.4.1 VGG-16, ResNet-50 e EfficientNet-B7

A arquitetura do Grupo de Geometria Visual (*Visual Geometry Group* - VGG) foi introduzida por Simonyan e Zisserman (2014). A arquitetura VGG é a base de modelos inovadores de reconhecimento de objetos. A VGG-16 é uma variante da VGG, consistindo

Figura 7 – Arquitetura CNN.



Fonte: Elaborado pelo autor.

em uma CNN avançada com camadas pré-treinadas e uma grande compreensão do que define uma imagem em termos de forma, cor e estrutura. A VGG-16 possui 16 camadas (13 camadas de convolução, 3 camadas totalmente conectadas, incluindo *Max pool*, camada *Rectified Linear Unit* (ReLU), camada *Dropout* e camada *Softmax* (BALDI; SADOWSKI, 2013; LAU; LIM, 2018)). A camada de entrada tem um tamanho de  $128 \times 128$ .

A ResNet (HE et al., 2016a) é uma abreviatura de *Residual Network* (Redes Residuais). As Redes Residuais formam uma família com várias redes neurais da mesma arquitetura que diferem apenas pelo tamanho de suas profundidades. A ResNet apresenta uma nova camada designada de unidade de aprendizagem residual, que visa atenuar a degradação da aprendizagem em redes neurais profundas (NGUYEN et al., 2018). As unidades residuais são conexões de atalho que conectam a saída de uma camada à entrada de outra ligeiramente anterior (HE et al., 2016a). O uso de blocos residuais pode fornecer melhor precisão de classificação sem aumentar a complexidade do modelo, além de aumentar a velocidade de treinamento (SZEGEDY et al., 2016). Neste trabalho, foi selecionada a rede ResNet-50, que consiste em 50 camadas (48 camadas de convolução e duas de *Pool*), além de consistir em camadas residuais, camada totalmente conectada e a camada *Softmax*. Assim como a VGG-16, a camada de entrada tem o tamanho de  $128 \times 128$ .

A EfficientNet (TAN; LE, 2019) é uma nova família de arquitetura de redes neurais que propõe um novo método de escalonamento de redes neurais. O escalonamento é uma técnica amplamente utilizada para melhorar o desempenho de arquiteturas já existentes. Um método simples, mas eficaz, que dimensiona uniformemente a largura, profundidade e resolução da rede. A EfficientNet-B7 é uma variante da EfficientNet-B0 que consiste em 7 blocos de dimensionamento e 3 camadas totalmente conectadas. Cada bloco apresenta um convolução 2D profunda, camada *Batch Normalization*, *Global Average Pooling*, camada de redimensionamento seguida por duas convoluções 2D. Semelhante às outras redes mencionadas, a camada de entrada desta rede tem um tamanho de  $128 \times 128$ .

Neste trabalho, são obtidas as características de saída da última camada de convo-

lução de cada arquitetura (VGG-16, ResNet-50 e EfficientNet-B7). Assim, o objetivo desta etapa é extrair características das regiões das imagens sísmicas 2D para posteriormente agrupá-las por suas similaridades. Por fim, experimentos individuais são realizados com as características adquiridas de cada rede por meio do algoritmo de agrupamento K-Means.

## 3.5 Agrupamento

Agrupamento (*clustering*) é um método de aprendizado não-supervisionado (BARLOW, 1989) que tem por objetivo dividir uma população ou os pontos de dados em vários grupos (*clusters*), de modo que os pontos de dados nos mesmos grupos sejam mais semelhantes a outros pontos de dados no mesmo grupo e diferentes dos pontos de dados em outros grupos (ROKACH; MAIMON, 2005). Originalmente, este método foi introduzido na pesquisa de mineração de dados como a classificação não supervisionada de padrões em grupos (GAERTLER, 2005).

O agrupamento é uma das primeiras etapas na análise de mineração de dados (ABBAS, 2008). Ele identifica grupos de registros relacionados que podem ser usados como ponto de partida para explorar padrões dentro de um determinado conjunto de dados (BERKHIN, 2006). Esse método dá suporte ao desenvolvimento de modelos de segmentação populacional, como a segmentação de clientes com base em características demográficas (ROKACH; MAIMON, 2005). Análises adicionais usando técnicas analíticas padrão e outras técnicas de mineração de dados podem determinar as características desses segmentos com relação a algum resultado desejado (ABBAS, 2008).

### 3.5.1 K-Means

O algoritmo de aprendizado não-supervisionado (BARLOW, 1989) K-Means é um dos métodos de agrupamento mais populares, pertencente a classes dos métodos de agrupamento por particionamento (*Partitioning Clustering*). Proposto inicialmente em 1967 por MacQueen (1967) como método de classificação e análises de observações multivariadas. É um algoritmo iterativo que tenta particionar o conjunto de dados em subgrupos distintos não sobrepostos pré-definidos (grupos) onde cada ponto de dados pertence a apenas um grupo. Desta forma, o algoritmo tenta tornar os pontos de dados semelhantes o mais próximo possível, ao mesmo tempo em que mantém os grupos mais diferentes o mais distante possível (SYAKUR et al., 2018).

O K-Means é um algoritmo de agrupamento baseado em distância que divide os dados em vários agrupamentos em atributos numéricos (JIN; HAN, 2010). Esse algoritmo requer na sua inicialização a quantidade de K-grupos que deverão ser gerados, uma vez que o centro inicial do grupo pode mudar de forma que este evento pode resultar em agrupamento instável de dados (SYAKUR et al., 2018). A saída do K-Means depende dos

valores centrais selecionados no agrupamento (JIN; HAN, 2010). Assim, o valor inicial do ponto central do grupo torna-se a base para a determinação do grupo. O centroide inicial do grupo atribui aleatoriamente um impacto ao desempenho do grupo.

Em resumo, o K-Means tem os seguintes passos:

- Determinar o número de K-grupos e a quantidade máxima de iterações.
- Aplicar o processo de inicialização K-grupo do ponto médio e, em seguida, a equação do recurso de contagem de centroides (Equação 3.1),

$$C_i = \frac{1}{M} \sum_{j=1}^M x_j. \quad (3.1)$$

- Calcular a soma da distância ao quadrado entre os pontos de dados e todos os centroides. Conforme a Equação 3.2,

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}. \quad (3.2)$$

- Atribuir cada ponto de dados ao grupo mais próximo (centroide).
- Calcular os centroides para os grupos tirando a média de todos os pontos de dados que pertencem a cada grupo (Equação 3.3),
- Persistir as iterações até que não haja alteração nos centroides, ou seja, a atribuição de pontos de dados para grupos não está mudando.

$$J = \sum_{i=1}^n \sum_{l=1}^k a_{il} D(x_i, c_l)^2, \quad (3.3)$$

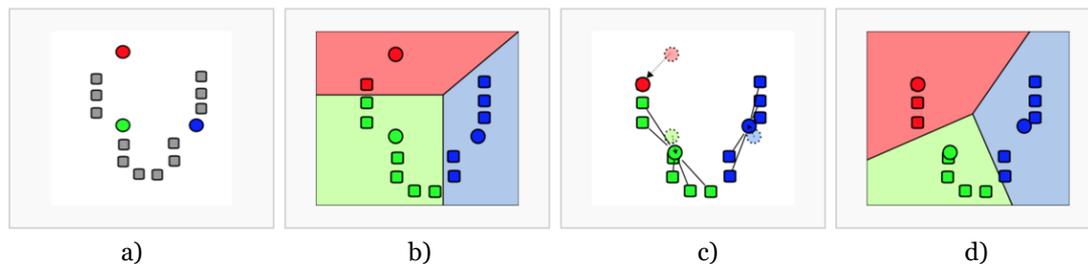
onde,  $a_{ij}$  é o valor de associação do ponto  $x_i$  para os centros do grupo  $c_l$ ,  $d$  é a distância mais curta dos dados  $x_i$  ao K-grupo após serem comparados, e  $c_l$  é o centro do grupo para  $l$ .  $n$  é a quantidade de dados,  $k$  é o número de grupos,  $a_{i1}$  é o valor de associação do ponto de dados  $x_i$  para o grupo  $c_1$  seguido de  $a$  que tem um valor de 0 ou 1. As etapas do algoritmo são ilustradas na Figura 8.

Neste trabalho, a etapa de agrupamento visa agrupar regiões sísmicas semelhantes para construir modelos específicos para cada grupo de forma que seus treinamentos sejam equilibrados a fim de obter melhores desempenhos e robustez.

## 3.6 Algoritmo Evolutivo

Algoritmo evolutivo é um componente da computação evolucionária e da computação bioinspirada (BÄCK; FOGEL; MICHALEWICZ, 1997). Esses algoritmos são baseados

Figura 8 – Etapas do K-Means. a)  $k = 3$  e os centroides são gerados aleatoriamente com os dados do domínio; b) grupos são gerados com base na distância; c) o novo centroide de cada grupo é atualizado; d) passos b e c são repetidos até a convergência.



Fonte: (CHEON; LEE; LEE, 2020).

em heurísticas para resolver problemas de difícil resposta em tempo polinomial. Para isso, usam como base o princípio de evolução inspirado na natureza: sobrevivência do mais apto, por meio de processos que emulam os comportamentos dos organismos vivos. Esses algoritmos são frequentemente empregados na ciência e na engenharia para lidar com problemas complexos de otimização (DASGUPTA; MICHALEWICZ, 1997). Esses tipos de algoritmos possuem essencialmente um conjunto de soluções candidatas, que representam indivíduos. Esses indivíduos evoluem e competem pela sobrevivência a cada nova geração, e apenas os melhores indivíduos têm as melhores chances de sobreviver (GABRIEL; DELBEM, 2008).

Otimização trata-se do estudo de problemas em que se busca minimizar ou maximizar uma função por meio da escolha sistemática de valores. Neste estudo, o algoritmo evolutivo denominado *Particle Swarm Optimization* (PSO) foi usado para otimizar o conjunto de hiperparâmetros das amostras espaço-temporais. O objetivo deste ajuste de hiperparâmetros é encontrar o conjunto de amostras que melhor representa o problema, consequentemente, maximizar as métricas de validação do modelo. O algoritmo PSO foi escolhido porque produz soluções de alta qualidade que oferecem melhor desempenho (ISLAM et al., 2019).

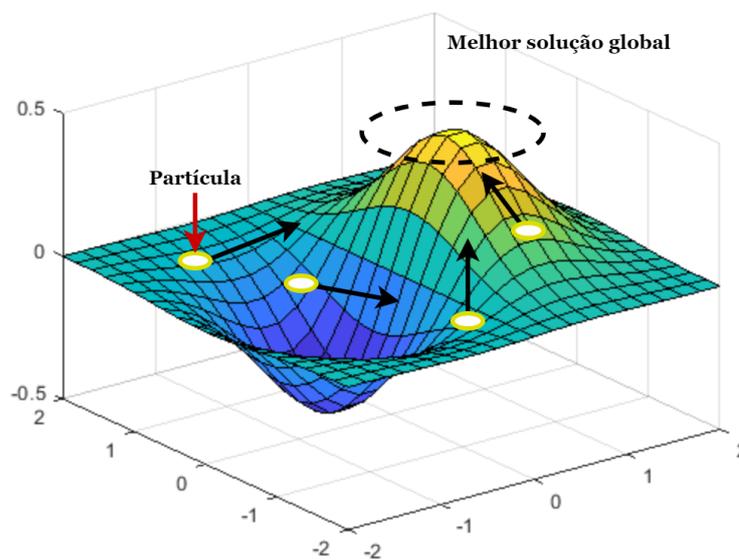
### 3.6.1 *Particle Swarm Optimization* (PSO)

O algoritmo evolutivo PSO é uma das meta-heurística mais conhecidas. Foi proposto inicialmente em 1995 por Eberhart e Kennedy (1995) como uma metodologia para resolver problemas não lineares contínuos. É uma técnica inspirada em enxame e comportamentos colaborativos de populações biológicas (EBERHART; KENNEDY, 1995). Embora tenha havido modificações e melhorias significativas desde que foi introduzido pela primeira vez, os princípios fundamentais permaneceram os mesmos.

Em geral, uma “população” de soluções possíveis para o problema é criada primeiro

com cada solução sendo pontuada usando uma “função de aptidão” que indica quão boas elas são (GABRIEL; DELBEM, 2008). O PSO busca uma solução ótima alterando iterativamente as velocidades e posições das partículas de acordo com as experiências de voo da partícula e do grupo, orientando-os para a localização dos hiperparâmetros  $Gbest$  e  $Pbest$  nas iterações subsequentes.  $Gbest$  corresponde ao valor de aptidão (*fitness*) da população alcançado por qualquer partícula. Enquanto  $Pbest$  corresponde ao valor ótimo de aptidão de partícula alcançado até a iteração presente (KENNEDY, 2010). O movimento das partículas do PSO é ilustrado na Figura 9.

Figura 9 – Movimentação de partículas do PSO.



Fonte: (JUNIOR, 2020).

As Equações 3.4 e 3.5 descrevem a atualização do movimento da partícula para cada iteração:

$$v_i = w \cdot v_i + (C_1 \cdot r_1 \cdot (Pbest - x_i)) + (C_2 \cdot r_2 \cdot (Gbest - x_i)), \quad (3.4)$$

$$x_i = x_i + v_i, \quad (3.5)$$

onde  $i$  denota a partícula e  $x$  sua posição no espaço.  $w$  é a constante de inércia, que representa o impacto das velocidades anteriores na velocidade atual.  $C_1$  é a constante que atrai cada partícula para sua melhor posição local, e  $C_2$  é a constante que atrai a partícula para a melhor posição. Por fim,  $r_1$  e  $r_2$  são números aleatórios entre 0 e 1.

Em resumo, após definir a partícula, seus limites e sua função de aptidão, são realizados os seguintes passos (LE et al., 2019):

- Passo 1: uma população de dez partículas aleatórias é criada. Em seguida, a função de aptidão de cada partícula é calculada.
- Passo 2: cada partícula percorre de forma circular no espaço de busca em uma velocidade inicial, conforme estabelecido na etapa anterior. Para cada iteração, busca-se a partícula local ótima. O melhor resultado geral representa a melhor partícula atual. As velocidades também são atualizadas durante esta etapa.
- Passo 3: depois de calcular e atualizar a velocidade, as partículas percorrem o espaço de busca nessa nova velocidade.
- Passo 4: a melhor localização e o melhor resultado geral são atualizados para a melhor posição, de acordo com a função de aptidão.
- Passo 5: a condição de parada de pesquisa é verificada. Caso a função de aptidão da partícula for ótima, a busca é interrompida. Caso contrário, retorna ao Passo 2.

Neste trabalho, a otimização de hiperparâmetros é uma etapa fundamental. Para isso, o algoritmo PSO foi escolhido para otimizar os hiperparâmetros das amostras espaço-temporais, tais como o número de amostras, largura e altura.

### 3.7 Métricas de Desempenho

Para validar os resultados alcançados por um método proposto, a quantificação dos resultados é comumente adotada. O objetivo é avaliar o desempenho do método construído por meio da análise estatística dos resultados obtidos. Neste estudo, foram aplicadas métricas frequentemente aplicadas na área de imagens médicas e na literatura, sendo elas: acurácia, precisão, sensibilidade, especificidade e F1-score (FAWCETT, 2006; BLAND, 2015; TAHA; HANBURY, 2015)

Para o cálculo das métricas, baseou-se na matriz de confusão, que leva em consideração 4 variáveis: (1) Verdadeiro Positivo (VP) indica a classificação correta dos *pixels* da classe positiva, ou seja, potenciais acumulações de gás; (2) Falso Positivo (FP) trata da classificação incorreta dos *pixels* da classe negativa como classe positiva; (3) Verdadeiro Negativo (VN) denota a classificação correta dos *pixels* da classe negativa; e (4) Falso Negativo (FN) indica erro de classificação dos *pixels* da classe positiva como classe negativa.

A acurácia (*Acc*) é a métrica definida como a razão entre o número de *pixels* corretamente classificados (classe positiva e negativa) e a quantidade total de *pixels* na amostra do estudo. A acurácia é definida na Equação 3.6,

$$Acc = \frac{VP + VN}{VP + VN + FP + FN}. \quad (3.6)$$

A precisão (Pre) é denotada como o número de casos positivos dividido pelo número de casos positivos mais o número de falsos positivos. Em suma, é a porcentagem de instâncias classificadas na classe positiva realmente correta. A precisão é definida na Equação 3.7,

$$Pre = \frac{VP}{VP + FP}. \quad (3.7)$$

A sensibilidade (Sen) tem a capacidade de encontrar todas as instâncias relevantes (verdadeiros positivos) na amostra em estudo, ou seja, expressa a proporção de verdadeiros positivos. O cálculo da sensibilidade é definida na Equação 3.8,

$$Sen = \frac{VP}{VP + FN}. \quad (3.8)$$

Outra métrica aplicada é a especificidade (Esp). Essa métrica indica a capacidade de prever corretamente a classe negativa, ou seja, a proporção de verdadeiros negativos. A Equação 3.9 define esta métrica,

$$Esp = \frac{VN}{VN + FP}. \quad (3.9)$$

Por fim, como há desbalanceamento entre as classes de gás e não-gás, foi usada a métrica F1-score (F1), que representa a média harmônica entre a precisão (Pre) e a sensibilidade (Sen). Essa métrica é definida na Equação 3.10,

$$F1 = 2 * \frac{Pre * Sen}{Pre + Sen}. \quad (3.10)$$

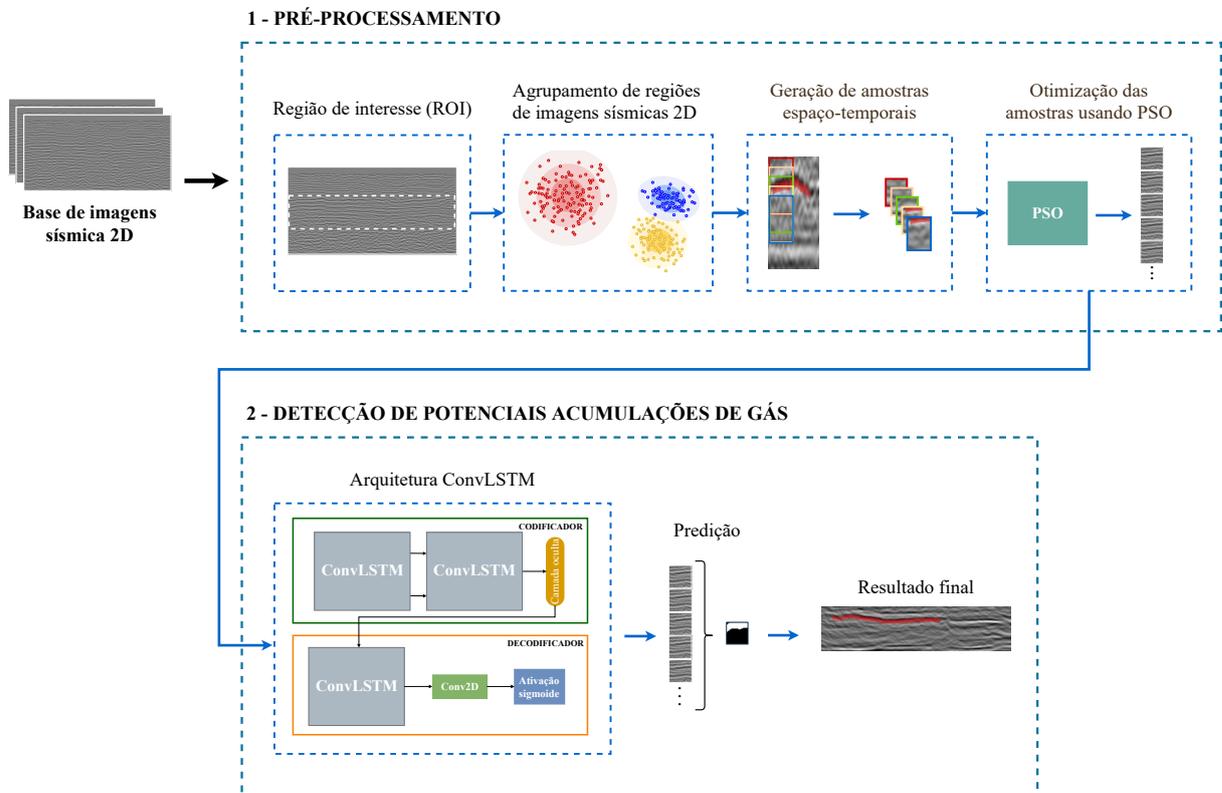
## 3.8 Considerações Finais

Neste capítulo, foi apresentada a fundamentação teórica necessária para a compreensão das técnicas usadas e suas aplicações no método proposto. Os principais tópicos abordados foram gás natural, sísmica, aprendizado profundo (CNN e RNN), agrupamento (K-Means), algoritmo evolutivo (PSO) e métricas de desempenho.

## 4 Método Proposto

Este capítulo descreve o método proposto para detectar regiões de acúmulo de gás. Para isso, são realizadas duas etapas, que são apresentadas em detalhes posteriormente. A base de imagens sísmica usada para validar o método proposto é descrita na Seção 5.1. A primeira etapa descreve as técnicas de pré-processamento aplicadas às imagens sísmicas. Por fim, a segunda etapa apresenta o modelo de rede neural usado para a detecção de potenciais acumulações de gás. A Figura 10 ilustra as etapas do método proposto.

Figura 10 – Etapas do método proposto.



Fonte: Elaborado pelo autor.

### 4.1 Pré-processamento

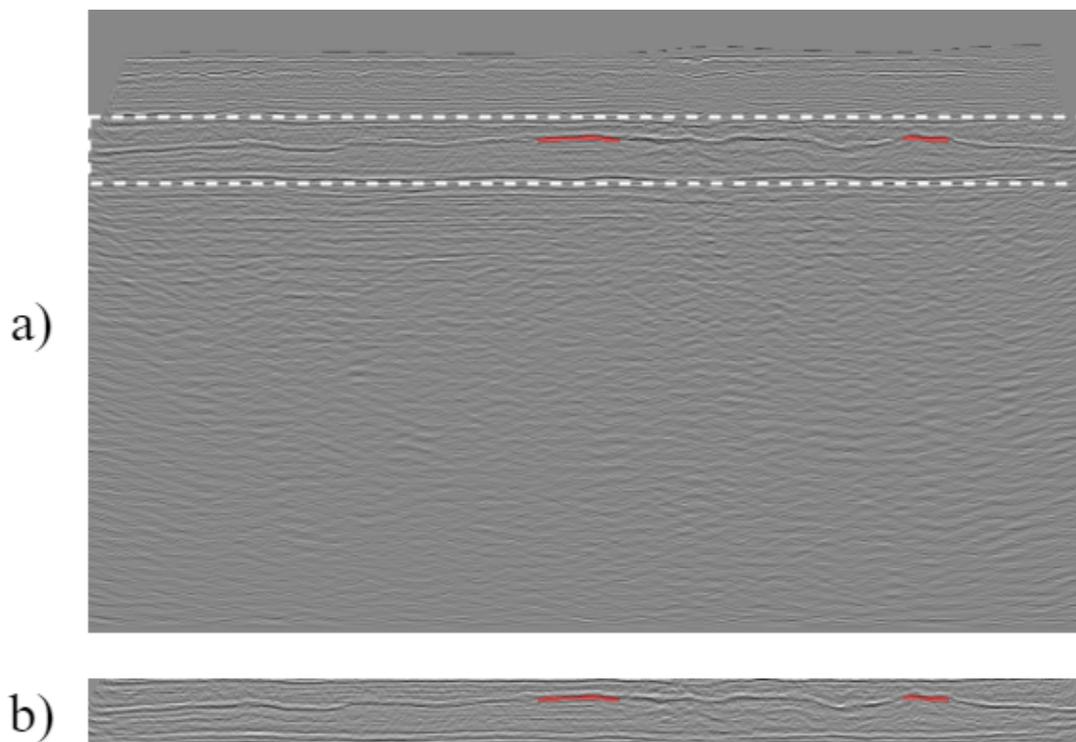
Na primeira etapa do método proposto, são aplicadas subetapas aplicadas a base de imagens sísmica 2D. A primeira subetapa, consiste em delimitar a região de interesse (ROI) das imagens. Em seguida, é realizado o agrupamento das regiões de imagens sísmicas 2D para cada campo de exploração da base de imagens. Posteriormente, são geradas amostras espaço-temporais das regiões agrupadas que servirão para última subetapa, que é a otimização das amostras usando o PSO. Finalmente, as amostras geradas serão usadas

para a segunda etapa, que é a detecção de potenciais acumulações de gás (Seção 4.2). Nas próximas Subseções, cada subetapa será explicada com mais detalhes.

#### 4.1.1 Região de Interesse (ROI)

Na primeira etapa do método proposto, é aplicado um processo de normalização dos valores de amplitude sísmica devido à heterogeneidade desses valores em razão aos diferentes processos de aquisição e processamentos sísmicos (SELLEY; COCKS; PLIMER, 2005; MIRANDA et al., 2018). Assim, a técnica de padronização (*standardization*) foi selecionada para esse processo devido à característica dos valores de amplitude sísmica de se aproximarem de uma distribuição gaussiana (PAINTER; BERESFORD; PATERSON, 1995). A padronização consiste em colocar todos os dados em um intervalo em que a média é igual a zero e o desvio padrão igual a um (PAINTER; BERESFORD; PATERSON, 1995). Em seguida, é necessário determinar um intervalo de busca relevante para detecção do gás. Desta forma, com base em dados de campo, poços exploratórios perfurados e inferência, os geocientistas da Eneva S.A delimitaram Regiões de Interesse (ROI) que possuem maior probabilidade de conter acúmulo de gás. A ROI (Figura 11) é individual para cada imagem e delimita uma área com os padrões sísmicos que o modelo deve aprender para detectar as estruturas que possam acumular gás. Além disso, ela possui uma altura fixada em 128 *pixels* e uma largura que varia entre 383 e 2809 *pixels*.

Figura 11 – Área de interesse. a) imagem sísmica com marcação do especialista; b) ROI.



Fonte: Elaborado pelo autor.

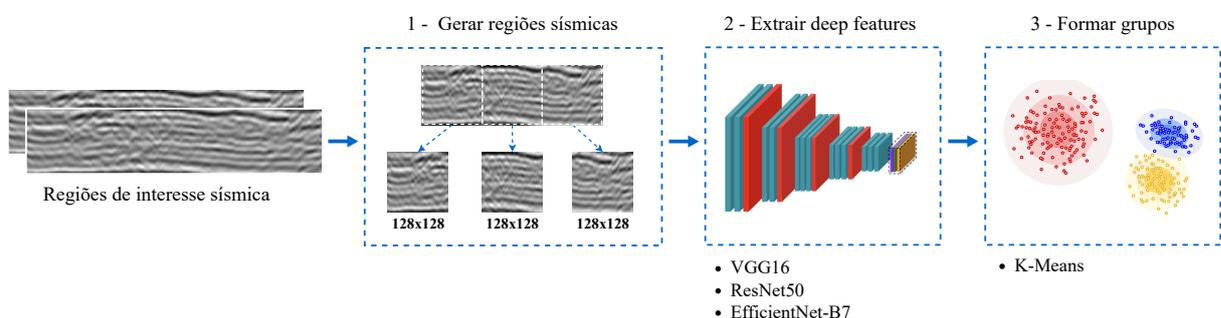
Como pode ser visto, a Figura 11 (a) ilustra uma imagem sísmica na qual a ROI é demarcada pelo especialista, e na cor vermelha a região de gás sísmico. A Figura 11 (b) apresenta a ROI (cortada) a ser utilizado neste trabalho, onde se encontra a maior probabilidade de conter o acúmulo de gás, de acordo com as informações fornecidas pela Eneva S.A.

#### 4.1.2 Agrupamento de Regiões de Imagens Sísmicas 2D

A imagem sísmica de reflexão é um tipo de dado bastante heterogêneo devido aos diferentes processos de aquisição, processamento sísmico (SELLEY; COCKS; PLIMER, 2005), além das diferenças geomorfológicas de cada local onde a imagem foi obtida (MIRANDA et al., 2018). Portanto, em uma mesma imagem sísmica podem existir regiões muito distintas entre si, o que pode dificultar o treinamento de um único modelo generalista de predição. Além disso, para que os modelos de aprendizado profundo sejam robustos, deve haver um bom equilíbrio entre os conjuntos de treinamento e validação para evitar problemas como *overfitting* (JOHNSON; KHOSHGOFTAAR, 2019) ou *underfitting* (KOEHRSEN, 2018). Desta forma, dividir as imagens sísmicas em regiões e agrupá-las para construir modelos especialistas para cada grupo é uma abordagem que pode proporcionar resultados mais robustos. Por esta razão, foi desenvolvido um método automático com o objetivo de agrupar regiões de imagens sísmicas 2D de um determinado conjunto de imagens.

O método consiste em três etapas principais: (1) dividir a imagem sísmica em regiões de dimensões iguais (altura, largura); (2) extrair *deep features*; e (3) formar grupos das regiões sísmicas extraídas. A Figura 12 ilustra as etapas descritas.

Figura 12 – Método proposto para agrupar regiões de imagens sísmicas.



Fonte: Elaborado pelo autor.

Após a etapa de pré-processamento (Seção 4.1), é realizada a primeira etapa do método para agrupar regiões de imagens sísmicas (Figura 12). Esta etapa consiste em dividir cada imagem em regiões de dimensões fixas ( $128 \times 128$  pixels). Na segunda

etapa, os modelos VGG19 (SIMONYAN; ZISSERMAN, 2014), ResNet50 (HE et al., 2016a) e EfficientNet-B7 (TAN; LE, 2019) foram selecionados para a extração de *deep features* (JÚNIOR et al., 2021) das imagens a serem usadas como dados de entrada para a próxima etapa. Esses modelos foram selecionados nessa etapa por já estarem bem estabelecidos na literatura para essa tarefa, na qual apresentam bom desempenho, além de já terem sido pré-treinados. Em cada arquitetura, as características obtidas são extraídas da última camada de convolução. Os modelos são inicializados usando pesos pré-treinados aplicados à base de imagem ImageNet (DENG et al., 2009).

Finalmente, a terceira etapa consiste em usar as características extraídas por cada modelo *deep features* para realizar experimentos de agrupamento de imagens (Seção 3.5). Esta etapa visa agrupar as regiões das imagens sísmicas com características semelhantes, a fim de gerar um modelo de detecção de região de gás específico para cada grupo encontrado. Portanto, foi usado o K-Means (Seção 3.5.1) para separar as regiões das imagens em K-grupos.

Inicialmente, o modelo K-Means foi parametrizado em cada modelo de *deep features* com diferentes números de K-grupos (de 2 a 10). Para cada valor de K, o coeficiente de silhueta (ROUSSEEUW, 1987) foi calculado para medir o quão bem as regiões sísmicas foram agrupadas pelo K-Means. O coeficiente de silhueta é uma medida de quão semelhante um objeto (região sísmica) é ao seu próprio grupo (distância intra-grupo) em comparação com outros grupos (distância entre grupos) (ROUSSEEUW, 1987; RENDÓN et al., 2011). O coeficiente de silhueta para uma amostra de dados  $i$  é dado por:

$$S_i = \frac{b_i - a_i}{\max(b_i, a_i)}, \quad (4.1)$$

Onde  $a_i$  representa a distância intra-grupo definida como a distância média a todos os outros pontos no grupo do qual faz parte. E,  $b_i$  é a distância entre grupos definida como a distância média até o grupo mais próximo do ponto de dados  $i$  (ROUSSEEUW, 1987). Depois de calcular o coeficiente de silhueta para cada ponto, faz-se a média para obter a pontuação da silhueta do K-grupo. Esse coeficiente retorna um intervalo entre  $[-1, 1]$ , na qual valor próximo de 1, indica que existe uma relação próxima entre o objeto (região sísmica) e o grupo. Valores próximos a 0 indicam grupos sobrepostos. Valores negativos geralmente indicam que uma amostra foi atribuída ao grupo errado, pois um grupo diferente é mais semelhante. Portanto, se um grupo em um modelo for gerado com um coeficiente silhueta relativamente alto, o modelo é adequado e aceitável (ROUSSEEUW; KAUFMAN, 2009).

Em seguida, o hiperparâmetro K é otimizado com o método da silhueta (ROUSSEEUW; KAUFMAN, 2009), que é frequentemente usado para encontrar o número ideal de grupos. Em que, dentre os K-grupos de um modelo *deep features*, é selecionado aquele com

maior coeficiente de silhueta, representando o melhor agrupamento. Este mesmo processo descrito é realizado para cada modelo *deep features* a fim de encontrar o seu melhor grupo. Posteriormente, dentre os modelos, é selecionado aquele com maior valor de coeficiente de silhueta, pois representará o modelo com melhor número de grupos. Por fim, o método proposto é aplicado para cada campo de exploração da base de imagens. Isso finaliza o método para agrupamento de regiões de imagens sísmicas.

Vale ressaltar que antes de aplicar as etapas descritas, o conjunto de teste de cada campo de exploração da base de imagens é escolhido aleatoriamente. Em seguida, as regiões sísmicas de cada um dos grupos gerados pelo método proposto são selecionados aleatoriamente e distribuídos proporcionalmente entre os conjuntos de treinamento e validação. Isso garante um modelo de detecção de região de gás mais equilibrado, pois deve haver regiões sísmicas de todos os grupos em ambos os conjuntos de dados. Conseqüentemente, aumenta a generalização do modelo.

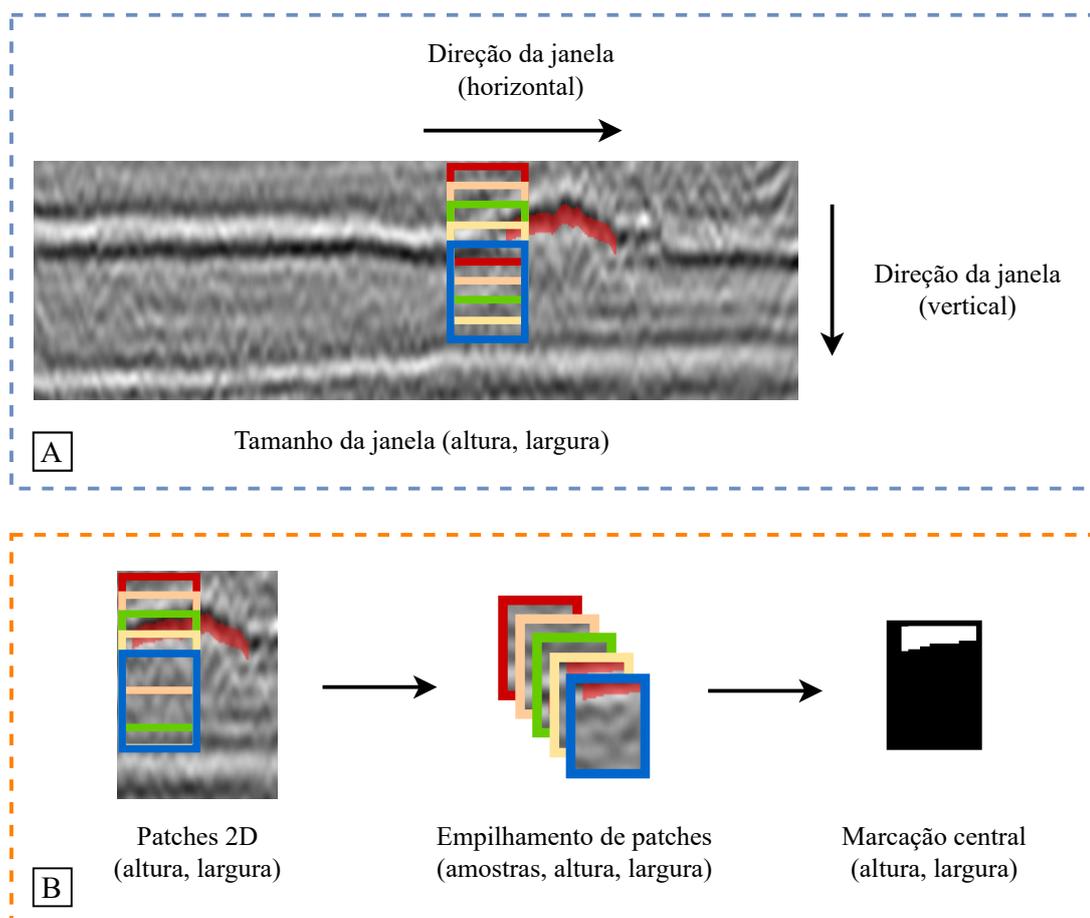
### 4.1.3 Geração de Amostras Espaço-temporais

A reflexão sísmica é um método de exploração geofísica que fornece informações sobre as propriedades do subsolo da terra a partir da reflexão de ondas sísmicas (SELLEY; COCKS; PLIMER, 2005). O princípio geral envolve o envio de ondas acústicas geradas artificialmente para o subsolo, em que diferentes estruturas e objetos dentro da crosta terrestre refletem essa energia de volta de acordo com sua impedância acústica (SELLEY; COCKS; PLIMER, 2005).

Portanto, devido à natureza da aquisição de dados sísmicos por meio da reflexão sísmica, amostras espaço-temporais são geradas verticalmente a partir da ROI. Este processo consiste em aplicar uma janela deslizante de passo igual a 1 na direção vertical (Figura 13 (a)). Posteriormente, uma janela de passo igual a um é aplicada na direção horizontal, novamente realizando os passos anteriores. Desta forma, a imagem sísmica 2D é completamente percorrida. Isso é necessário para que seja possível padronizar a dimensão das imagens sísmicas, além de aumentar o número de amostras de dados. Então, para obter as informações temporais, os *patches* extraídos e que são verticalmente sequenciais são empilhados em uma matriz tridimensional, na qual a primeira dimensão da matriz representa a quantidade de *patches* empilhados (Figura 13 (b)). Além disso, o rótulo do *patch* espaço-temporal gerado será a localização do gás do *patch* 2D central da pilha da matriz tridimensional gerada. A Figura 13 ilustra este processo.

Ao gerar os *patches*, pode surgir um desbalanceamento entre os que têm gás e os que não têm. Esse desbalanceamento entre os *patches* pode impactar negativamente o desempenho do modelo em aprender corretamente as regiões de gás. Por esta razão, aplica-se a técnica de subamostragem (DRUMMOND; HOLTE, 2003) nas amostras predominantes para excluir algumas amostras aleatórias. Por fim, determinar as dimensões da amostra

Figura 13 – Geração de amostras espaço-temporais.



Fonte: Elaborado pelo autor.

espaço-temporal é um passo crítico com grande impacto para a performance do método proposto. Deste modo, a dimensão da amostra é formada por três dimensões, a primeira contém a quantidade de amostras que foram empilhadas. A segunda e terceira dimensões referem-se à altura e largura da amostra, respectivamente.

As amostras espaço-temporais serão extraídas das regiões sísmicas que foram agrupadas (Seção 4.1.2). Essas amostras servirão como entrada para a etapa de detecção de gás usando a ConvLSTM (Seção 4.2).

#### 4.1.4 Otimização das Amostras usando PSO

A otimização de hiperparâmetros é uma tarefa árdua, por isso na literatura encontra-se algumas técnicas de otimização, como a busca manual (HUTTER; LÜCKE; SCHMIDT-THIEME, 2015), *Grid Search* (LIASHCHYNSKYI; LIASHCHYNSKYI, 2019), *Randomized Search* (BERGSTRÄ; BENGIO, 2012), bem como abordagens evolucionárias (LIASHCHYNSKYI; LIASHCHYNSKYI, 2019; ZITZLER, 1999). As abordagens evolucionárias apresentam algumas vantagens em relação a outras, como a simplicidade conceitual, ampla

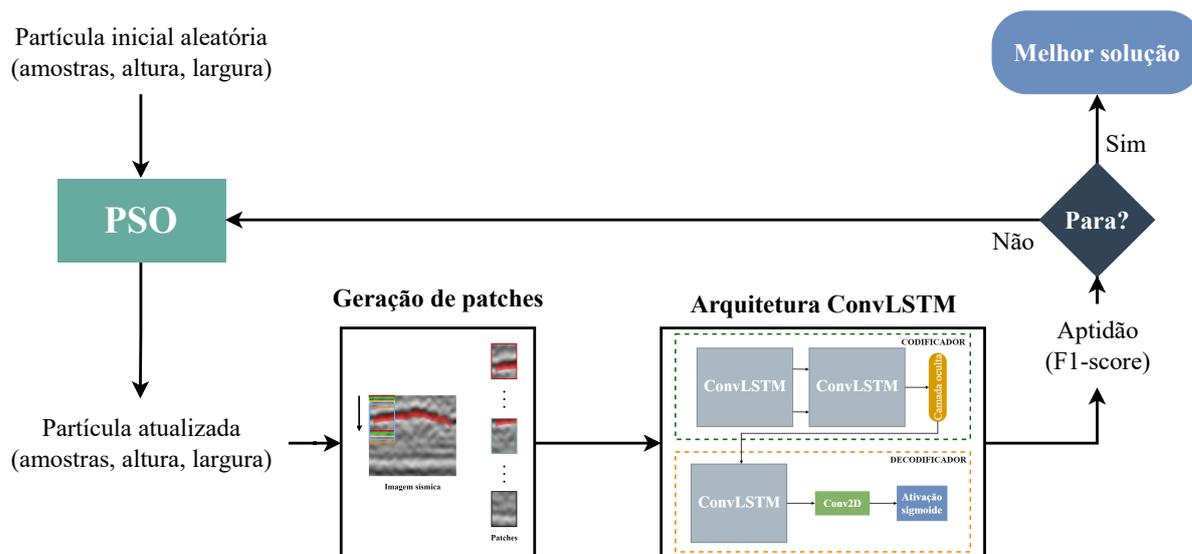
aplicabilidade, superior aos métodos clássicos em problemas reais e, finalmente, pode ser aplicada a problemas onde não há soluções conhecidas (FOGEL, 1997). Por esta razão, a abordagem evolucionária, em especial a técnica PSO (EBERHART; KENNEDY, 1995) foi escolhida para estabelecer a dimensão ótima de amostra neste trabalho.

O PSO pode gerar uma solução de alta qualidade em um tempo de cálculo mais curto e exibindo características de convergência estável mais eficazes do que outras técnicas de otimização (ISLAM et al., 2019). Além disso, há menos hiperparâmetros de controle para ajustar e é mais eficiente em manter a diversidade do enxame, pois todas as partículas usam as informações relacionadas à partícula mais bem-sucedida (partícula *Gbest*) para se aprimorar. Por esse motivo, selecionou-se o PSO para otimizar os hiperparâmetros das amostras espaço-temporais (KENNEDY, 2010; JÚNIOR et al., 2021).

Os hiperparâmetros das amostras espaço-temporais usados para otimização são: número de amostras temporais, altura e largura do *patch*. Para representar uma partícula PSO, é criado um vetor de três posições, no qual cada componente do vetor representa um dos hiperparâmetros mencionados anteriormente. Cada hiperparâmetro requer um espaço de busca, que é simplesmente denotado pelos limites dos valores máximo e mínimo que podem ser assumidos. Além disso, para permitir a evolução do algoritmo PSO, é necessária uma função de aptidão.

A aptidão de cada partícula foi avaliada utilizando os resultados obtidos pelo modelo ConvLSTM (Seção 4.2), que operou no subconjunto de validação de acordo com os hiperparâmetros selecionados. Aqui, o método de ponderação usado na aptidão é explicado. O principal objetivo da ponderação é manter um equilíbrio entre sensibilidade e precisão. Para isso, o F1-score (SASAKI; FELLOW, 2007) é usado para obter modelos superiores na detecção de gás. Esta aptidão é definida na Equação 3.10 na Seção 3.7.

A Figura 14 ilustra as etapas discutidas anteriormente. Em resumo, uma população de partículas aleatórias é criada, os três componentes obtidos (amostras, altura, largura) são repassados para a etapa de geração de *patches*. Posteriormente, o modelo ConvLSTM é treinado, retornando a aptidão, que é a menor *loss* (F1-score) de validação. Caso a aptidão da partícula for ótima, a busca é interrompida, caso contrário, a partícula é atualizada. Este procedimento é repetido até que um número predeterminado de iterações ou até que a convergência total do modelo seja alcançada. Ao final da otimização, obtemos os melhores hiperparâmetros de dimensão para as amostras da etapa de validação do modelo. Por fim, na base de imagens de teste aplica-se métricas de validação para calcular a robustez do método.

Figura 14 – Procedimento para geração dos *patches* usando o PSO.

Fonte: Elaborado pelo autor.

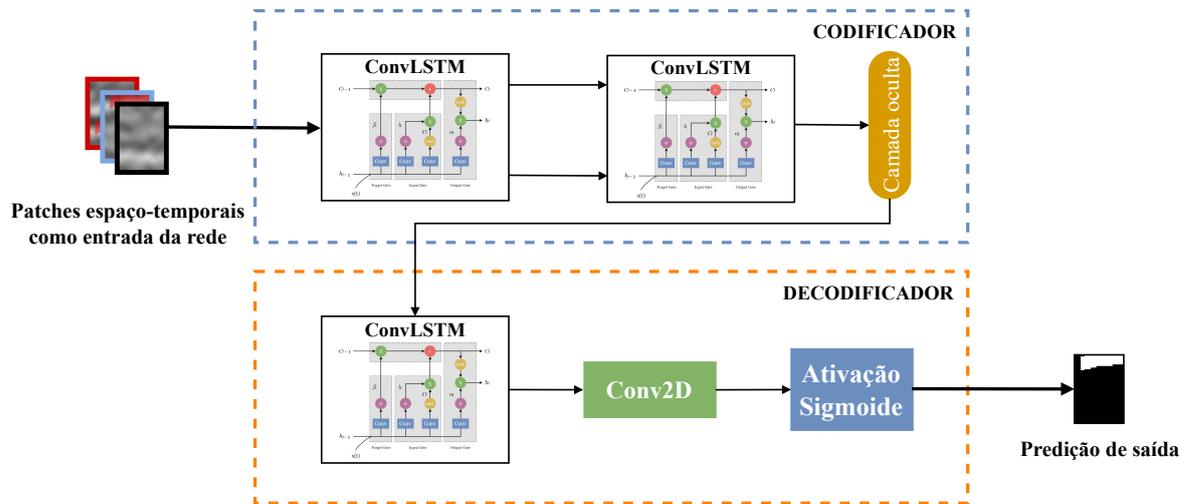
## 4.2 Detecção de Potenciais Acumulações de Gás usando Arquitetura ConvLSTM

Após a preparação dos dados, a próxima etapa é detectar potenciais regiões de gás. Para esta etapa, é usado uma técnica de aprendizado profundo para segmentação semântica de *patches*. Assim, neste trabalho, um modelo baseado na arquitetura ConvLSTM (SHI et al., 2015a) foi proposto devido à sua capacidade em aprender correlações espaço-temporais.

O modelo ConvLSTM proposto para detecção de gás em dados sísmicos é ilustrado na Figura 15. Esse modelo é baseado na ConvLSTM-padrão (SHI et al., 2015a; HOCHREITER; SCHMIDHUBER, 1997) que é usada para criar uma arquitetura do tipo *encoder-decoder*. As duas camadas ConvLSTM empilhadas formam o recurso de codificador de nossa topologia, com a segunda camada tendo o dobro do número de filtros que a primeira, como um estilo de gargalo. Usamos esse tipo de camada porque sua estrutura permite que o modelo entenda o contexto e as dependências espaço-temporais das imagens sísmicas (SHI et al., 2015a). A saída do codificador, o estado oculto, é o estado da última etapa espaço-temporal ConvLSTM. A saída do codificador, indicada no círculo preenchido em amarelo na figura, é uma camada oculta que encapsula todo o significado da imagem espaço-temporal de entrada. As dimensões desta camada dependem do número de células no ConvLSTM. Para decodificar o estado oculto e prever a localização do gás na imagem espaço-temporal da entrada da rede, usamos ConvLSTM, seguido por uma camada Conv2D e uma ativação sigmoide.

Para treinamento de modelo, *patches* espaço-temporais (Seção 4.1.4) são fornecidos como dados de entrada do modelo. Desta forma, o modelo terá como objetivo realizar a

Figura 15 – Arquitetura do modelo proposto.



Fonte: Elaborado pelo autor.

segmentação semântica da localização da região do gás no *patch* central em referência à imagem sísmica 2D. Depois disso, a imagem original é restaurada a partir dos *patches* preditos e as métricas de validação (Seção 5.1.2) são extraídas para mensurar a robustez do modelo.

Vale ressaltar que esse processo é realizado para cada um dos campos de exploração da base de imagens sísmica. Em que, inicialmente, as regiões da imagem são agrupadas em cada campo (Seção 4.1.2). Posteriormente, para cada grupo é gerado um modelo usando a ConvLSTM.

### 4.3 Considerações Finais

Este capítulo detalhou cada uma das etapas do método proposto para detectar potenciais acumulações de gás em imagens sísmicas 2D. Entre as principais contribuições estão: agrupamento de regiões de imagens sísmicas; análise do espaço-temporal para geração de *patches*; otimização de hiperparâmetros das amostras espaço-temporais; e adaptações empregadas na ConvLSTM para a detecção de potenciais gás.

No próximo seguinte, serão apresentados os resultados obtidos com a aplicação do método proposto. Além disso, são apresentadas a base de imagens aplicada, a configuração experimental das redes usadas e alguns experimentos para validar as etapas do método proposto.

## 5 Resultados

Este capítulo apresenta a base de imagens sísmica usada, descreve a configuração experimental, o procedimento de preparação da base de imagens, e os resultados dos experimentos realizados.

### 5.1 Base de Imagens Sísmica 2D

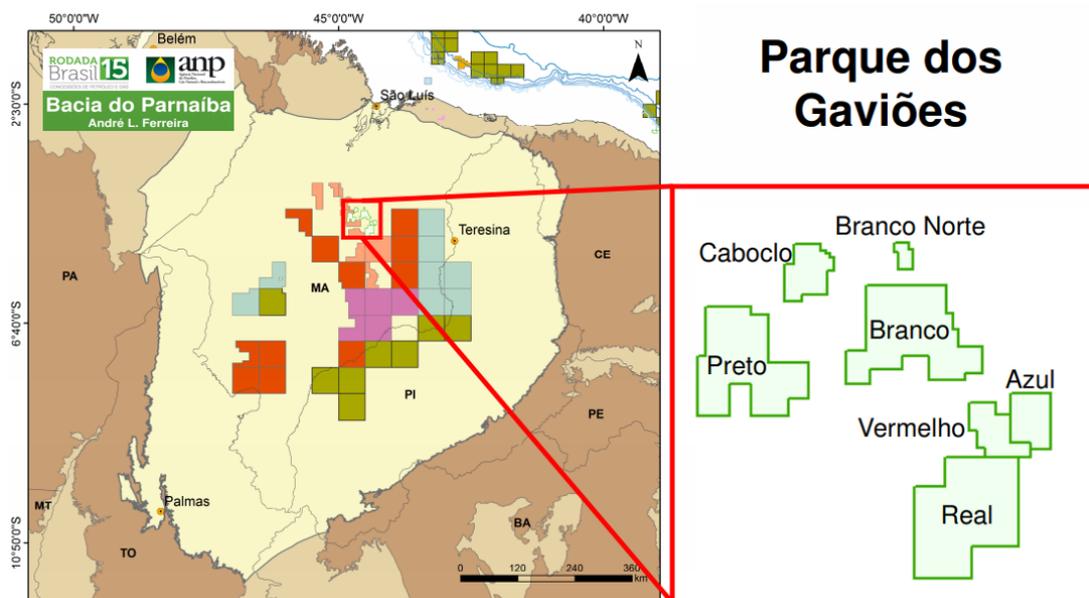
Os dados sísmicos utilizados como objeto de estudo são provenientes da Bacia Paleozoica do Parnaíba. A Bacia é uma bacia intra-cratônica de formato oval clássico desenvolvida em um embasamento continental, durante o estágio de estabilização da plataforma Sul-Americana. Localiza-se entre o Cráton Amazônico e a Província Borborema (ALMEIDA; CARNEIRO et al., 2004; MIRANDA et al., 2018). Seu limite norte é definido pelo Arco Ferrer–Urbano Santos e o limite sul é definido pelo Arco São Francisco (MIRANDA et al., 2018). A oeste, o arco do Tocantins separa a Bacia do Parnaíba do Cráton Amazônico e da Bacia do Marajó. Abrange mais de 600.000km<sup>2</sup> com um depocentro atingindo quase 3.500m de espessura (MIRANDA et al., 2018).

Além disso, em campos de gás descobertos, os valores de permeabilidade podem chegar a 240 mD e a porosidade média é de 18%. Essas feições geralmente estão relacionadas a corpos de areia marinhos fluviais-deltaicos rasos depositados sob a influência de marés ou ondas (MIRANDA et al., 2018). Em relação à qualidade do reservatório, é possível classificar a região em três zonas: a zona superior que tem a melhor qualidade de reservatório, a zona intermediária que tem uma qualidade média e por último a zona inferior que tem a menor qualidade, a mais heterogêneo e laminada de todos. No entanto, todas as zonas são capazes de produzir gás a taxas comercialmente rentáveis (MIRANDA et al., 2018).

Os principais reservatórios em seis dos sete campos existentes na Bacia do Parnaíba são os arenitos da Formação Poti com boas propriedades poropérmicas na bacia (MIRANDA et al., 2018). A principal área produtora é conhecida como “Parque dos Gaviões” em referência às espécies nativas de gaviões brasileiros em que os campos são nomeados (Figura 16).

Os dados disponíveis consistem em 380 seções de imagens sísmicas 2D localizadas na área do Parque dos Gaviões. A base de imagens foi fornecida e rotulada pela Eneva S.A., uma empresa brasileira de energia. Essas imagens foram obtidas em diferentes intervalos de tempo com diferenças de clima, geologia, processo de aquisição e outros fatores externos. Assim, nota-se o desafio de se trabalhar com essas imagens, uma vez que estes são diversificados e heterogêneos.

Figura 16 – Parque dos Gaviões (MIRANDA et al., 2018).



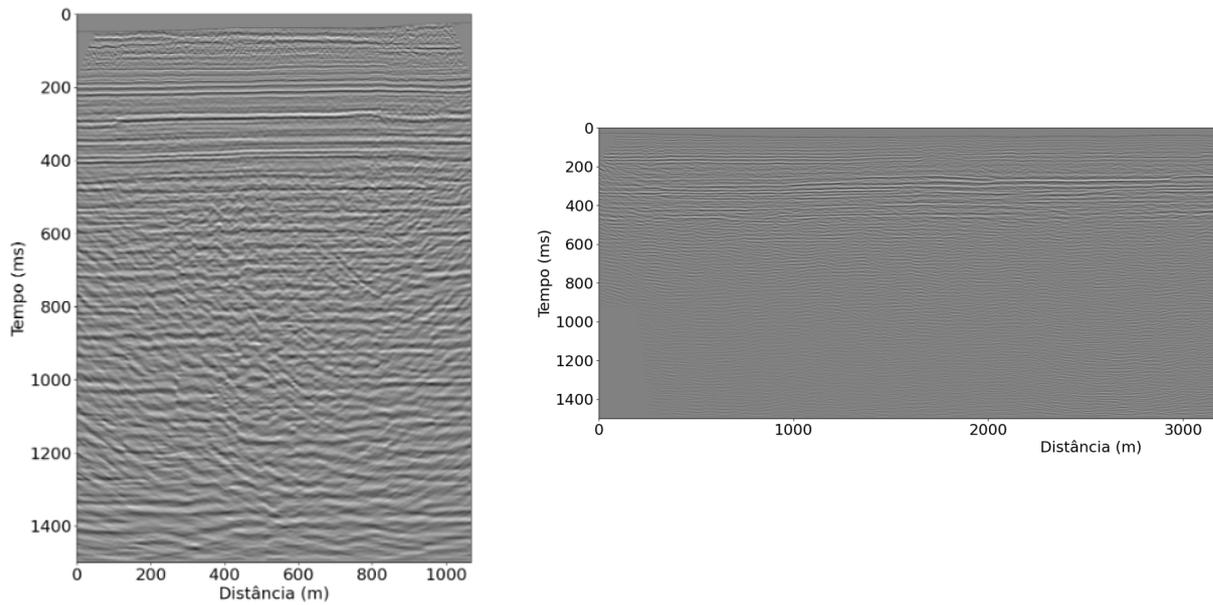
Fonte: Elaborado pelo autor.

A Figura 17 ilustra exemplos de imagens sísmicas. As imagens são obtidas a partir da reflexão no tempo das ondas sísmicas no subsolo (eixo y) geradas por alguma perturbação mecânica durante o processo de aquisição. A região de aquisição é a distância (eixo x) obtida através de vários receptores dispostos em linha reta e equidistantes a uma distância que varia em metros. O número de receptores é muito grande, pode ser centenas, o que significa que o receptor mais distante está a quilômetros de distância da fonte (THOMAS et al., 2004; KROHN, 2008; SELLEY; COCKS; PLIMER, 2005). Portanto, as imagens apresentam aspectos e características como ondas e tons de cinza. Devido ao método de aquisição, as amostras espaço-temporais são adquiridas verticalmente (Seção 4.1.3). Assim, as amostras são geradas analisando as características fundamentais da imagem, obtendo uma boa representação dos dados, o que impacta diretamente no modelo.

### 5.1.1 Agrupamento de Regiões de Imagens Sísmicas 2D

Esta Subseção apresenta o resultado da aplicação do método de agrupamento de regiões sísmicas à base de imagens proveniente do Parque dos Gaviões (Seção 5.1). Para realizar os experimentos, foram usados quatro campos sísmicos, sendo eles: Gavião Preto, Gavião Real, Gavião Branco e Gavião Vermelho. A Tabela 4 apresenta o número de imagens sísmicas por campo de exploração. Cada conjunto foi inicialmente selecionado aleatoriamente para cada campo de exploração, seguindo as três etapas (Seção 4.1.2): (1) dividir a imagem sísmica em regiões de dimensões iguais (altura, largura); (2) extrair *deep features*; e (3) formar grupos das regiões sísmicas extraída.

Figura 17 – Exemplo de imagens sísmicas. O eixo y representa o tempo em milissegundos e o eixo x representa a distância em metros.



Fonte: Elaborado pelo autor.

Na primeira etapa, o pré-processamento apresentado na Seção 4.1 é aplicado às imagens sísmicas. Em seguida, as imagens são divididas em regiões de  $128 \times 128$  *pixels* para cada campo de exploração.

Na segunda etapa, são extraídas as *deep features* das regiões sísmicas previamente obtidas. A Tabela 2 mostra o número de características extraídas das regiões para cada modelo descrito na Seção 3.4.1.

Tabela 2 – Total de características extraídas em cada modelo de CNN.

Modelo	Nº de características por região sísmica
VGG-16	512
ResNet-50	2.048
EfficientNet-B7	2.560

Na terceira etapa, as características extraídas por cada modelo são usadas para realizar o agrupamento de dados com K-Means. A Tabela 3 apresenta os campos da base Gavião, os modelos, o melhor hiperparâmetro  $K$  encontrado no intervalo de 1 a 10 e seus respectivos coeficientes de silhueta. Dentre eles, o modelo EfficientNet-B7 foi o selecionado por apresentar o maior coeficiente de silhueta em todos os campos.

Acredita-se que o modelo EfficientNet-B7 foi capaz de extrair características mais discriminativas das regiões sísmicas por ter um novo mecanismo interno de dimensionamento para melhorar o desempenho das redes neurais. A EfficientNet-B7 faz uso dessa técnica simples, mas eficaz, que dimensiona uniformemente a largura, a profundidade e a

Tabela 3 – Melhores grupos e seus coeficientes de silhueta encontrados para os modelos usando o método da silhueta.

Base Gavião	Modelo	Nº ótimo de grupos	Silhueta
Preto	VGG-16	2	0,363
	ResNet-50	2	0,406
	EfficientNet-B7	3	0,594
Real	VGG-16	2	0,147
	ResNet-50	2	0,474
	EfficientNet-B7	2	0,545
Branco	VGG-16	2	0,119
	ResNet-50	3	0,332
	EfficientNet-B7	3	0,529
Vermelho	VGG-16	2	0,082
	ResNet-50	2	0,241
	EfficientNet-B7	2	0,51

resolução da rede. Assim, equilibrar todas as dimensões da largura/profundidade/resolução da rede foi crucial para uma melhor eficiência e performance da rede (TAN; LE, 2019). Por esta razão, a arquitetura EfficientNet-B7, dentre os modelos, foi a capaz de extrair um conjunto maior e mais significativo de características para o problema proposto.

Finalmente, o método de agrupamento proposto é aplicado a cada campo de exploração da base de imagens sísmica. Além disso, para cada K-grupo obtido em cada campo de exploração, um modelo de detecção de gás será gerado (Seção 4.2).

### 5.1.2 Preparação da Base de Imagens e Configuração Experimental

O método proposto foi construído usando a linguagem de programação Python 3.7, com os frameworks Keras e TensorFlow 2.x (ABADI et al., 2015). A biblioteca Segyio (KVALSVIK, 2019) foi usada para manipular os dados sísmicos. A máquina usada possui hardware composto por um processador Intel Core i7-9700K 4.20GHz  $\times$  8, 24 GB de RAM e uma GPU GeForce RTX 2070 de 8 GB, com sistema operacional Arch Linux. A base de imagens sísmica foi separada por campo de exploração, e a quantidade das imagens sísmicas para os experimentos está descrita na Tabela 4. Além disso, a quantidade de *patches* espaço-temporal gerados a partir do treino e validação são descritos nas Tabelas 5 e 6, respectivamente.

Tabela 4 – Número de imagens sísmicas por campo de exploração.

Base Gavião	Número de imagens sísmicas
Preto	21
Real	21
Branco	35
Vermelho	10

Tabela 5 – Número de *patches* de treino por campo de exploração.

Base Gavião	Gás	Não-gás
Preto	44.482	11.075.875
Real	42.039	9.668.970
Branco	58.855	14.713.650
Vermelho	28.026	7.062.552

Tabela 6 – Número de *patches* de validação por campo de exploração.

Base Gavião	Gás	Não-gás
Preto	22.364	5.233.199
Real	24.397	4.635.468
Branco	40.662	13.418.460
Vermelho	20.331	3.659.580

Pode-se ver que as bases de imagens por campo de exploração são distintas no número de imagens possíveis para treinamento, validação e teste. Assim, devido à quantidade de amostras de treinamento, os resultados podem variar devido ao número de indivíduos representativos em cada conjunto de dados.

Para validar o método, foi aplicado a técnica de validação cruzada *k-fold*, definindo  $k = 5$ . Nessa abordagem, o método é treinado e testado cinco vezes, em cada campo de exploração da base de imagens. O conjunto de regiões sísmicas de cada grupo é dividido na proporção 80:20 para garantir a proporção para as duas classes. Ao final de cada procedimento de treinamento, as métricas de validação foram extraídas. Como resultado, foi obtido a média de cada métrica junto com seu desvio padrão. Isso permitiu fazer análises mais adequadas do método. Também foi possível evitar o problema de *overfitting*, pois cada campos de exploração foi treinado pelo menos uma vez no procedimento de validação *k-fold*.

Deste modo, foram aplicadas métricas populares na área de processamento de imagens, sendo elas: F1-score (F1), sensibilidade (Sen), precisão (Prec), especificidade (Esp) e acurácia (Acc), conforme a Seção 3.7. As métricas foram calculadas com base na matriz de confusão.

A seguir, são apresentados os experimentos realizados para validar o método proposto. Primeiro, os resultados são apresentados em todos os conjuntos de dados separadamente (com e sem agrupamento das regiões sísmicas) e, em seguida, os resultados comparados com outras abordagens (com e sem agrupamento) são apresentados.

## 5.2 Resultados por Campo

Após o processo de divisão da base, a próxima etapa é extrair as amostras espaço-temporais de cada imagem de entrada. Para isso, foi aplicado o algoritmo de otimização PSO para estimar as dimensões. Para o número de amostras foi definido um limiar discreto entre 3 e 25, para a largura e altura foram definidos limiares discretos entre 10 e 110. O valor estimado da amostra de  $15 \times 10 \times 70$  foi o que produziu os melhores resultados.

O conjunto de amostras (treino e validação) que possui gás e não-gás tem uma razão média de 1:234, na qual apresenta desbalanceamento. Esse desbalanceamento pode impactar negativamente o modelo e, conseqüentemente, os resultados. Para resolver isso, a técnica de subamostragem (DRUMMOND; HOLTE, 2003) foi aplicada às amostras predominantes (não-gás) para excluir algumas amostras aleatórias, obtendo uma proporção de 1:4 de amostras de gás e não-gás. A proporção 1:4 produziu os melhores resultados sem comprometer os recursos computacionais.

Com as amostras geradas, o próximo passo é treinar o modelo ConvLSTM para detectar as regiões potenciais de gás. Para isso, foram realizados dois experimentos. O primeiro trata da aplicação do método proposto sem a etapa de agrupamento das regiões sísmicas. O segundo experimento, é realizado com a etapa de agrupamento (Seção 5.1.1). A Tabela 7 descreve os resultados produzidos pela aplicação do método aos campos de exploração descritos sem o agrupamento, e a Tabela 8 os resultados do método proposto aplicando a etapa de agrupamento.

Tabela 7 – Resultados por campo de exploração sem a etapa de agrupamento.

Base Gavião	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
Preto	52,21 ± 2,89	81,98 ± 2,42	38,71 ± 3,42	98,44 ± 0,25	97,51 ± 0,45
Real	56,85 ± 1,02	72,36 ± 1,35	46,86 ± 1,04	98,61 ± 0,24	98,36 ± 0,3
Branco	48,34 ± 1,9	74,65 ± 0,95	36,32 ± 2,76	97,14 ± 0,59	96,64 ± 0,75
Vermelho	84,25 ± 1,46	96,3 ± 1,81	75,06 ± 2,24	99,35 ± 0,17	99,34 ± 0,13

Tabela 8 – Resultados por campo de exploração com a etapa de agrupamento.

Base Gavião	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
Preto	58,11 ± 1,1	83,36 ± 1,27	44,63 ± 1,46	98,43 ± 0,26	99,29 ± 0,47
Real	60,4 ± 0,35	77,79 ± 0,42	49,36 ± 0,56	98,62 ± 0,26	98,38 ± 0,33
Branco	60,14 ± 0,42	77,89 ± 0,49	48,98 ± 0,53	96,93 ± 0,62	96,66 ± 0,77
Vermelho	85,51 ± 0,22	98,88 ± 0,47	75,33 ± 0,17	98,93 ± 0,82	98,35 ± 0,84

Observa-se nas Tabelas 7 e 8 que os melhores resultados em todos os campos de exploração foram obtidos usando a etapa de agrupar as regiões sísmicas. Isso pode ser justificado pelo fato de que apesar do aumento na quantidade de amostra dos dados, o padrão de gás de cada campo sísmico pode apresentar algumas divergências nas regiões geológicas que tem acumulação de gás, dificultando a generalização da rede (MIRANDA

et al., 2018). Portanto, acredita-se que ao agrupar as regiões sísmicas faz com que tenham regiões mais semelhantes, garantindo que os modelos sejam equilibrados e obtenham um melhor desempenho, o que garantiu os bons resultados produzidos pelo método proposto com agrupamento.

É importante mencionar que a métrica mais importante a ser levada em consideração é a sensibilidade, pois mostra a quantidade de acerto na classe de gás, que é o principal objetivo. A métrica F1-score mostra uma proporção harmônica entre precisão e sensibilidade. É importante mencionar que o conjunto de teste há desequilíbrio entre as classes de gás e não-gás. Em que, pode afetar negativamente as métricas, por exemplo, uma baixa precisão indica a presença de muitos falsos positivos. Nota-se que todos os campos da Tabela 8 produziram resultados superiores a 96% para as métricas de especificidade e acurácia, e mais de 77% para sensibilidade. Os resultados da F1-score nos dão uma visão geral da performance do modelo, pois ela mede o desempenho de forma ponderada.

Ressalta-se também que o conjunto de dados de Gavião Vermelho apresentou resultados superiores em todas as métricas em relação aos demais campos. Destacam-se a sensibilidade e o F1-score, nos quais apresentaram resultados significativos, demonstrando que o modelo foi capaz de segmentar bem a classe positiva (gás) e ao mesmo tempo obter boa similaridade entre os objetos de estudo. Este resultado pode ser atribuído a uma melhor homogeneidade dos grupos e qualidade dos dados sísmicos (SANTOS, 2019). Assim, é perceptível a eficácia do método na tarefa de detecção de potenciais acumulações de gás usando o modelo ConvLSTM.

### 5.3 Comparação com Outras Abordagens

Para validar a vantagem da abordagem espaço-temporal, foram propostos experimentos usando as abordagens espaciais e temporais de forma individual. Na abordagem espacial, realizamos experimentos usando redes convolucionais com a U-Net (HE et al., 2016b) e ResUNet (ZHANG; LIU; WANG, 2018), e uma rede de atenção, a Vision Transformer (DOSOVITSKIY et al., 2020). Na abordagem temporal, os experimentos foram concentrados na aplicação de uma rede recorrente, a LSTM (HOCHREITER; SCHMIDHUBER, 1997), e uma rede de auto atenção, a Transformer (VASWANI et al., 2017). Os hiperparâmetros das redes foram os padrões utilizados na literatura.

Foi necessário fazer algumas adaptações para executar as redes na abordagem espacial no método proposto: *patches* não foram empilhados conforme descrito na etapa de pré-processamento. Em vez disso, apenas os *patches* 2D gerados para a segmentação foram considerados e o PSO foi aplicado para encontrar os melhores hiperparâmetros de altura e largura. Além disso, também foi necessário fazer algumas adaptações na abordagem temporal. Em vez de empilhar *patches* ou extrair 2D *patches*, 1D *patches* foram extraídos

verticalmente da imagem sísmica e o PSO foi aplicado para estimar o valor do comprimento do *patch*.

Os hiperparâmetros encontrados pelo PSO para as abordagens espaciais foram: para a U-Net e ResUnet,  $64 \times 64$  de altura e largura, respectivamente, e para a arquitetura Vision Transformer, 20 altura e largura. Para as abordagens temporais foram: 65 de comprimento do *path* para LSTM e 75 para Transformer.

Finalmente, foram aplicados dois experimentos. Basicamente, comparações do método proposto com outros modelos sem a etapa de agrupamento das regiões sísmicas do método proposto (Tabela 9) e com agrupamento (Tabela 10).

Tabela 9 – Resultados da comparação do método proposto com outros modelos sem a etapa agrupamento.

Abordagem	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
U-Net	42,68 $\pm$ 1,98	49,24 $\pm$ 1,75	37,88 $\pm$ 3,7	95,88 $\pm$ 1,56	98,37 $\pm$ 1,22
ResUnet	44,83 $\pm$ 1,79	51,03 $\pm$ 1,68	40,13 $\pm$ 3,38	97,42 $\pm$ 1,29	95,39 $\pm$ 1,44
Vision Transformer	54,64 $\pm$ 1,3	68,64 $\pm$ 0,11	45,41 $\pm$ 1,8	96,37 $\pm$ 1,18	95,75 $\pm$ 1,23
LSTM	57,84 $\pm$ 1,92	77,51 $\pm$ 2,19	46,2 $\pm$ 2,57	96,94 $\pm$ 1,7	97,44 $\pm$ 0,83
Transformer	48,15 $\pm$ 1,86	52,63 $\pm$ 1,81	44,4 $\pm$ 2,32	95,19 $\pm$ 1,36	94,01 $\pm$ 1,01
<b>Método Proposto</b>	84,25 $\pm$ 1,46	96,3 $\pm$ 1,81	75,06 $\pm$ 2,24	99,35 $\pm$ 0,17	99,34 $\pm$ 0,13

Tabela 10 – Resultados da comparação do método proposto com outros modelos com a etapa agrupamento.

Abordagem	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
U-Net	43,99 $\pm$ 0,42	49,64 $\pm$ 1,08	39,51 $\pm$ 0,41	98,29 $\pm$ 0,71	98,59 $\pm$ 1,2
ResUnet	47,21 $\pm$ 1,11	55,95 $\pm$ 1,18	40,83 $\pm$ 1,16	97,5 $\pm$ 0,71	98,13 $\pm$ 0,87
Vision Transformer	60,45 $\pm$ 1,09	79 $\pm$ 0,6	48,98 $\pm$ 1,62	97,26 $\pm$ 0,66	98 $\pm$ 1,36
LSTM	61,51 $\pm$ 0,33	78,71 $\pm$ 0,99	50,49 $\pm$ 0,75	98,04 $\pm$ 1,27	97,51 $\pm$ 0,98
Transformer	51,02 $\pm$ 1,31	55,5 $\pm$ 1,01	47,23 $\pm$ 1,74	98,44 $\pm$ 0,88	98,14 $\pm$ 1,09
<b>Método Proposto</b>	85,51 $\pm$ 0,22	98,88 $\pm$ 0,47	75,33 $\pm$ 0,17	98,93 $\pm$ 0,82	98,35 $\pm$ 0,84

É importante mencionar que os resultados apresentados na Tabelas 9 e 10 foram obtidos usando o conjunto de dados do campo Gavião Vermelho, pois é o que apresenta a melhor homogeneidade e qualidade dos dados sísmicos. Nota-se que novamente os melhores resultados em todos os modelos foram usando a etapa de agrupamento (Tabela 9). Além disso, analisando as quantificações pode-se concluir que o método proposto usando a ConvLSTM obtém os melhores resultados em comparação com outros modelos. Acreditamos que isso seja possível devido ao uso da abordagem espaço-temporal, uma vez que faz uso dos pontos fortes das abordagens espaciais e temporais. Portanto, acabou sendo uma estratégia importante devido à forma como as imagens sísmicas são adquiridas. Além disso, como a ConvLSTM é uma rede capaz de aprender correlações espaço-temporais, resultou em um modelo de alto poder de generalização para detectar potenciais acumulações de gás. Isso mais uma vez demonstra que o método proposto é robusto, e promissor.

## 5.4 Considerações Finais

Neste capítulo, os resultados obtidos pelos experimentos realizados no desenvolvimento do método proposto foram apresentados e discutidos. Além disso, mais alguns experimentos foram realizados a fim de validar as etapas do método proposto.

No próximo capítulo serão apresentados os estudos de casos, também será feita uma comparação com os trabalhos descritos na literatura, visando contextualizar a relevância da pesquisa desenvolvida neste trabalho. Por fim, serão descritos os principais aspectos e limitações encontrados após a análise das etapas propostas.

## 6 Discussão

Neste capítulo são apresentados alguns estudos de caso positivos e negativos relacionados à detecção de acumulações de gás, bem como uma comparação do método proposto com os trabalhos relacionados encontrados na literatura (Capítulo 2). Finalmente, são discutidos as vantagens e limitações do método proposto.

### 6.1 Estudos de Caso

Para avaliar os resultados alcançados no método proposto, foram definidos dois estudos de caso. No primeiro caso, o modelo pode detectar de forma eficaz possíveis acumulações de gás nos campos Preto, Real, Branco e Vermelho. No segundo caso, o modelo apresenta algumas deficiências nos resultados de detecção de reservatórios de gás nos mesmos campos supracitados.

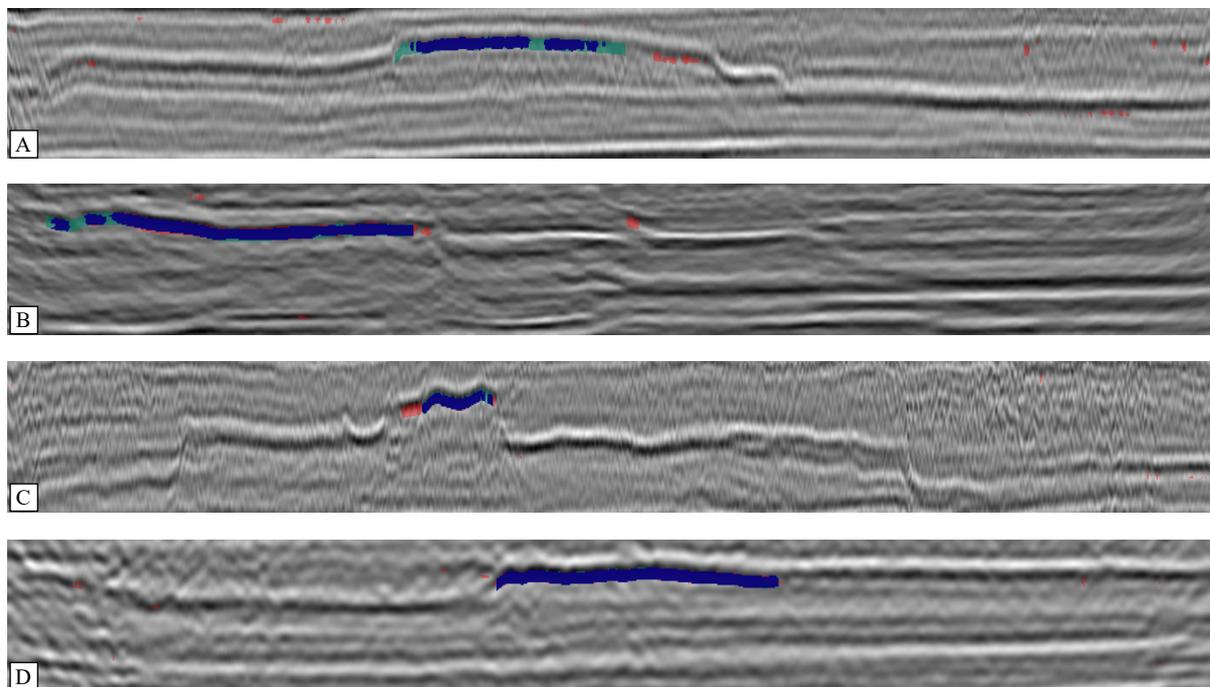
Na Figura 18, são apresentados os casos que tiveram os melhores resultados para cada campo. Pode-se notar que apesar de alguns falsos positivos gerados (em vermelho), o método consegue detectar a região alvo (em azul) de forma eficaz em todos os campos, visto que a marcação do método proposto é muito semelhante à marcação do especialista. Isso pode facilitar a análise dos dados por um especialista, ajudando a reduzir os riscos exploratórios. A Tabela 11 apresenta os resultados individuais das métricas de validação para cada campo. Destacamos o resultado do campo Vermelho, na qual obteve resultados superiores a 92% em todas as métricas, validando os resultados visuais. Portanto, esses casos demonstram que o método proposto é promissor tanto para resultados quantitativos quanto qualitativos. Vale ressaltar que vários resultados semelhantes foram encontrados em todas as bases de imagens.

Tabela 11 – Resultados do estudo de caso 1.

Estudos de Caso	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
Preto	65,02	69,24	61,28	99,23	98,71
Real	84,76	87,16	82,48	99,47	99,13
Branco	74,96	88,56	64,98	99,74	99,68
Vermelho	92,88	98,48	87,88	99,71	99,68

O segundo estudo de caso é ilustrado na Figura 19, na qual apresenta os piores resultados para cada campo. Nesses casos, o método proposto não foi capaz de definir com maior precisão as regiões potenciais de acúmulo de gás. Embora o modelo tenha atingido algumas regiões-alvo, a maioria das regiões de gás não foi detectada (em verde). Além disso, a ConvLSTM confunde a previsão de gás com regiões semelhantes, gerando

Figura 18 – Estudo de caso 1 - Base Gavião. (a) Preto, (b) Real, (c) Branco, e (d) Vermelho. Na cor vermelha, representa falsos positivos. Em azul, os verdadeiros positivos. Em verde, falsos negativos.



Fonte: Elaborado pelo autor.

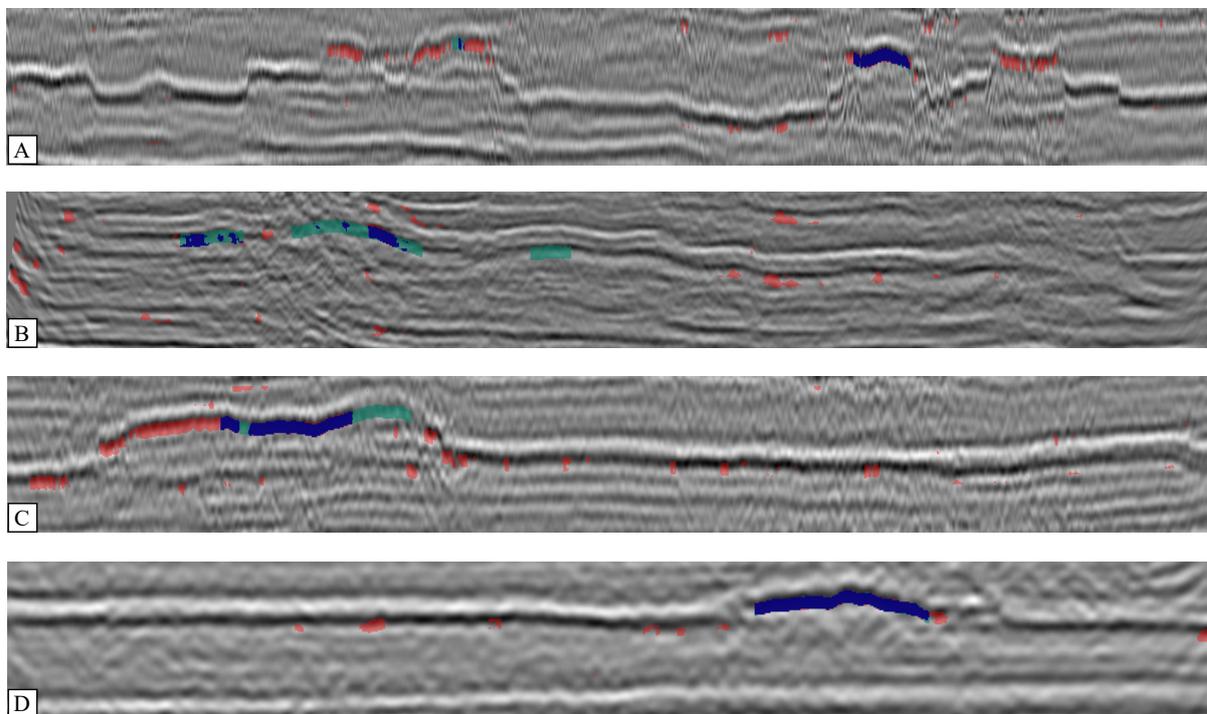
previsões falsos positivos (em vermelho). A Tabela 12 apresenta as taxas de desempenho dos quantificadores para cada um dos campos. Novamente, destacamos o campo Vermelho, na qual o seu pior resultado ainda produziu resultados expressivos, atingindo 75,56% de F1-score e 97,64% de sensibilidade. Essas métricas são importantes na tarefa de detecção, uma vez que a sensibilidade representa o percentual de segmentação na classe positiva e o F1-score indica a similaridade entre os objetos de estudo, por meio da média harmônica entre a precisão e sensibilidade (FAWCETT, 2006). Isso mostra que, apesar dos resultados promissores, o modelo ainda não consegue detectar alguns dados em todos os campos. Provavelmente porque as amostras extra-classe são muito semelhantes, gerando falsas predições.

Tabela 12 – Resultados do estudo de caso 2.

Estudos de caso	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
Preto	30,66	84,70	18,72	98,08	98,01
Real	28,85	31,89	26,34	98,37	97,18
Branco	38,86	64,33	27,84	97,57	97,09
Vermelho	75,56	97,64	61,62	99,18	99,16

Vale lembrar que a análise de dados não é uma tarefa trivial. Por esta razão, requer experiência especializada e é demorado. Portanto, acredita-se que a proposta, aliada ao

Figura 19 – Estudo de caso 2 - Base Gavião. (a) Preto, (b) Real, (c) Branco, e (d) Vermelho. Na cor vermelha, representa falsos positivos. Em azul, os verdadeiros positivos. Em verde, falsos negativos.



Fonte: Elaborado pelo autor.

conhecimento do especialista em análise de dados, pode ser um método promissor para a identificação de potenciais regiões de gás.

## 6.2 Comparação com Trabalhos Relacionados

Após a apresentação dos resultados, foi realizada uma análise comparativa dos resultados alcançados com os resultados dos trabalhos relacionados. Para uma comparação mais rigorosa, os resultados obtidos no método proposto foram comparados com os trabalhos relacionados que buscam o mesmo objetivo, a detecção de potenciais acumulações de gás. Na Tabela 13, apresentamos informações das técnicas, datasets e um resumo dos resultados encontrados nos trabalhos relacionados e no método proposto.

Analisando a Tabela 13 podemos ver que os trabalhos de Cipriano et al. (2022) e Santos (2019) usam base de imagens sísmicas diferentes da abordada em nosso estudo. Portanto, não é possível fazer uma comparação fiel com esses trabalhos. Esses trabalhos usam MLP-Mixer, U-Net e LSTM, enquanto usamos a ConvLSTM, que combina as vantagens das redes recorrentes (permite que uma memória de entradas anteriores persista no estado interno da rede e, assim, influencie a saída da rede (GOODFELLOW; BENGIO; COURVILLE, 2016) e convolucionais (mantém as características espaciais de uma imagem,

Tabela 13 – Comparação com os trabalhos relacionados.

Técnicas	Base Sísmica	F1 (%)	Sen (%)	Prec (%)	Esp (%)	Acc (%)
MLP-Mixer e U-Net (CIPRIANO et al., 2022)	Netherlands F3-Block	84,18	86,85	83,82	99,79	99,6
Time2Vec Transformer (DINIZ et al., 2022)	Parque dos Gaviões	-	96,12	-	98,92	98,87
LSTM (ANDRADE et al., 2021a)	Parque dos Gaviões	-	-	-	-	-
LSTM (SANTOS et al., 2020)	Parque dos Gaviões	-	90,28	-	97,67	97,62
LSTM (SANTOS, 2019)	Netherlands F3-Block	-	97,1	-	96,83	97,1
<b>Método Proposto</b>	Parque dos Gaviões	85,51	98,88	75,33	98,93	98,35

como a altura e largura (LECUN; BENGIO; HINTON, 2015)). No melhor cenário, esses trabalhos obtiveram resultados inferiores ao nosso método.

Nos trabalhos de Andrade et al. (2021a) e Santos et al. (2020) também fizeram uso da arquitetura LSTM. Santos et al. (2020) usou a técnica de *transfer learning* visando obter um melhor treinamento e generalização do modelo LSTM, e alcançaram 90,28%, 97,67% e 97,62% de sensibilidade, especificidade e acurácia, respectivamente. Andrade et al. (2021a) afirmam que obtiveram boa identificação de acúmulo de gás usando a LSTM. No entanto, nenhuma métrica de validação foi usada para comprovar a eficiência do método. Assim, ficamos impossibilitados de realizar maiores comparações com este trabalho. Em nosso estudo, não limitamos aos resultados visuais, nos quais obtivemos resultados quantitativos promissores e expressivos para cada campo do dataset. Dessa forma, é possível demonstrar a viabilidade da utilização do nosso método para a detecção de possíveis acúmulos de gás em imagens sísmicas.

Diniz et al. (2022) propuseram o modelo Time2Vec que incorpora séries temporais na forma de incorporação de vetores de alta dimensão. Os autores visaram automatizar o processo de engenharia de recursos e melhorar o desempenho do tempo do modelo. Entretanto, não é levado em consideração estruturas espaciais apenas o tempo. Em nosso estudo, desenvolvemos uma abordagem espaço-temporal, preocupando-se com o tratamento da aquisição das imagens sísmicas. Alencado a isso, usamos a ConvLSTM na qual tem potencial para aprender características espaço-temporal. Portanto, a combinação da forma como os dados são tratados e manipulados, resultou em um modelo de alto desempenho, alcançando resultados superiores em relação ao Time2Vec.

Em contraste com os métodos descritos na literatura, destaca-se que nosso trabalho propõe um método que usa exclusivamente propriedades recorrentes e convolucionais mais características espaço-temporais extraídas das imagens sísmicas. Além disso, fazemos uso do PSO para otimizar os hiperparâmetros das amostras espaço-temporais, na qual apresentou uma solução de alta qualidade capaz de fornecer um método mais robusto na tarefa de detectar acúmulos de gás. Assim, foram alcançados resultados comparáveis aos trabalhos consolidados na literatura, indicando que o modelo proposto é promissor e

robusto. Portanto, os resultados indicam que o método sugerido é viável, sendo possível utilizá-lo como ferramenta para a detectar potenciais acumulações de gás.

### 6.3 Aspectos Importantes do Método Proposto

A detecção de acumulações de gás em imagens sísmicas é um desafio. É uma área em constante crescimento, visando contribuir para a redução dos riscos exploratórios, uma vez que se trata de um processo financeiramente oneroso. O método proposto mostrou-se promissor na tarefa de detectar acumulações de gás. Destacamos os aspectos importantes encontrados e suas limitações após a análise das etapas do método.

1. Essa pesquisa rendeu resultados positivos, assumindo posição de destaque entre os métodos encontrados na literatura, apesar da complexidade do desafio na detecção de gás natural;
2. Conhecendo as propriedades das imagens de reflexão sísmica, reconhece-se que podem ser heterogêneas em termos de aquisição e características geomorfológicas. Sendo assim, pode-se ver a importância de uma etapa adicional para detectar padrões de características existentes e agrupar regiões sísmicas semelhantes com base nos padrões identificados. Como existem vários tipos de regiões na mesma imagem sísmica, os modelos tiveram uma convergência mais equilibrada e, portanto, um desempenho superior após formar grupos de regiões sísmicas e treinar modelos especializados para cada grupo. Esta etapa foi fundamental para o sucesso das etapas seguintes;
3. A complexidade desse desafio é amplamente reconhecida em nossa área de pesquisa. Isso fica evidente quando nos deparamos com poucos trabalhos na literatura que abordam o tema em questão. Isso nos mostra a necessidade de ampliar esse cenário pouco explorado, que tem grande responsabilidade social e altos custos exploratórios. Contribuindo assim para a sociedade e pesquisa científica, na qual apresentamos progressos no desenvolvimento dessa área e uso da combinação de técnicas robustas e inovadoras, que podem ser aplicadas a outros problemas em geral;
4. Analisando a aquisição das imagens sísmica, observamos a importância de uma etapa de geração de amostras para servir como entrada ao método proposto. A abordagem adotada levou em consideração o processo de reflexão sísmica, resultando em amostras espaço-temporais. Essa prática impactou diretamente com o desempenho do modelo ConvLSTM, pois as amostras são geradas com base nas características relevantes da imagem, criando uma boa representação dos dados. Essa etapa foi fundamental para o sucesso das etapas subsequentes;
5. ConvLSTM é uma rede recorrente que se destacou devido à sua capacidade de aprender correlações espaço-temporais. Além disso, a forma de predizer os *patches*

espaço-temporais centrais da pilha, considerando os anteriores e os posteriores, foi crucial para obter bons resultados. Essa combinação resultou em um modelo de alto desempenho para detectar potenciais acumulações de gás;

6. É importante destacar que o método proposto é executado por um modelo CNN, que são ferramentas muito robustas que realizam implicitamente a extração e seleção de características. Este é um aspecto positivo, pois elimina a necessidade de extrair empiricamente o conjunto de características a serem utilizadas no processo de aprendizagem e de definir as técnicas a serem usadas na seleção das características;
7. Outro aspecto importante foi o uso do PSO para otimizar hiperparâmetros de amostras espaço-temporais. O PSO gerou uma solução de alta qualidade e apresentou convergência estável. Essa etapa foi capaz de proporcionar maiores chances de detecção bem-sucedida de potenciais acumulações de gás, uma vez que os hiperparâmetros escolhidos apresentaram as características relevantes nas amostras;
8. Finalmente, a combinação de todas as técnicas neste estudo proporcionou uma melhor detecção de potenciais acumulações de gás. Até onde sabemos, este é o primeiro método que combinou explicitamente todas essas técnicas. Em comparação com trabalhos relacionados, o método proposto apresentou resultados expressivos, alcançando no melhor cenário 85,51%, 98,88%, 75,33%, 98,93% e 98,35% de F1-score, sensibilidade, precisão, especificidade e acurácia, respectivamente.

Destaca-se também algumas limitações encontradas no método, apesar de vários fatores positivos:

1. No método proposto, o especialista delimitar previamente a ROI é uma limitação. Uma evolução seria desenvolver um método complementar para detectar a ROI inicialmente;
2. Outra limitação é que o modelo ConvLSTM apresenta bons resultados, porém, a característica ruidosa da imagem acaba dificultando a plena generalização do modelo. Portanto, uma alternativa seria aplicar e combinar algumas técnicas de pré-processamento com o intuito de mitigar o impacto dessa característica ruidosa das imagens sísmicas de reflexão;
3. Por fim, vale ressaltar que o modelo de aprendizado profundo, a ConvLSTM usada em neste estudo, apresenta alguns resultados com muitos falsos positivos. Assim, é importante explorar técnicas de pós-processamento eficazes e que sejam estáveis para criar uma etapa para remover os falsos positivos.

Os aspectos positivos discutidos nas etapas do método proposto contribuíram para os resultados obtidos garantindo um lugar de destaque entre os trabalhos encontrados na literatura. Portanto, este estudo, apesar de algumas limitações, apresenta contribuições para a comunidade científica ao apresentar um novo método para detectar potenciais acumulações de gás natural, além de ampliar a pesquisa na área sísmica. É um ponto de partida para contribuir com uma nova ferramenta para a reduzir os riscos exploratórios de gás, que são financeiramente elevados, além de auxiliar os geofísicos na tarefa de encontrar estruturas de acumulações de gás.

## 6.4 Considerações Finais

Este capítulo apresentou os estudos de casos para a detecção de potenciais acumulações de gás em imagens sísmicas. Também foi feito um comparativo com os trabalhos relacionados, como forma de analisar a relevância da pesquisa desenvolvida. Por fim, as vantagens e limitações foram discutidas após a análise das etapas propostas no método.

No próximo capítulo, são apresentadas as conclusões sobre a pesquisa desenvolvida nesta pesquisa. As principais contribuições também são apontadas, bem como sugestões para trabalhos futuros.

## 7 Conclusão

Neste trabalho foi proposto um método para detectar gás em imagens sísmicas usando agrupamento de regiões sísmicas, espaço-temporal, PSO, ConvLSTM. O método proposto estabelece a dimensão ótima de amostras usando um algoritmo evolutivo para melhor ajustá-lo ao reconhecimento de padrões em imagens sísmicas. Os resultados experimentais revelam que o método proposto é promissor para detecção de potenciais acumulações de gás. No melhor cenário, o método alcançou 85,51% de F1-score, 98,88% de sensibilidade, 75,33% de precisão, 98,93% de especificidade e 98,35% de acurácia, alcançando lugar de destaque entre as outras abordagens consolidadas na literatura. Com isso, acredita-se que o método proposto pode ser fundamental, aliado à prática do especialista, para a detecção de potenciais reservatórios de gás natural.

### 7.1 Contribuições

As principais contribuições do método proposto nesta dissertação são descritas abaixo:

1. Elaboração de um método automático para agrupar regiões de imagens sísmicas e posteriormente treinar um modelo para cada grupo de cada campo de exploração para garantir que as amostras sísmicas fossem equilibradas e assim os modelos obtivessem melhor desempenho;
2. Desenvolvimento da abordagem espaço-temporal para geração de amostras que serviram de entrada para o modelo proposto. Tal abordagem levou em consideração o processo de reflexão sísmica, que se mostrou essencial para o sucesso das demais etapas do método;
3. Aplicação do algoritmo evolutivo PSO para otimizar hiperparâmetros das amostras espaço-temporais. Com este processo, foi escolhido um conjunto de hiperparâmetros em que a amostra obteve características relevantes. Isso garantiu que o modelo fosse equilibrado e tivesse um melhor desempenho;
4. Adaptação da arquitetura ConvLSTM para a detecção de potenciais acumulações de gás. A combinação da abordagem espaço-temporal para gerar amostras em conjunto com o modelo resultou em uma ferramenta poderosa para capturar correlações espaço-temporais.

## 7.2 Trabalhos Futuros

Embora bons resultados tenham sido obtidos para a detecção de potenciais acumulações de gás em imagens sísmica, melhorias ainda podem ser realizadas no método proposto para aumentar a sua eficiência. A seguir são listadas algumas sugestões:

1. Considerando a diversidade de aquisições e os ruídos presentes na base de imagens, padronizar as entradas da rede usando uma rede *autoencoder* como um pré-processamento poderia aumentar a eficiência do modelos de segmentação ConvLSTM;
2. Construir um método complementar para detectar o ROI na imagem de reflexão sísmica. Este novo método seria integrado ao método proposto como um passo inicial para identificar potenciais regiões de reservatório de gás. Posteriormente, a ROI seria usada como entrada para o método proposto;
3. Aprimorar o método de detecção de gás com um *ensemble* com o objetivo de melhorar a precisão.

## 7.3 Produções Científicas

A Tabela 14 apresenta os artigos diretamente relacionados ao tema da pesquisa proposta. Além disso, a Tabela 15 lista os artigos científicos que foram publicados em outras aplicações desde o início do mestrado.

Tabela 14 – Produções científicas relacionadas ao tema da pesquisa proposta.

Artigo	Tipo	Qualis	Status
Gas Detection from Seismic Data using PSO-Optimized Convolutional LSTM Model. Em: Expert Systems with Applications. Ano: 2022.	Periódico	A1	Publicado
Automatic Method Based on PSO-optimized Vision-Transformer for Gas Detection in 2D Seismic Images. Em: Revista de Sistemas e Computação - RSC. Ano: 2022.	Periódico	B5	Publicado
PSO-based ViT-Seismic: A Vision Transformer Approach for Gas Detection in Seismic Images. Em: Escola Regional de Computação do Ceará, Maranhão e Piauí. Ano: 2022.	Congresso	-	Publicado
Automatic gas detection using seismic data and Transformer neural networks. Em: Sociedade Brasileira de Geofísica. Ano: 2021.	Congresso	-	Publicado

Tabela 15 – Produções científicas não relacionadas ao tema da pesquisa proposta.

Artigo	Tipo	Qualis	Status
Time2Vec Transformer: A Time Series Approach for Gas Detection in Seismic Data. Em: Proceedings of the 37th ACM/SIGAPP Symposium on Applied Computing. Ano: 2022.	Congresso	A3	Publicado
Detection and Delimitation of Natural Gas in Seismic Images Using MLP-Mixer and U-Net. Em: International Conference on Enterprise Information Systems. Ano: 2022.	Congresso	A3	Publicado
Kidney tumor segmentation from computed tomography images using DeepLabv3+ 2.5D model. Em: Expert Systems with Applications. Ano: 2022.	Periódico	A1	Publicado
Heart segmentation in planning CT using 2.5D U-Net++ with attention gate. Em: Computer Methods In Biomechanics And Biomedical Engineering-Imaging And Visualization. Ano: 2022.	Periódico	A3	Publicado
Implementando o Gitflow para Gerencia de Configuração em um Projeto de Desenvolvimento de Software Ágil: Um Relato de Experiência. In: Computer on the Beach. Em: Computer on the Beach. Ano: 2021.	Congresso	B3	Publicado
Automatic method for classifying COVID-19 patients based on chest X-ray images, using deep features and PSO-optimized XGBoost. Em: Expert Systems with Applications. Ano: 2021.	Periódico	A1	Publicado
Classificação automática de glóbulos brancos usando descritores de forma e textura e eXtreme Gradient Boosting. Em: Simpósio Brasileiro de Computação Aplicada à Saúde. Ano: 2021.	Congresso	B3	Publicado

# Referências

- ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M. et al. Tensorflow: Large-scale machine learning on heterogeneous systems. *Software available from tensorflow.org*, 2015. Citado na página 50.
- ABBAS, O. A. Comparisons between data clustering algorithms. *International Arab Journal of Information Technology (IAJIT)*, v. 5, n. 3, 2008. Citado na página 32.
- ALMEIDA, E. F. d.; FERRARO, M. C. Indústria do gás natural: fundamentos técnicos e econômicos. *Rio de Janeiro: Synergia*, 2013. Citado na página 20.
- ALMEIDA, F. d.; CARNEIRO, C. D. R. et al. Inundações marinhas fanerozóicas no Brasil e recursos minerais associados. *Mantesso Neto, V.; Bartorelli, A.; Carneiro, CDR*, p. 43–60, 2004. Citado na página 47.
- ANDRADE, F.; SANTOS, L. F.; GATTASS, M.; QUEVEDO, R.; MICHELON, D.; SIEDSCHLAG, C.; RIBEIRO, R. Gas reservoir segmentation in 2d onshore seismics using lstm-autoencoder. In: SOCIETY OF EXPLORATION GEOPHYSICISTS. *First International Meeting for Applied Geoscience & Energy*. [S.l.], 2021. p. 1651–1655. Citado 3 vezes nas páginas 17, 19 e 59.
- ANDRADE, F.; SANTOS, L. F.; GATTASS, M.; QUEVEDO, R.; MICHELON, D.; SIEDSCHLAG, C.; RIBEIRO, R. Gas reservoir segmentation in 2d onshore seismics using lstm-autoencoder. In: SOCIETY OF EXPLORATION GEOPHYSICISTS. *First International Meeting for Applied Geoscience & Energy*. [S.l.], 2021. p. 1651–1655. Citado na página 18.
- ARAYA-POLO, M.; DAHLKE, T.; FROGNER, C.; ZHANG, C.; POGGIO, T.; HOHL, D. Automated fault detection without seismic processing. *The Leading Edge*, Society of Exploration Geophysicists, v. 36, n. 3, p. 208–214, 2017. Citado 2 vezes nas páginas 14 e 17.
- BÄCK, T.; FOGEL, D. B.; MICHALEWICZ, Z. Handbook of evolutionary computation. *Release*, v. 97, n. 1, p. B1, 1997. Citado na página 33.
- BALDI, P.; SADOWSKI, P. J. Understanding dropout. In: *Advances in neural information processing systems 26*. [S.l.: s.n.], 2013. p. 2814–2822. Citado na página 31.
- BARBOSA, G. N.; BEZERRA, G. M. G.; MEDEIROS, D. S. de; LOPEZ, M. A.; MATTOS, D. M. Segurança em redes 5g: Oportunidades e desafios em detecção de anomalias e previsão de tráfego baseadas em aprendizado de máquina. *Sociedade Brasileira de Computação*, 2021. Citado 2 vezes nas páginas 28 e 29.
- BARBOSA, M. O.; PEYERL, D. Natural gas associated with the energy transition and the decentralization of energy generation in Brazil. *Opportunities and Challenges of Natural Gas and Liquefied Natural Gas in Brazil*, p. 18, 2020. Citado 2 vezes nas páginas 20 e 21.

BARLOW, H. B. Unsupervised learning. *Neural computation*, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 1, n. 3, p. 295–311, 1989. Citado na página 32.

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. *Journal of machine learning research*, v. 13, n. 2, 2012. Citado na página 43.

BERKHIN, P. A survey of clustering data mining techniques. In: *Grouping multidimensional data*. [S.l.]: Springer, 2006. p. 25–71. Citado na página 32.

BLAND, M. *An introduction to medical statistics*. [S.l.]: Oxford University Press (UK), 2015. 446 p. Citado na página 36.

BP. *Statistical Review of World Energy*. 2019. Disponível em: <<https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy.html>>. Acesso em: 29 de junho de 2022. Citado na página 21.

CHENG, F.; ZHAO, J. A novel process monitoring approach based on feature points distance dynamic autoencoder. In: KISS, A. A.; ZONDERVAN, E.; LAKERVELD, R.; ÖZKAN, L. (Ed.). *29th European Symposium on Computer Aided Process Engineering*. Elsevier, 2019, (Computer Aided Chemical Engineering, v. 46). p. 757–762. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128186343501272>>. Citado na página 27.

CHENG, J.-Z.; NI, D.; CHOU, Y.-H.; QIN, J.; TIU, C.-M.; CHANG, Y.-C.; HUANG, C.-S.; SHEN, D.; CHEN, C.-M. Computer-aided diagnosis with deep learning architecture: applications to breast lesions in us images and pulmonary nodules in ct scans. *Scientific reports*, Nature Publishing Group, v. 6, n. 1, p. 1–13, 2016. Citado na página 24.

CHEON, E.; LEE, S.-R.; LEE, D.-H. Hazard assessment based on the combination of dan3d and machine learning method for planning closed-type barriers against debris-flow. *Water*, MDPI, v. 12, n. 1, p. 170, 2020. Citado na página 34.

CHEVITARESE, D.; SZWARCMAN, D.; SILVA, R. M. D.; BRAZIL, E. V. Transfer learning applied to seismic images classification. *AAPG Annual and Exhibition*, 2018. Citado na página 17.

CHEVITARESE, D. S.; SZWARCMAN, D.; SILVA, R. G. e; BRAZIL, E. V. Deep learning applied to seismic facies classification: A methodology for training. In: EUROPEAN ASSOCIATION OF GEOSCIENTISTS & ENGINEERS. *Saint Petersburg 2018*. [S.l.], 2018. v. 2018, n. 1, p. 1–5. Citado 2 vezes nas páginas 14 e 17.

CIPRIANO, C. L. S.; JÚNIOR, D. A. D.; DINIZ, P. S.; MARIN, L. F.; PAIVA, A. C. de; DINIZ, J. O. B.; SILVA, A. C. Detection and delimitation of natural gas in seismic images using mlp-mixer and u-net. In: FILIPE, J.; SMIALEK, M.; BRODSKY, A.; HAMMOUDI, S. (Ed.). *Proceedings of the 24th International Conference on Enterprise Information Systems, ICEIS 2022, Online Streaming, April 25-27, 2022, Volume 1*. [S.l.]: SCITEPRESS, 2022. p. 578–585. Citado 4 vezes nas páginas 17, 19, 58 e 59.

COLLOBERT, R.; WESTON, J. A unified architecture for natural language processing: Deep neural networks with multitask learning. In: ACM. *Proceedings of the 25th international conference on Machine learning*. [S.l.], 2008. p. 160–167. Citado na página 14.

COX, M. *Static corrections for seismic reflection surveys*. [S.l.]: Society of Exploration Geophysicists, 1999. Citado na página 13.

DAKE, L. P. *Fundamentals of reservoir engineering*. [S.l.]: Elsevier, 1983. Citado na página 20.

DARABOINA, N.; PACHITSAS, S.; SOLMS, N. von. Natural gas hydrate formation and inhibition in gas/crude oil/aqueous systems. *Fuel*, Elsevier, v. 148, p. 186–190, 2015. Citado na página 20.

DASGUPTA, D.; MICHALEWICZ, Z. Evolutionary algorithms — an overview. In: *Evolutionary Algorithms in Engineering Applications*. [S.l.]: Springer, 1997. p. 3–28. Citado na página 34.

DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, K.; FEI-FEI, L. Imagenet: A large-scale hierarchical image database. In: IEEE. *2009 IEEE conference on computer vision and pattern recognition*. [S.l.], 2009. p. 248–255. Citado na página 41.

DI, H.; WANG, Z.; ALREGIB, G. Deep convolutional neural networks for seismic salt-body delineation. In: *AAPG Annual Convention and Exhibition*. [S.l.: s.n.], 2018. Citado na página 17.

DI, H.; WANG, Z.; ALREGIB, G. Seismic fault detection from post-stack amplitude by convolutional neural networks. In: EUROPEAN ASSOCIATION OF GEOSCIENTISTS & ENGINEERS. *80th EAGE Conference and Exhibition 2018*. [S.l.], 2018. v. 2018, n. 1, p. 1–5. Citado 2 vezes nas páginas 14 e 17.

DINIZ, P.; JUNIOR, D. A. D.; DINIZ, J. O.; PAIVA, A. C. de; SILVA, A. C. d.; GATTASS, M.; QUEVEDO, R.; MICHELON, D.; SIEDSCHLAG, C.; RIBEIRO, R. Time2vec transformer: a time series approach for gas detection in seismic data. In: *Proceedings of the 37th ACM/SIGAPP Symposium on Applied Computing*. [S.l.: s.n.], 2022. p. 66–72. Citado 3 vezes nas páginas 17, 19 e 59.

DOSOVITSKIY, A.; BEYER, L.; KOLESNIKOV, A.; WEISSENBORN, D.; ZHAI, X.; UNTERTHINER, T.; DEHGHANI, M.; MINDERER, M.; HEIGOLD, G.; GELLY, S. et al. An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*, 2020. Citado na página 53.

DRUMMOND, C.; HOLTE, R. Class imbalance and cost sensitivity: Why undersampling beats oversampling. In: *ICML-KDD 2003 Workshop: Learning from Imbalanced Datasets*. [S.l.: s.n.], 2003. v. 3. Citado 2 vezes nas páginas 42 e 52.

DUPOND, S. A thorough review on the current advance of neural network structures. *Annual Reviews in Control*, v. 14, p. 200–230, 2019. Citado na página 26.

EBERHART, R.; KENNEDY, J. Particle swarm optimization. In: CITESEER. *Proceedings of the IEEE international conference on neural networks*. [S.l.], 1995. v. 4, p. 1942–1948. Citado 2 vezes nas páginas 34 e 44.

ECONOMIDES, M. J.; WOOD, D. A. The state of natural gas. *Journal of Natural Gas Science and Engineering*, Elsevier, v. 1, n. 1-2, p. 1–13, 2009. Citado na página 13.

EEB. *Seismic wave*. 2022. Disponível em: <<https://www.britannica.com/science/seismic-wave>>. Acesso em: 30 de junho de 2022. Citado 2 vezes nas páginas 21 e 22.

- ELIAS, S.; ALDERTON, D. *Encyclopedia of Geology*. [S.l.]: Academic Press, 2020. Citado 2 vezes nas páginas 21 e 22.
- ELMAN, J. L. Finding structure in time. *Cognitive science*, Wiley Online Library, v. 14, n. 2, p. 179–211, 1990. Citado na página 26.
- EOF. *Compare-Contrast-Connect: Seismic Waves and Determining Earth's Structure*. 2022. Disponível em: <<https://manoa.hawaii.edu/exploringourfluidearth/node/1336>>. Acesso em: 30 de junho de 2022. Citado na página 22.
- EPE. *Balanço Energético Nacional 2022*. 2022. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2022>>. Acesso em: 29 de junho de 2022. Citado na página 21.
- FAWCETT, T. An introduction to roc analysis. *Pattern recognition letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado 2 vezes nas páginas 36 e 57.
- FERNANDES, B. J. T. *Redes neurais com extração implícita de características para reconhecimento de padrões visuais*. Tese (Doutorado) — Universidade Federal de Pernambuco, Recife, 2013. Citado na página 24.
- FOGEL, D. B. Practical advantages of evolutionary computation. *Applications of Soft Computing*, SPIE, v. 3165, p. 14–22, 1997. Citado na página 44.
- FOREEST, F. V. *The role of natural gas in the dutch energy transition: towards low-carbon electricity supply*. [S.l.]: Oxford Institute for Energy Studies, 2010. Citado na página 21.
- GABRIEL, P. H. R.; DELBEM, A. C. B. *Fundamentos de algoritmos evolutivos*. [S.l.]: ICMC-USP, 2008. Citado 2 vezes nas páginas 34 e 35.
- GAERTLER, M. Clustering. In: \_\_\_\_\_. *Network Analysis: Methodological Foundations*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005. p. 178–215. ISBN 978-3-540-31955-9. Disponível em: <[https://doi.org/10.1007/978-3-540-31955-9\\_8](https://doi.org/10.1007/978-3-540-31955-9_8)>. Citado na página 32.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016. Citado na página 58.
- GUITTON, A.; WANG, H.; TRAINOR-GUITTON, W. Statistical imaging of faults in 3d seismic volumes using a machine learning approach. In: *SEG Technical Program Expanded Abstracts 2017*. [S.l.]: Society of Exploration Geophysicists, 2017. p. 2045–2049. Citado na página 17.
- GUO, Y.; LIU, Y.; OERLEMANS, A.; LAO, S.; WU, S.; LEW, M. S. Deep learning for visual understanding: A review. *Neurocomputing*, v. 187, p. 27 – 48, 2016. ISSN 0925-2312. Recent Developments on Deep Big Vision. Citado 2 vezes nas páginas 24 e 26.
- HAFEMANN, L. G. *An analysis of deep neural networks for texture classification*. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba - PR, 2014. Citado na página 26.
- HALL, C.; THARAKAN, P.; HALLOCK, J.; CLEVELAND, C.; JEFFERSON, M. Hydrocarbons and the evolution of human culture. *Nature*, Nature Publishing Group, v. 426, n. 6964, p. 318–322, 2003. Citado na página 13.

- HAN, J. M.; ANG, Y. Q.; MALKAWI, A.; SAMUELSON, H. W. Using recurrent neural networks for localized weather prediction with combined use of public airport data and on-site measurements. *Building and Environment*, v. 192, p. 107601, 2021. ISSN 0360-1323. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360132321000160>>. Citado na página 26.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778. Citado 3 vezes nas páginas 30, 31 e 41.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. p. 770–778. Citado na página 53.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, Nov 1997. ISSN 0899-7667. Citado 5 vezes nas páginas 27, 28, 29, 45 e 53.
- HUA, K.-L.; HSU, C.-H.; HIDAYATI, S. C.; CHENG, W.-H.; CHEN, Y.-J. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *OncoTargets and therapy*, Dove Press, v. 8, 2015. Citado na página 24.
- HUANG, L.; DONG, X.; CLEE, T. E. A scalable deep learning platform for identifying geologic features from seismic attributes. *The Leading Edge*, Society of Exploration Geophysicists, v. 36, n. 3, p. 249–256, 2017. Citado na página 17.
- HUBEL, D. H.; WIESEL, T. N. Early exploration of the visual cortex. *Neuron*, Elsevier, v. 20, n. 3, p. 401–412, 1998. Citado na página 24.
- HURTADO, J. V.; VALADA, A. Chapter 12 - semantic scene segmentation for robotics. In: IOSIFIDIS, A.; TEFAS, A. (Ed.). *Deep Learning for Robot Perception and Cognition*. Academic Press, 2022. p. 279–311. ISBN 978-0-323-85787-1. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780323857871000178>>. Citado na página 24.
- HUTTER, F.; LÜCKE, J.; SCHMIDT-THIEME, L. Beyond manual tuning of hyperparameters. *KI-Künstliche Intelligenz*, Springer, v. 29, n. 4, p. 329–337, 2015. Citado na página 43.
- ISLAM, M. R.; LU, H. H.; HOSSAIN, M. J.; LI, L. A comparison of performance of ga, pso and differential evolution algorithms for dynamic phase reconfiguration technology of a smart grid. In: IEEE. *2019 IEEE Congress on Evolutionary Computation (CEC)*. [S.l.], 2019. p. 858–865. Citado 2 vezes nas páginas 34 e 44.
- JIN, X.; HAN, J. *K-Medoids Clustering*, *Encyclopedia of Machine Learning*. [S.l.]: Springer US, 2010. Citado 2 vezes nas páginas 32 e 33.
- JOHNSON, J. M.; KHOSHGOFTAAR, T. M. Survey on deep learning with class imbalance. *Journal of Big Data*, Springer, v. 6, n. 1, p. 1–54, 2019. Citado na página 40.
- JUNIOR, D. A. D. *Método automático para classificar pacientes com COVID-19 em imagens de raios-X de tórax, usando Deep Features e XGBoost otimizado com PSO*. Tese (Doutorado) — Universidade Federal do Maranhão, Ciência da Computação. São Luís - MA, 2020. Citado na página 35.

- JÚNIOR, D. A. D.; CRUZ, L. B. da; DINIZ, J. O. B.; SILVA, G. L. F. da; JUNIOR, G. B.; SILVA, A. C.; PAIVA, A. C. de; NUNES, R. A.; GATTASS, M. Automatic method for classifying covid-19 patients based on chest x-ray images, using deep features and pso-optimized xgboost. *Expert Systems with Applications*, Elsevier, v. 183, p. 115452, 2021. Citado 3 vezes nas páginas 30, 41 e 44.
- KARIMI, D.; WARD, R. K. Patch-based models and algorithms for image processing: a review of the basic principles and methods, and their application in computed tomography. *International journal of computer assisted radiology and surgery*, Springer, v. 11, n. 10, p. 1765–1777, 2016. Citado na página 14.
- KENNEDY, J. Particle swarm optimization. *Encyclopedia of machine learning*, Springer, p. 760–766, 2010. Citado 2 vezes nas páginas 35 e 44.
- KENT, J. A. Natural gas. In: \_\_\_\_\_. *Riegel's Handbook of Industrial Chemistry*. Boston, MA: Springer US, 2003. p. 545–569. ISBN 978-0-387-23816-6. Disponível em: <[https://doi.org/10.1007/0-387-23816-6\\_16](https://doi.org/10.1007/0-387-23816-6_16)>. Citado na página 20.
- KIDNAY, A. J.; PARRISH, W. R. *Fundamentals of natural gas processing*. [S.l.]: CRC press, 2006. Citado na página 13.
- KOEHRSEN, W. Overfitting vs. underfitting: A complete example. *Towards Data Science*, 2018. Citado na página 40.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105. Citado na página 14.
- KROHN, C. E. Seismic data acquisition. In: *Handbook of Signal Processing in Acoustics*. [S.l.]: Springer, 2008. p. 1545–1558. Citado 2 vezes nas páginas 22 e 48.
- KVALSVIK, J. Before machine learning: handling seismic data with python and segyio. In: EUROPEAN ASSOCIATION OF GEOSCIENTISTS & ENGINEERS. *81st EAGE Conference and Exhibition 2019*. [S.l.], 2019. v. 2019, n. 1, p. 1–4. Citado na página 50.
- LAU, M. M.; LIM, K. H. Review of adaptive activation function in deep neural network. In: IEEE. *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*. [S.l.], 2018. p. 686–690. Citado na página 31.
- LE, L. T.; NGUYEN, H.; ZHOU, J.; DOU, J.; MOAYEDI, H. et al. Estimating the heating load of buildings for smart city planning using a novel artificial intelligence technique pso-xgboost. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 9, n. 13, p. 2714, 2019. Citado na página 35.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436–44, 05 2015. Citado 4 vezes nas páginas 24, 25, 30 e 59.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Ieee, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 25.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278–2324, 1998. Citado na página 25.

- LECUN, Y.; KAVUKCUOGLU, K.; FARABET, C. Convolutional networks and applications in vision. In: *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*. [S.l.: s.n.], 2010. p. 253–256. Citado na página 26.
- LeCun, Y.; Kavukcuoglu, K.; Farabet, C. Convolutional networks and applications in vision. In: *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*. [S.l.: s.n.], 2010. p. 253–256. ISSN 2158-1525. Citado na página 26.
- LIASHCHYNSKYI, P.; LIASHCHYNSKYI, P. Grid search, random search, genetic algorithm: A big comparison for nas. *arXiv preprint arXiv:1912.06059*, 2019. Citado na página 43.
- LIU, W.; WANG, Z.; LIU, X.; ZENG, N.; LIU, Y.; ALSAADI, F. E. A survey of deep neural network architectures and their applications. *Neurocomputing*, v. 234, p. 11 – 26, 2017. ISSN 0925-2312. Citado na página 25.
- LONG, J.; SHELHAMER, E.; DARRELL, T. Fully convolutional networks for semantic segmentation. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 3431–3440. Citado na página 26.
- MA, Q.; WANG, M.; HU, L.; ZHANG, L.; HUA, Z. A novel recurrent neural network to classify eeg signals for customers' decision-making behavior prediction in brand extension scenario. *Frontiers in Human Neuroscience*, Frontiers Media SA, v. 15, p. 610890, 2021. Citado na página 26.
- MACQUEEN, J. Classification and analysis of multivariate observations. In: *5th Berkeley Symp. Math. Statist. Probability*. [S.l.: s.n.], 1967. p. 281–297. Citado na página 32.
- MANDIC, D.; CHAMBERS, J. *Recurrent neural networks for prediction: learning algorithms, architectures and stability*. [S.l.]: Wiley, 2001. Citado na página 26.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado na página 24.
- MIRANDA, F. S. de; VETTORAZZI, A. L.; CUNHA, P. R. da C.; ARAGÃO, F. B.; MICHELON, D.; CALDEIRA, J. L.; PORSCHE, E.; MARTINS, C.; RIBEIRO, R. B.; VILELA, A. F. et al. Atypical igneous-sedimentary petroleum systems of the parnaíba basin, brazil: seismic, well logs and cores. *Geological Society, London, Special Publications*, Geological Society of London, v. 472, n. 1, p. 341–360, 2018. Citado 6 vezes nas páginas 23, 39, 40, 47, 48 e 53.
- MME. *Boletim Mensal de Acompanhamento da Indústria de Gás Natural 2022*. 2022. Disponível em: <<https://www.gov.br/mme/pt-br/assuntos/secretarias/petroleo-gas-natural-e-bicombustiveis/publicacoes-1/boletim-mensal-de-acompanhamento-da-industria-de-gas-natural>>. Acesso em: 29 de junho de 2022. Citado na página 21.
- MOHAMED, E. H.; EL-BEHAIDY, W. H.; KHORIBA, G.; LI, J. Improved white blood cells classification based on pre-trained deep learning models. *Journal of Communications Software and Systems*, Udruga za komunikacijske i informacijske tehnologije, Fakultet . . . , v. 16, n. 1, p. 37–45, 2020. Citado na página 30.

- MORTON-THOMPSON, D.; WOODS, A. M. et al. *Development geology reference manual: AAPG methods in exploration series, no. 10*. [S.l.]: AAPG, 1993. Citado na página 13.
- NGUYEN, L. D.; LIN, D.; LIN, Z.; CAO, J. Deep cnns for microscopic image classification by exploiting transfer learning and feature concatenation. In: IEEE. *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*. [S.l.], 2018. p. 1–5. Citado na página 31.
- NISHA, S. S.; MEERAL, M. N. 9 - applications of deep learning in biomedical engineering. In: BALAS, V. E.; MISHRA, B. K.; KUMAR, R. (Ed.). *Handbook of Deep Learning in Biomedical Engineering*. Academic Press, 2021. p. 245–270. ISBN 978-0-12-823014-5. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128230145000089>>. Citado 2 vezes nas páginas 25 e 26.
- PAINTER, S. L.; BERESFORD, G.; PATERSON, L. On the distribution of seismic reflection coefficients and seismic amplitudes. *Geophysics*, v. 60, p. 1187–1194, 1995. Citado na página 39.
- PAPATHANASAKI, I. Ground roll attenuation with least-squares and robust inversion. 2020. Citado na página 23.
- PATEL, D.; GIERTSEN, C.; THURMOND, J.; GJELBERG, J.; GRØLLER, E. The seismic analyzer: Interpreting and illustrating 2d seismic data. *IEEE transactions on visualization and computer graphics*, IEEE, v. 14, n. 6, p. 1571–1578, 2008. Citado 2 vezes nas páginas 14 e 19.
- PHAM, B. T.; NGUYEN, M. D.; BUI, K.-T. T.; PRAKASH, I.; CHAPI, K.; BUI, D. T. A novel artificial intelligence approach based on multi-layer perceptron neural network and biogeography-based optimization for predicting coefficient of consolidation of soil. *CATENA*, v. 173, p. 302–311, 2019. ISSN 0341-8162. Citado na página 26.
- POCHET, A.; DINIZ, P. H.; LOPES, H.; GATTASS, M. Seismic fault detection using convolutional neural networks trained on synthetic poststacked amplitude maps. *IEEE Geoscience and Remote Sensing Letters*, IEEE, v. 16, n. 3, p. 352–356, 2018. Citado 2 vezes nas páginas 14 e 17.
- QUINTELLA, C. O. d. V. Natural gas. In: \_\_\_\_\_. Booklets FGV energia, 2014. p. 78. Disponível em: <[https://fgvenergia.fgv.br/sites/fgvenergia.fgv.br/files/caderno\\_fgvenergia\\_gas\\_natural.pdf](https://fgvenergia.fgv.br/sites/fgvenergia.fgv.br/files/caderno_fgvenergia_gas_natural.pdf)>. Citado na página 20.
- RENDÓN, E.; ABUNDEZ, I.; ARIZMENDI, A.; QUIROZ, E. M. Internal versus external cluster validation indexes. *International Journal of computers and communications*, v. 5, n. 1, p. 27–34, 2011. Citado na página 41.
- ROKACH, L.; MAIMON, O. Clustering methods. In: *Data mining and knowledge discovery handbook*. [S.l.]: Springer, 2005. p. 321–352. Citado na página 32.
- ROUSSEEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, Elsevier, v. 20, p. 53–65, 1987. Citado na página 41.

- ROUSSEEUW, P. J.; KAUFMAN, L. *Finding groups in data: An introduction to cluster analysis*. [S.l.]: John Wiley & Sons, 2009. Citado na página 41.
- ROY, S.; KIRAL-KORNEK, I.; HARRER, S. Deep learning enabled automatic abnormal eeg identification. In: IEEE. *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2018. p. 2756–2759. Citado na página 14.
- SANTOS, L. F.; GATTASS, M.; SILVA, A.; MIRANDA, F.; SIEDSCHLAG, C.; RIBEIRO, R. Natural gas detection in onshore data using transfer learning from a lstm pre-trained with offshore data. In: *SEG Technical Program Expanded Abstracts 2020*. [S.l.]: Society of Exploration Geophysicists, 2020. p. 1190–1195. Citado 3 vezes nas páginas 18, 19 e 59.
- SANTOS, L. F. T. *Detector de assinaturas de gás em levantamentos sísmicos utilizando LSTM*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio de Janeiro, 2019. Citado 6 vezes nas páginas 14, 18, 19, 53, 58 e 59.
- SARKER, I. H. Deep cybersecurity: a comprehensive overview from neural network and deep learning perspective. *SN Computer Science*, Springer, v. 2, n. 3, p. 1–16, 2021. Citado 2 vezes nas páginas 25 e 26.
- SARKER, I. H. Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, Springer, v. 2, n. 6, p. 1–20, 2021. Citado na página 25.
- SASAKI, Y.; FELLOW, R. The truth of the f-measure, manchester: Mib-school of computer science. *University of Manchester*, 2007. Citado na página 44.
- SELLEY, R. C.; COCKS, L. R. M.; PLIMER, I. R. *Encyclopedia of geology*. [S.l.]: Elsevier Academic, 2005. Citado 5 vezes nas páginas 22, 39, 40, 42 e 48.
- SENGUPTA, S.; BASAK, S.; SAIKIA, P.; PAUL, S.; TSALAVOUTIS, V.; ATIAH, F.; RAVI, V.; PETERS, A. A review of deep learning with special emphasis on architectures, applications and recent trends. *Knowledge-Based Systems*, p. 105596, 2020. ISSN 0950-7051. Citado na página 24.
- SHI, X.; CHEN, Z.; WANG, H.; YEUNG, D.-Y.; WONG, W.-k.; WOO, W.-c. Convolutional lstm network: A machine learning approach for precipitation nowcasting. In: *Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 1*. Cambridge, MA, USA: MIT Press, 2015. (NIPS'15), p. 802–810. Citado 4 vezes nas páginas 27, 28, 29 e 45.
- SHI, X.; CHEN, Z.; WANG, H.; YEUNG, D.-Y.; WONG, W.-K.; WOO, W.-c. Convolutional lstm network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, v. 28, 2015. Citado na página 29.
- SILVA, R. M.; BARONI, L.; FERREIRA, R. S.; CIVITARESE, D.; SZWARCMAN, D.; BRAZIL, E. V. Netherlands dataset: A new public dataset for machine learning in seismic interpretation. *arXiv preprint arXiv:1904.00770*, 2019. Citado na página 17.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. Citado 2 vezes nas páginas 30 e 41.

SINGH, E.; KUZHAGALIYEVA, N.; SARATHY, S. M. Chapter 9 - using deep learning to diagnose preignition in turbocharged spark-ignited engines. In: BADRA, J.; PAL, P.; PEI, Y.; SOM, S. (Ed.). *Artificial Intelligence and Data Driven Optimization of Internal Combustion Engines*. Elsevier, 2022. p. 213–237. ISBN 978-0-323-88457-0. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780323884570000059>>. Citado na página 27.

SINGH, U.; KEDAS, S.; PRASANTH, S.; KUMAR, A.; SEMWAL, V. B.; TIKKIWAL, V. A. Design of a recurrent neural network model for machine reading comprehension. *Procedia Computer Science*, v. 167, p. 1791–1800, 2020. ISSN 1877-0509. International Conference on Computational Intelligence and Data Science. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050920308541>>. Citado na página 26.

SRINIVAS, M.; MOHAN, C. K. Medical image indexing and retrieval using multi-feature extraction method. In: *Proceedings of the IEEE International Conference on Computational Intelligence and Information Technology (CIIT)(Elsevier), Mumbai*. [S.l.: s.n.], 2013. Citado na página 26.

SYAKUR, M.; KHOTIMAH, B.; ROCHMAN, E.; SATOTO, B. D. Integration k-means clustering method and elbow method for identification of the best customer profile cluster. In: IOP PUBLISHING. *IOP conference series: materials science and engineering*. [S.l.], 2018. v. 336, n. 1, p. 012017. Citado na página 32.

SZEGEDY, C.; IOFFE, S.; VANHOUCKE, V.; ALEMI, A. Inception-v4, inception-resnet and the impact of residual connections on learning. *arXiv preprint arXiv:1602.07261*, 2016. Citado na página 31.

TAHA, A. A.; HANBURY, A. Metrics for evaluating 3d medical image segmentation: analysis, selection, and tool. *BMC medical imaging*, BioMed Central, v. 15, n. 1, p. 1–28, 2015. Citado na página 36.

TAN, M.; LE, Q. Efficientnet: Rethinking model scaling for convolutional neural networks. In: PMLR. *International conference on machine learning*. [S.l.], 2019. p. 6105–6114. Citado 4 vezes nas páginas 30, 31, 41 e 50.

TEIXEIRA, W.; FAIRCHILD, T. R.; TOLEDO, M. C. M. d.; TAIOLI, F. Decifrando a terra. 2009. Citado na página 13.

THOMAS, J. E. et al. Fundamentos de engenharia de petróleo. 2ª edição. *Editora Interciência*, 2004. Citado 3 vezes nas páginas 21, 22 e 48.

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, L.; POLOSUKHIN, I. Attention is all you need. *arXiv preprint arXiv:1706.03762*, 2017. Citado na página 53.

WHEELER, J.; CHEADLE, M. Geophysics. In: *Reference Module in Earth Systems and Environmental Sciences*. Elsevier, 2014. ISBN 978-0-12-409548-9. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780124095489090382>>. Citado na página 21.

- WRONA, T.; PAN, I.; GAWTHORPE, R. L.; FOSSEN, H. Seismic facies analysis using machine learning. *Geophysics*, Society of Exploration Geophysicists, v. 83, n. 5, p. O83–O95, 2018. Citado na página 17.
- WU, X.; GENG, Z.; SHI, Y.; PHAM, N.; FOMEL, S.; CAUMON, G. Building realistic structure models to train convolutional neural networks for seismic structural interpretation. *Geophysics*, Society of Exploration Geophysicists, v. 85, n. 4, p. WA27–WA39, 2020. Citado na página 14.
- XAVIER, J.; MACHADO, J.; THOMAS, J.; FILHO, d. S. J.; PAULA, J. d.; ROSSI, N. d.; PITOMBO, N.; GOUVEA, P. d. M. Fundamentos da engenharia do petróleo. *Segunda edição*. Rio de Janeiro: Editora Interciência, 2001. Citado na página 20.
- YANG, C.; XU, C. Properties of hadamard product of inverse m-matrices. *Numerical Linear Algebra with Applications*, Wiley Online Library, v. 11, n. 4, p. 343–354, 2004. Citado na página 29.
- ZHANG, Z.; LIU, Q.; WANG, Y. Road extraction by deep residual u-net. *IEEE Geoscience and Remote Sensing Letters*, IEEE, v. 15, n. 5, p. 749–753, 2018. Citado na página 53.
- ZHAO, T. Seismic facies classification using different deep convolutional neural networks. In: *SEG Technical Program Expanded Abstracts 2018*. [S.l.]: Society of Exploration Geophysicists, 2018. p. 2046–2050. Citado na página 17.
- ZHU, W.; MA, Y.; ZHOU, Y.; BENTON, M.; ROMAGNOLI, J. Deep learning based soft sensor and its application on a pyrolysis reactor for compositions predictions of gas phase components. In: EDEN, M. R.; IERAPETRITOU, M. G.; TOWLER, G. P. (Ed.). *13th International Symposium on Process Systems Engineering (PSE 2018)*. Elsevier, 2018, (Computer Aided Chemical Engineering, v. 44). p. 2245–2250. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780444642417503694>>. Citado na página 25.
- ZITZLER, E. *Evolutionary algorithms for multiobjective optimization: Methods and applications*. [S.l.]: Citeseer, 1999. v. 63. Citado na página 43.