

UNIVERSIDADE FEDERAL DO MARANHÃO – UFMA  
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ELETRICIDADE

**CAROLINA LIMA SARAIVA CIPRIANO**

**DETECÇÃO E DELIMITAÇÃO DE GÁS NATURAL EM IMAGENS  
SÍSMICAS USANDO MLP-MIXER E U-NET**

SÃO LUÍS – MA

2022

CAROLINA LIMA SARAIVA CIPRIANO

DETECÇÃO E DELIMITAÇÃO DE GÁS NATURAL EM IMAGENS  
SÍSMICAS USANDO MLP-MIXER E U-NET

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão como requisito parcial para obtenção do grau de Mestra em Engenharia Elétrica.

Orientador: Prof. Dr. Aristófanés Corrêa Silva

Coorientador: Prof. Dr. Anselmo Cardoso de Paiva

SÃO LUÍS – MA

2022

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

Cipriano, Carolina Lima Saraiva.

Detecção e Delimitação de Gás Natural em Imagens Sísmicas usando Mlp-mixer e U-net / Carolina Lima Saraiva Cipriano. - 2023.

55 p.

Coorientador(a): Anselmo Cardoso de Paiva.

Orientador(a): Aristóфанes Corrêa Silva.

Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Elétrica/ccet, Universidade Federal do Maranhão, Videoconferência, 2023.

1. Aprendizado de máquina. 2. Hidrocarbonetos. 3. Imagens sísmicas. 4. MLP-Mixer. 5. U-Net. I. Paiva, Anselmo Cardoso de. II. Silva, Aristófanes Corrêa. III. Título.

CAROLINA LIMA SARAIVA CIPRIANO

**DETECÇÃO E DELIMITAÇÃO DE GÁS NATURAL EM IMAGENS  
SÍSMICAS USANDO MLP-MIXER E U-NET**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão como requisito parcial para obtenção do grau de Mestra em Engenharia Elétrica.

Dissertação aprovada em 20 de janeiro de 2023.

---

**Prof. Dr. Aristófanês Corrêa Silva**  
Orientador

---

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

---

**Prof. Dr. André Borges Cavalcante**  
Membro da Banca Examinadora

---

**Prof. Dr. Antonio Oseas De Carvalho  
Filho**  
Membro da Banca Examinadora

SÃO LUÍS – MA  
2022

*A meu Deus, família e amigos dessa jornada*

## AGRADECIMENTOS

Agradeço a Deus por Sua bondade, Sua misericórdia e pelas condições dadas para realizar este trabalho. Sou muito grata à minha família, em especial a minha mãe Marcileude Lima, meu pai Wellington Soares e meu irmão Gustavo Soares, por todo o apoio e incentivo na realização dos meus sonhos.

Agradeço também ao meu orientador, o Prof. Dr. Aristófanês Corrêa Silva, com quem trabalhei desde o início de minha carreira científica. Ele me ensinou sobre Processamento de Imagem, Machine Learning e ciência, além de me ensinar sobre resiliência e determinação. Obrigada pelos conselhos, puxões de orelha (rsrs) e por sempre acreditar no meu trabalho

Agradeço também ao meu coorientador, o Prof. Dr. Anselmo Cardoso de Paiva, o melhor professor de ED1, sempre disposto a ajudar com suas correções e palavras de incentivo.

Agradeço também ao Prof. Dr. João Dallyson e à Profa. Dra Simara Vieira, com quem tive a oportunidade de aprender muito em alguns projetos de pesquisa durante minha jornada.

A todos os meus amigos de graduação e pós-graduação, especialmente Luana Batista, Domingos Alves (Obrigada amigo, você é um amigo rsrs), Victor Henrique e Nélia Reis, que me apoiaram e incentivaram durante a pesquisa.

Agradeço também ao Núcleo de Computação Aplicada (NCA) da Universidade Federal do Maranhão, onde pude aprender e crescer profissionalmente ao lado de pesquisadores e amigos que levarei para sempre comigo.

Agradeço a Felipe Jordão, Luiz Santos, Carlos Siedschlag e toda a equipe da Tecgraf pelos aprendizados e pelo suporte na resolução de dúvidas sobre dados sísmicos, sendo fundamentais para este trabalho.

Sou grata ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento da pesquisa, ao Instituto Tecgraf (PUC-Rio) pelo apoio e disponibilização dos dados, e ao Programa de Pós-Graduação em Engenharia Elétrica (PPGE) pelo apoio à pesquisa.

Por fim, agradeço também a todos os professores e educadores que tive o prazer de conhecer até agora, em especial à minha professora favorita: minha mãe.

*"Quem na concha de sua mão mediu as águas  
e tomou a medida dos céus a palmos? [...]  
e pesou os montes e as colinas numa balança?"*

*(Isaías 40:12)*

## RESUMO

O uso da energia é fundamental para a realização de diversas atividades, desde as mais simples até as mais complexas. Os hidrocarbonetos são uma das principais fontes de energia atualmente utilizadas e são originados a partir da decomposição de compostos orgânicos presentes em camadas geológicas subterrâneas ou marinhas. Para identificar essas camadas e detectar a extensão dos depósitos de hidrocarbonetos, é necessário realizar o levantamento sísmico. Dados sísmicos adquiridos por meio do método de reflexão sísmica são importantes para a prospecção de hidrocarbonetos, mas as técnicas de análise desses dados são complexas para os especialistas e estão sujeitas a erros e divergências. Além disso, os reservatórios de hidrocarbonetos podem ter diferentes tamanhos e formas, variando de grandes e contínuos a pequenos e fragmentados. O crescimento do aprendizado profundo tem trazido grandes destaques para tarefas de segmentação, classificação e detecção de objetos em imagens de diversas áreas. Consequentemente, também cresce o uso de aprendizado de máquina em dados sísmicos. Por essa razão, este trabalho propõe um método automático de detecção e delimitação de regiões de gás natural em imagens sísmicas 2D utilizando a rede neural MLP-Mixer e U-Net. A MLP-Mixer é usada para detectar regiões de interesse que podem conter gás, reduzindo o número de falsos positivos e facilitando a delimitação do gás. A U-Net é utilizada para a tarefa de delimitação da região de gás, que é a etapa mais complexa. Apesar do desbalanceamento natural entre o número de amostras de gás e não gás, a U-Net teve um desempenho satisfatório no método proposto. Os resultados obtidos para a detecção de hidrocarbonetos foram competitivos, com uma acurácia de 99,6% para seções sísmicas *inline* e 99,55% para seções sísmicas *crossline* e uma especificidade de 99,79% para seções sísmicas *inline* e 99,73% para seções sísmicas *crossline*.

**Palavras-chave:** Hidrocarbonetos, Imagens sísmicas, Aprendizado de máquina, MLP-Mixer, U-Net.



## ABSTRACT

Energy use is essential for carrying out various activities, from the simplest to the most complex. Hydrocarbons are one of the main energy sources currently used and originate from the decomposition of organic compounds in underground or marine geological layers. To identify these layers and detect the extent of hydrocarbon deposits, it is necessary to carry out a seismic survey. Seismic data acquired through the seismic reflection method are important for prospecting hydrocarbons, but the techniques for analyzing these data are complex for specialists and are subject to errors and divergences. In addition, hydrocarbon reservoirs can have different sizes and shapes, ranging from large and continuous to small and fragmented. The growth of deep learning has greatly emphasized segmentation, classification and object detection tasks in images from different areas. Consequently, the use of machine learning on seismic data is also growing. For this reason, this work proposes an automatic method of detection and delimitation of natural gas regions in 2D seismic images using the neural network MLP-Mixer and U-Net. The MLP-Mixer is used to detect regions of interest that may contain gas, reducing the number of false positives and facilitating gas delimitation. U-Net is used for the gas region delimitation task, which is the most complex step. Despite the natural imbalance between the number of gas and non-gas samples, U-Net had a satisfactory performance in the proposed method. The results obtained detecting of hydrocarbons were competitive, with an accuracy of 99.6% for inline seismic sections and 99.55% for crossline seismic sections and a specificity of 99.79% for inline seismic sections and 99.73% for crossline seismic sections.

**Keywords:** Hydrocarbons, Seismic images, Machine learning, MLP-Mixer, U-Net.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Aquisição de dados sísmicos. . . . .	22
Figura 2 – Modelos supervisionados. . . . .	24
Figura 3 – Neurônio artificial. . . . .	25
Figura 4 – Exemplo e MLP com três camadas. . . . .	26
Figura 5 – Arquitetura MLP-Mixer. . . . .	27
Figura 6 – Arquitetura U-Net. . . . .	29
Figura 7 – Etapas do método proposto. . . . .	32
Figura 8 – Exemplo de extração de <i>patch</i> 2D com sobreposição. . . . .	33
Figura 9 – Arquitetura da MLP-Mixer proposta. . . . .	34
Figura 10 – Arquitetura da U-Net proposta. . . . .	35
Figura 11 – Imagem ilustrativa. A) Localização aproximada da <i>Netherlands F3-Block</i> e B) <i>Netherlands F3-Block</i> 3D visualizada com <i>OpendTect</i> . . .	37
Figura 12 – Imagem ilustrativa. A) Cubo sísmico, B) Região de interesse e C) Seções sísmicas 2D e marcações do especialista . . . . .	38
Figura 13 – <i>Crossline</i> 909: Resultado geral. . . . .	44
Figura 14 – <i>Inline</i> 597: Caso bom. . . . .	45
Figura 15 – <i>Inline</i> 221: Caso ruim. . . . .	45
Figura 16 – <i>Crossline</i> 511: Caso bom. . . . .	45

## LISTA DE TABELAS

Tabela 1 – Matriz de confusão. . . . .	30
Tabela 2 – Quantidade de amostras geradas para os modelos de Detecção da região de gás. . . . .	39
Tabela 3 – Quantidade de amostras geradas para os modelos de Delimitação da região de gás. . . . .	39
Tabela 4 – Configurações usadas na MLP-Mixer. . . . .	40
Tabela 5 – Resultado da etapa de Detecção da região de gás . . . . .	40
Tabela 6 – Bloco de classificação para os modelos de comparação do Detecção da região de gás. . . . .	40
Tabela 7 – Tabela de comparação de métodos para detecção de gás. . . . .	41
Tabela 8 – Comparação dos modelos em relação ao tempo de treinamento. . . .	41
Tabela 9 – Resultado do método proposto. . . . .	42
Tabela 10 – Comparação do método proposto com outro trabalho da literatura .	42
Tabela 11 – Artigos publicados que possuem relação com o tema proposto. . . . .	48

## LISTA DE ABREVIATURAS E SIGLAS

AC	Acurácia
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
AUC	<i>Area under the ROC Curve</i>
CNN	<i>Convolutional Neural Network</i>
CNPQ	Conselho Nacional de Desenvolvimento Científico e Tecnológico
DL	<i>Deep Learning</i>
F1	<i>F1 score</i>
FN	Falso Negativo
FP	Falso Positivo
LSTM	<i>Long Short-Term Memory</i>
MLP	<i>Multilayer Perceptron</i>
ML	<i>Machine Learning</i>
NCA	Núcleo de Computação Aplicada
PPGE	Programa de Pós Graduação em Engenharia Elétrica
PRE	Precisão
ReLU	<i>Rectified Linear Unit</i>
ROC	<i>Receiver Operating Characteristic</i>
SEAL	<i>Offshore</i> do Sergipe-Alagoas
SEN	Sensibilidade
ESP	Especificidade
UFMA	Universidade Federal do Maranhão
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

## SUMÁRIO

1	INTRODUÇÃO . . . . .	13
1.1	Objetivos . . . . .	15
1.1.1	Objetivos Específicos . . . . .	15
1.2	Organização do Trabalho . . . . .	16
2	TRABALHOS RELACIONADOS . . . . .	17
2.1	Detecção de Hidrocarbonetos . . . . .	17
2.2	Detecção de Corpos e Estruturas Sísmicas . . . . .	18
2.3	Considerações . . . . .	19
3	FUNDAMENTAÇÃO TEÓRICA . . . . .	21
3.1	Prospecção de Hidrocarbonetos . . . . .	21
3.2	Aprendizado de Máquina . . . . .	23
3.2.1	Redes Neurais Artificiais . . . . .	24
3.2.2	<i>Multilayer Perceptron</i> . . . . .	25
3.2.2.1	MLP-Mixer . . . . .	26
3.2.3	Redes Neurais Convolucionais . . . . .	27
3.2.3.1	U-Net . . . . .	28
3.3	Métricas de Avaliação . . . . .	30
4	MÉTODO PROPOSTO . . . . .	32
4.1	Pré-processamento . . . . .	32
4.2	Detecção da Região de Gás . . . . .	33
4.3	Delimitação da Região de Gás . . . . .	35
5	RESULTADOS E DISCUSSÃO . . . . .	37
5.1	Base de Dados <i>Netherlands F3-Block</i> . . . . .	37
5.2	Configuração dos Experimentos . . . . .	38
5.3	Pré-processamento . . . . .	39
5.4	Detecção da Região de Gás . . . . .	39
5.5	Delimitação da Região de Gás . . . . .	41
5.6	Discussão . . . . .	42
5.7	Visualização dos Resultados . . . . .	44

<b>6</b>	<b>CONCLUSÃO</b> . . . . .	<b>46</b>
<b>6.1</b>	<b>Trabalhos Futuros</b> . . . . .	<b>47</b>
<b>6.2</b>	<b>Produções Científicas</b> . . . . .	<b>47</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>49</b>

## 1 INTRODUÇÃO

No processo de desenvolvimento cultural humano, a exploração de recursos energéticos para obtenção de energia tem sido indispensável. No curso desse desenvolvimento, o músculo humano, animal, a energia eólica e hidráulica foram usados como energia por muito tempo. Mas, o protagonismo dessas energias foi sendo substituído por combustíveis fósseis (também conhecidos por hidrocarbonetos), como: carvão, no século XIX; petróleo, desde o século XX; e, agora, cada vez mais, gás natural (HALL et al., 2003).

Essa energia indispensável é necessária desde as tarefas mais simples até as tarefas mais complexas desempenhadas pelo homem, como: cozinhar alimentos, aquecer, refrigerar, iluminar, processar materiais e o próprio transporte (JENKINS; EKANAYAKE, 2017). Apesar dos investimentos em energias renováveis, hoje, a participação dos hidrocarbonetos no cenário global de energia tem sido alta, em torno de 80% (IEA, 2022).

A origem dos hidrocarbonetos vem da decomposição natural de compostos orgânicos (ISLAM; HOSSAIN; ISLAM, 2018). Eles estão enterrados em profundas estruturas geológicas subterrâneas ou marinhas (AL-SHUHAIL; AL-DOSSARY; MOUSA, 2017). E a produção de hidrocarbonetos varia no espaço e no tempo. Pois, as atuais áreas produtoras podem ficar sem reservas, mas novas reservas estão sempre sendo descobertas em outros lugares (TEIXEIRA et al., 2009).

Para explorar esses recursos, primeiro é necessário determinar a estrutura subterrânea. Isso significa obter uma imagem clara e precisa da subsuperfície por meio da coleta de dados em larga escala (AL-SHUHAIL; AL-DOSSARY; MOUSA, 2017). No entanto, a maneira mais segura de encontrar esses depósitos é perfurando poços. A tecnologia de perfuração rotativa tornou a perfuração de poços mais conveniente, mas escolher o local exato de perfuração continua sendo uma tarefa difícil (BARATI; ALHUBAIL, 2020). Como tal, a maioria das análises e explorações dependem de técnicas para detectar e determinar a extensão desses depósitos (COX, 1999).

Para determinar as estruturas da subsuperfície (terra ou mar) e detectar a extensão desses depósitos é necessário o levantamento sísmico. Os levantamentos sísmicos podem ser de dois tipos - refração e reflexão. As pesquisas geofísicas na indústria de gás são conduzidas principalmente usando técnicas de reflexão sísmica (COX, 1999). Essa técnica fornece mais informações, resolvendo detalhes estruturais e produzindo imagens

tridimensionais completas do subsolo (ASHCROFT, 2011). Após a aquisição dos dados, eles passarão pelos intérpretes sísmicos.

A interpretação dos dados é feita principalmente pelas empresas petrolíferas, que empregam geofísicos e geólogos como intérpretes sísmicos (ASHCROFT, 2011). Os reservatórios de hidrocarbonetos variam de formações grandes, espessas e contíguas a armazenamentos pequenos, rasos e fragmentados (SMIL, 2015). A tarefa de interpretação é desafiadora devido à baixa resolução e a natureza ruidosa dos dados sísmicos. Em caso de dúvida, o especialista, com frequência, cria várias alternativas da mesma estrutura sísmica. Além disso, não é incomum que a equipe discorde da interpretação e considere que partes dos dados podem ser reinterpretadas (Patel et al., 2008).

O uso de técnicas computacionais de Aprendizado de Máquina (do inglês *Machine Learning*, ML) e Aprendizado Profundo (do inglês *Deep Learning*, DL) nos dados sísmicos vem crescendo para aprimorar esses estudos. O uso do ML aumentou ao longo dos anos para auxiliar em uma variedade de tarefas e tomadas de decisão em problemas reais (SHINDE; SHAH, 2018). Esse crescimento acontece, em especial no aprendizado profundo, pela quantidade de dados disponíveis que possibilitam o treinamento desses modelos.

Em geofísica, os dados públicos são escassos e o número de pesquisas em relação à prospecção de hidrocarbonetos é pequena, se comparada a grandes áreas de aplicação, como a medicina. Mas o número de pesquisas de detecção de hidrocarbonetos bem como outros corpos e estruturas sísmicas como chaminés de gás (DIXIT; MANDAL, 2020), (RAMYA; SOMASUNDARESWARI; VIJAYALAKSHMI, 2020); corpos de sal (SHI; WU; FOMEL, 2018); fácies sísmicas (ZHAO, 2018) e falhas sísmicas (XIONG et al., 2018) vem crescendo.

As pesquisas citadas com ML em geofísica são muito diversificadas. Muitos dos trabalhos na literatura usam: redes neurais artificiais com atributos sísmicos, séries temporais, imagens 2D, dados 3D, dados sintéticos e muito mais. A abordagem 3D é complexa, pois a quantidade de dados sísmicos públicos necessários são difíceis de obter. A dificuldade do uso de dados sintéticos está em sua natureza de criação e similaridade com o mundo real. Outra abordagem é o uso de atributos sísmicos, sendo uma forma de fornecer recursos previamente conhecidos para detectar esses objetos, como exemplo da extração de características em imagens. Conforme citado por Wang et al. (2018), tratar dados sísmicos como imagens em vez de traços de sinal permite que os pesquisadores usem técnicas avançadas de processamento de imagem e aprendizado de máquina para



ajudar diretamente na interpretação.

Portanto, este trabalho, motivado pelo crescimento do aprendizado profundo e pela necessidade de interpretar dados sísmicos, aplica técnicas de aprendizado profundo, especialmente abordagens 2D, para detectar hidrocarbonetos em dados sísmicos para auxílio dos geofísicos. Esses estudos podem fornecer uma segunda análise, reduzir o tempo de resposta ou fornecer novas informações que podem ter implicações, inclusive, econômicas.

## 1.1 Objetivos

O objetivo geral desse trabalho é propor um método automático de detecção e delimitação de regiões que podem ocorrer acumulação de gás natural em imagens sísmicas 2D.

### 1.1.1 Objetivos Específicos

A fim de atingir o objetivo geral desta pesquisa, foram necessários realizar alguns objetivos específicos:

- Investigar as principais dificuldades no uso de aprendizado de máquina em dados sísmicos 2D;
- Investigar o desempenho de técnicas de Aprendizado de Máquina em dados sísmicos 2D usando os dados em diferentes escalas;
- Investigar arquiteturas capazes de atenuar os principais problemas do uso de DL em dados sísmicos 2D;
- Aplicar a rede MLP-Mixer em dados sísmicos 2D para diferentes tamanhos de imagem para classificação de *patches*;
- Aplicar a rede U-Net em dados sísmicos 2D para segmentação semântica;
- Avaliar o impacto de detecção da região de interesse antes da segmentação semântica de gás natural em dados sísmicos 2D;
- Avaliar o desempenho do método proposto, bem como a comparação com outros trabalhos encontrados na literatura.

## 1.2 Organização do Trabalho

Para melhor compreensão, este trabalho está organizado em mais cinco capítulos, além do capítulo de introdução. São eles:

- O **Capítulo 2** apresenta os trabalhos encontrados na literatura relacionados ao tema proposto e que contribuíram com o desenvolvimento dessa pesquisa.
- O **Capítulo 3** apresenta os principais conceitos utilizados e necessários para compreensão e construção do trabalho.
- O **Capítulo 4** apresenta os materiais, métodos e etapas que fazem parte do desenvolvimento da pesquisa.
- O **Capítulo 5** apresenta e discute os resultados obtidos pelo método proposto e analisa o desempenho em relação aos principais trabalhos relacionados ao tema de pesquisa.
- O **Capítulo 6** apresenta em resumo as considerações finais e futuras melhorias levantadas ao decorrer do desenvolvimento deste trabalho.

## 2 TRABALHOS RELACIONADOS

Neste capítulo, serão discutidos os trabalhos encontrados na literatura relacionados ao tema proposto ou que tenham contribuído para o desenvolvimento deste estudo. Foram encontrados alguns trabalhos fortemente relacionados à detecção direta de hidrocarbonetos (especialmente gás natural). Entretanto, a maioria dos trabalhos não teve estreita relação, mas contribuíram significativamente para o desenvolvimento desta pesquisa. A Seção 2.1 apresenta os trabalhos fortemente conectados, a Seção 2.2 os trabalhos que contribuíram e a Seção 2.3 são feitas as considerações sobre os trabalhos e a abordagem proposta.

### 2.1 Detecção de Hidrocarbonetos

Em Diniz et al. (2022), os autores propuseram um método para detectar anomalias conhecidas como Indicadores Diretos de Hidrocarbonetos. Para fazer isso, utilizaram a *Deep Transformer Neural Network* em imagens sísmicas. Os dados usados para conduzir os experimentos são da Bacia Paleozoica do Parnaíba, localizada no Nordeste do Brasil. No total, os dados disponíveis consistem em 380 seções sísmicas fornecidas e rotuladas pela Eneva SA. Os melhores resultados obtiveram acurácia de 98%, sensibilidade de 86% e especificidade de 98%.

Em Andrade et al. (2021), os autores propuseram um método para segmentação de dados sísmicos 2D *onshore* para exploração de gás natural. Esta abordagem usa a arquitetura codificador-decodificador *Long Short-Term Memory* (LSTM). Os autores também apresentam alguns *insights* sobre como reduzir os efeitos da qualidade da imagem por etapas de normalização e agrupamento de conjuntos de dados para melhorar a precisão de treinamento do modelo. A base de dados é da Bacia Paleozoica do Parnaíba, localizada no Nordeste do Brasil, mas os resultados numéricos obtidos com os experimentos não foram informados.

Em Santos et al. (2019) os autores propuseram uma nova abordagem para detectar indicadores de hidrocarbonetos em dados sísmicos usando traço sísmico e uma rede neural LSTM. Os dados foram usados de forma unidimensional ao longo do traço sísmico. Nesse processo, cada traço sísmico foi extraído usando quarenta amostras de comprimento de janela com sobreposição de uma amostra a cada janela. A base pública de dados usada para a identificação de gases no conjunto de dados foi a *Netherlands F3-Block*. Usando a

acurácia como principal métrica, o modelo alcançou 97% para delimitar automaticamente os locais de bolsas de gás.

## 2.2 Detecção de Corpos e Estruturas Sísmicas

Em Souza et al. (2020) os autores propuseram a identificação de *leads* geológicas de hidrocarbonetos em reservatórios de petróleo usando a arquitetura U-Net. A metodologia usando a rede de segmentação semântica utilizou como entrada *patches* 2D 80x80 com um limiar de 20% para rotulação de *patches* com *leads*. A base utilizada foi a *offshore* Sergipe-Alagoas (SEAL), bacia no nordeste do Brasil e divulgada pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP).

Em Hu et al. (2020) os autores propuseram um trabalho de segmentação de falhas sísmicas usando aprendizado profundo. A rede utilizada foi a VGG16 simplificada para detecção de falhas sísmicas de ponta a ponta, onde foi construído um fluxo de trabalho para implementar o processo de interpretação. Os dados utilizados foram a base de dados pública *Netherlands F3-Block*.

Em Cunha et al. (2020) os autores propuseram usar técnicas de Transferência de Aprendizado para explorar um classificador existente e aplicá-lo a outros dados sísmicos com pouco esforço. O modelo base é uma rede neural convolucional treinada e sintonizada em dados sísmicos sintéticos. Os resultados da Transferência de Aprendizado foram aplicados no bloco *Netherlands F3-Block offshore* da Holanda no Mar do Norte.

Em Zini, Rizk e Awad (2019) os autores propuseram um método de detecção de pontos brilhantes. Os pontos brilhantes são fortes indicadores da presença de gás natural. O modelo usou a SeisNet, uma rede neural convolucional com uma arquitetura "borboleta". O modelo também contou com o aumento de dados e transferência-aprendizado para superar o problema de limite de dados. Os dados usados no treinamento do SeisNet são adotados a partir de Rizk, Partamian e Awad (2017) e consistem em 110 imagens em escala de cinza. Com isso, foi alcançado 95,6% de *F1 score* e uma precisão com um erro absoluto médio que não excedeu 0,04% do volume total.

Em Souza et al. (2019) os autores propuseram uma classificação automática de *leads* em imagens sísmicas 2D através de redes neurais *perceptron* multicamadas e redes neurais convolucionais. Neste trabalho, "*lead*" é interpretado como uma estrutura cujo potencial de recuperação de hidrocarbonetos é incerto. A primeira abordagem (*perceptron*

multicamadas) é baseada em uma rede neural artificial padrão cujos recursos de entrada são orientados pelos descritores texturais de *Haralick*; o segundo (rede neural convolucional) é desenvolvido com múltiplas camadas que tenta identificar anomalias sísmicas usando filtros de processamento de imagem suportados pela biblioteca *Keras*. A base utilizada é um reservatório *offshore* localizado em águas profundas de Sergipe-Alagoas, no nordeste do Brasil. A quantidade de imagens para treino e teste não são mencionadas.

### 2.3 Considerações

Os trabalhos mencionados têm uma grande contribuição para a comunidade científica. Na Seção 2.1, Diniz et al. (2022) e Andrade et al. (2021) propuseram métodos de detecção de indicadores diretos de hidrocarbonetos em imagens sísmicas 2D. E, embora utilizem uma abordagem com redes neurais recorrentes e séries temporais, em Santos et al. (2019) os autores também propuseram a detecção direta de hidrocarbonetos. Na Seção 2.2 muitos trabalhos possuem uma abordagem com redes neurais convolucionais e dados bidimensionais, bem como essa pesquisa. Porém, por buscarem objetos diferentes dos hidrocarbonetos, não são considerados fortemente conectados para comparação de resultados. No entanto, eles são úteis para observar o comportamento dessas técnicas em dados sísmicos. São elas:

- Redes neurais recorrentes, utilizadas principalmente em abordagens 1D com traços sísmicos;
- Redes neurais *perceptron* multicamadas, que muitas vezes utilizam de recursos de entrada, guiadas por descritores de textura;
- Redes neurais convolucionais, que podem depender apenas de imagens como dados de entrada;
- Extração de *patches*, com o recurso de sobreposição para aumento de dados;
- Uso de dados sintéticos;
- Transferência de aprendizado.

Como podemos observar, os trabalhos encontrados usam alguma categoria de rede neural, sendo um algoritmo de ML, em suas abordagens. Outro ponto importante é

que a maioria dos trabalhos utiliza recursos para agregar dados, pois a falta de dados é um dos principais problemas encontrados no campo das sísmicas. Algumas pesquisas usam *patches* unidimensionais ou bidimensionais, com recurso de sobreposição. Há o uso de dados sintéticos e outros utilizam a transferência de aprendizado para mitigar a dificuldade da rede em aprender com a pouca quantidade de dados geralmente disponibilizada.

Portanto, é proposta a detecção e delimitação de gás natural usando redes neurais convolucionais em imagens sísmicas 2D. Serão extraídos *patches* das imagens com a finalidade de aumentar o número de amostras. E como diferencial, podemos citar a etapa de detecção de gás. Essa etapa recorre a uma rede de classificação de imagens cujo objetivo é diminuir, de forma automática, o campo de busca dessas acumulações.

### 3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os conceitos necessários para compreender e elaborar os temas utilizados no desenvolvimento do método proposto. Os temas a seguir são: prospecção de hidrocarbonetos, aprendizado de máquina e as métricas utilizadas para avaliar o método proposto.

#### 3.1 Prospecção de Hidrocarbonetos

Para prospecção de hidrocarbonetos, é necessário entender a estrutura do subsolo, ou seja, obter uma visão precisa das camadas geológicas subterrâneas ou marinhas onde os recursos de petróleo e gás estão enterrados. Isso pode ser feito através da aquisição abundante de dados sobre o subsolo (AL-SHUHAIL; AL-DOSSARY; MOUSA, 2017). Dados sísmicos são informações coletadas por observações, medições ou estimativas sobre o comportamento de ondas sísmicas geradas por fontes sísmicas e sua propagação através da terra (ZHOU, 2014). E esse processo de adquirir e processar dados sísmicos permite obter informações sobre o interior da Terra (ZHOU, 2014).

Há diferentes maneiras de obter informações sobre o subsolo, como os métodos diretos e indiretos. A perfuração de poços é um exemplo de método direto, sendo a opção geralmente mais cara. Outra opção é o uso de métodos indiretos, como a sísmica de reflexão ou refração. Neste método, ondas sísmicas são transmitidas e recebidas para obtenção de imagens subterrâneas (ECCO, 2011). Esses métodos permitem a criação de seções transversais que podem ser interpretadas geologicamente por especialistas. (BACON, 2005). Essas seções podem revelar detalhes das estruturas geológicas de dezenas de metros de profundidade até o nível da litosfera (KEAREY; BROOKS; HILL, 2002).


Os levantamentos sísmicos não eliminam a necessidade de perfurar poços. No entanto, eles visam agilizar os programas de prospecção, minimizar perfurações desnecessárias e expandir a cobertura da análise do solo (KEAREY; BROOKS; HILL, 2002). E entre os métodos, a reflexão sísmica é a técnica geofísica amplamente utilizada (KEAREY; BROOKS; HILL, 2002).

De forma resumida, a investigação de dados sísmicos para prospecção de hidrocarbonetos envolve três etapas principais: A primeira etapa é realizar a coleta de dados, também chamada de aquisição. Nessa etapa, os dados são coletados por método de

reflexão sísmica. A segunda etapa é o processamento dos dados adquiridos, onde análise e tratamento dos dados. E, a terceira etapa é realizar a interpretação dos dados processados. Nessa etapa é possível entender a estrutura geológica do local e identificar potenciais reservas de petróleo e gás.

Os dados sísmicos são coletados usando o método de reflexão sísmica, sendo amplamente utilizado na exploração de hidrocarbonetos. Nesse método, uma fonte como um explosivo cria ondas sísmicas na superfície, viaja pelo solo, refletem nas formações rochosas e retorna à superfície. O sinal refletido é captado e registrado pelo receptor (BACON, 2005). A Figura 1 ilustra o processo.

Figura 1 – Aquisição de dados sísmicos.



Fonte: Adaptado de (BACON, 2005)

Um receptor é um dispositivo semelhante a um microfone, mas sensível a frequências mais baixas de até 5 Hz. O tempo de trânsito da onda da fonte ao receptor é medido, permitindo determinar a profundidade da camada reflexiva. Repetindo as medições em vários locais, você pode criar um mapa da superfície reflexiva do subsolo e entender a estrutura geológica do local. Este princípio é semelhante ao método que as sondas de eco em navios usam para medir a distância do fundo do mar (BACON, 2005).

Após obter os dados sísmicos, o próximo passo é processar essas informações. O processamento de dados sísmicos envolve o uso de técnicas matemáticas e processamento de sinais, e pode ter um componente subjetivo, pois os geofísicos devem considerar sua experiência e conhecimento para interpretação (AL-SHUHAIL; AL-DOSSARY; MOUSA, 2017).



A interpretação de dados sísmicos é a última etapa e visa extrair todas as informações geológicas disponíveis dos dados processados. Isso inclui a análise da estrutura, estratigrafia e propriedades das rochas. A interpretação envolve o uso de algoritmos avançados de processamento de imagem, necessários devido aos avanços tecnológicos na área de computação e processamento de imagem (AL-SHUHAIL; AL-DOSSARY; MOUSA, 2017).

### 3.2 Aprendizado de Máquina

De forma geral, a aprendizagem é um processo ativo que tem como base informações já conhecidas. Além disso, requer a capacidade de pensar logicamente. O Aprendizado de Máquina é um ramo da ciência da computação que permite que máquinas possam aprender ativamente por dados e entendam o conhecimento subjacente que dados possuem (SHANTHAMALLU; SPANIAS, 2021).

Também podemos definir o Aprendizado de Máquina de maneira mais formal: um programa aprende com a experiência se ele pode melhorar seu desempenho em uma determinada tarefa (T) à medida que adquire mais experiência (E). Se a medida de desempenho (P) melhora com a experiência em relação à tarefa (T), isso significa que o programa está aprendendo e se tornando mais eficiente na tarefa (MITCHELL, 1997).

Um computador que aprende por experiência não depende de um conjunto predefinido de regras para executar suas tarefas. Em vez disso, eles são treinados para reconhecer padrões e fazer previsões com base em dados abundantes de maneira precisa (SHANTHAMALLU; SPANIAS, 2021).

Existem muitas abordagens diferentes para aprendizado de máquina, e como um algoritmo aprende depende do tipo de abordagem que você usa. De acordo com Boobier (2018), existem três tipos de abordagens de aprendizado de máquina: aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço. Cada uma dessas abordagens usa técnicas e algoritmos específicos para permitir que os computadores aprendam com a experiência de maneiras diferentes.

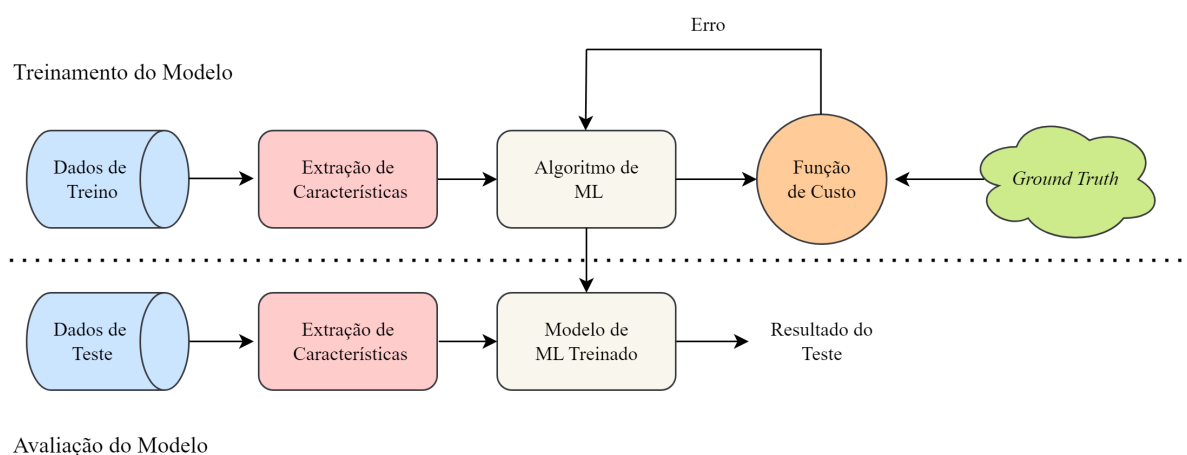
Boobier (2018) define a aprendizagem supervisionada como algoritmos calculam regras através dados rotulados pelo especialista. Já a aprendizagem não supervisionada, o algoritmo é encarregado de encontrar padrões em dados não rotulados. E, na aprendizagem por reforço, o algoritmo aprende em um ambiente dinâmico, como ao jogar um jogo,

modificado dependendo do nível de sucesso.

Neste trabalho, usaremos o tipo de abordagem supervisionada. Os dados possuem *ground truth* como rótulos criados por geofísicos, onde cada seção sísmica possui seu rótulo que indica se há a presença de hidrocarbonetos bem como sua localização.

A Figura 2 apresenta o diagrama dos passos que costumam ser usados em modelos de aprendizado de máquina supervisionados. Durante o processo de treinamento, o modelo de ML faz previsões apropriadas sobre os dados de entrada e melhora suas estimativas de previsão utilizando o *ground truth* e usa iterações para refinar o modelo até que ele atinja o nível de precisão desejado (SHANTHAMALLU; SPANIAS, 2021).

Figura 2 – Modelos supervisionados.



Fonte: Adaptado de (SHANTHAMALLU; SPANIAS, 2021)

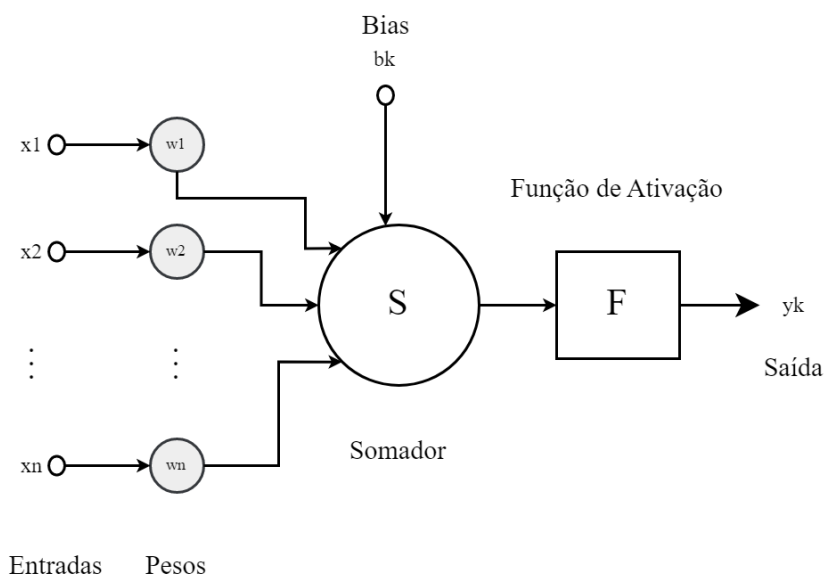
Em seguida, vamos explorar uma das principais técnicas de Aprendizado de Máquina e fundamental para o método utilizado neste trabalho: as redes neurais artificiais.

### 3.2.1 Redes Neurais Artificiais

As redes neurais artificiais são modelos computacionais que se baseiam no funcionamento do cérebro humano, sendo treinados para realizar tarefas específicas e aprendem a resolver diversos tipos de problemas. Elas são criadas simulando uma rede de neurônios em um computador e utilizando algoritmos que imitam os processos de comunicação entre os neurônios reais (KROGH, 2008). Um neurônio é uma unidade de processamento de informação fundamental para a operação de uma rede neural. Existem três elementos básicos de um neurônio (HAYKIN, 2001): um conjunto de sinapses, um somador e uma função de ativação.

A Figura 3 apresenta um exemplo de modelo de um neurônio que possui: 1) Um conjunto de sinapses, onde cada uma é caracterizada por um peso ou força própria; 2) Um somador, para somar os sinais de entrada ponderados pelas respectivas sinapses do neurônio; as operações descritas aqui constituem um combinador linear; 3) Uma função de ativação, para restringir a amplitude da saída de um neurônio (HAYKIN, 2001).

Figura 3 – Neurônio artificial.



Fonte: Adaptado de (HAYKIN, 2001)

### 3.2.2 *Multilayer Perceptron*

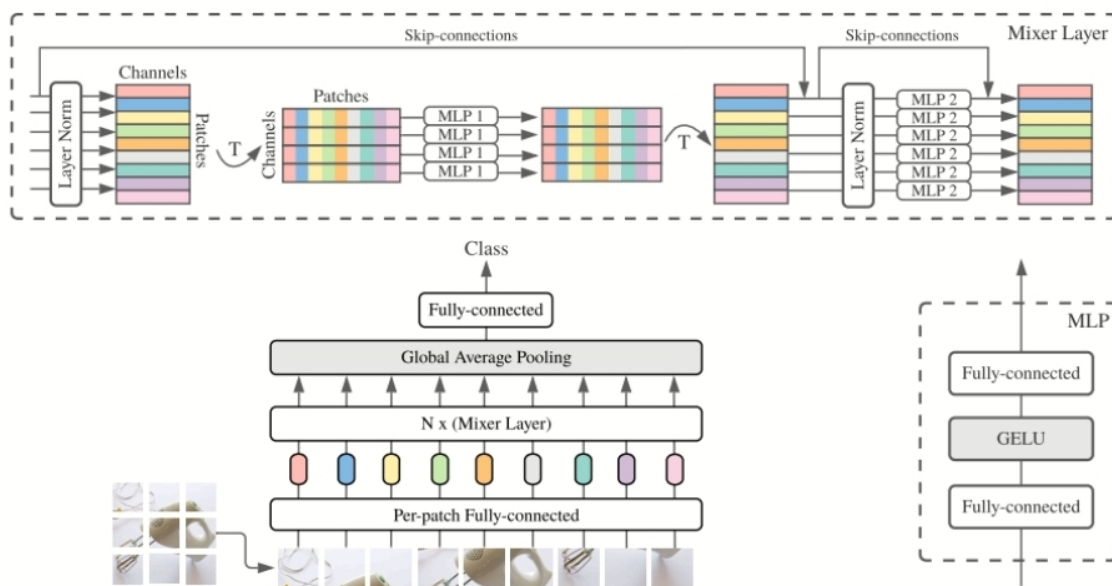
O modelo *Multilayer Perceptron* (MLP) é um tipo de rede neural formada por camadas sucessivas. Cada camada consiste em um número finito de unidades. Essas unidades são comumente chamadas de neurônios. Todas as unidades em cada camada estão conectadas a todas as unidades nas camadas subsequentes (portanto, anteriores) (PINKUS, 1999).

Em uma MLP há pelo menos três camadas. A primeira é camada de entrada, é a camada que recebe os dados. A segunda é a camada intermediária ou oculta. E, por fim, a camada de saída. A Figura 4 apresenta um exemplo de MLP com três camadas.

O treinamento de uma rede *perceptron* multicamadas é um processo onde os valores dos pesos individuais são determinados. O objetivo do treinamento é encontrar a combinação de pesos que minimize o erro (GARDNER; DORLING, 1998).



Figura 5 – Arquitetura MLP-Mixer.



Fonte: (TOLSTIKHIN et al., 2021)

- 2) Os MLPs de mixagem de canais permitem a comunicação entre diferentes canais, eles operam em cada token independentemente e recebem linhas individuais da tabela como entradas
- 3) Os MLPs de mistura de *tokens* permitem a comunicação entre diferentes localizações espaciais (*tokens*); eles operam em cada canal independentemente e recebem colunas individuais da tabela como entradas
- 4) E por fim, esses dois tipos de camadas são intercalados para permitir a interação de ambas as dimensões de entrada

### 3.2.3 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (do inglês *Convolutional Neural Network*, CNN) são semelhantes em arquitetura às redes neurais tradicionais, pois também consistem em neurônios que se auto-otimizam por meio do aprendizado (O'SHEA; NASH, 2015). A grande diferença desse tipo de rede é que ela possui em sua arquitetura camadas convolucionais que processam a entrada considerando o campo receptivo local (PONTI; COSTA, 2018).

Além disso, as CNNs são aplicadas principalmente no campo de reconhecimento de padrões de imagem. Pois, isso permite que recursos específicos da imagem sejam

codificados na arquitetura, tornando a rede mais adequada para tarefas centradas na imagem e reduzindo ainda mais os parâmetros necessários para configurar o modelo. Um comparativo interessante, é que as RNA tradicionais, por não possuírem o recurso da camada de convolução, lutam com a complexidade computacional necessária para computar imagens (O'SHEA; NASH, 2015).

Existem diversas arquiteturas de CNN, porém, elas podem ser resumidas em três tipos de camadas: 1) Camadas convolucionais; 2) Camadas de subamostragem; e, 3) Camadas totalmente conectadas (O'SHEA; NASH, 2015).

- 1) Uma camada de convolução consiste em vários *kernels* de convolução usados para calcular vários recursos de mapa. Especificamente, cada neurônio no mapa de recursos está conectado às regiões dos neurônios vizinhos na camada anterior (GU et al., 2018).
- 2) As camadas de subamostragem são usadas para reduzir a dimensionalidade espacial do mapa de recursos (sem perda de informação) e reduzir o número de parâmetros na rede, reduzindo assim a complexidade computacional geral. Isso controla problemas de sobreajuste (ALOYSIUS; GEETHA, 2017)
- 3) Os neurônios desta camada estão totalmente conectados a todos os neurônios da camada anterior, assim como em uma rede neural normal (ALOYSIUS; GEETHA, 2017).

### 3.2.3.1 U-Net

Os conceitos apresentados a seguir são definidos pelos autores do artigo Ronneberger, Fischer e Brox (2015).

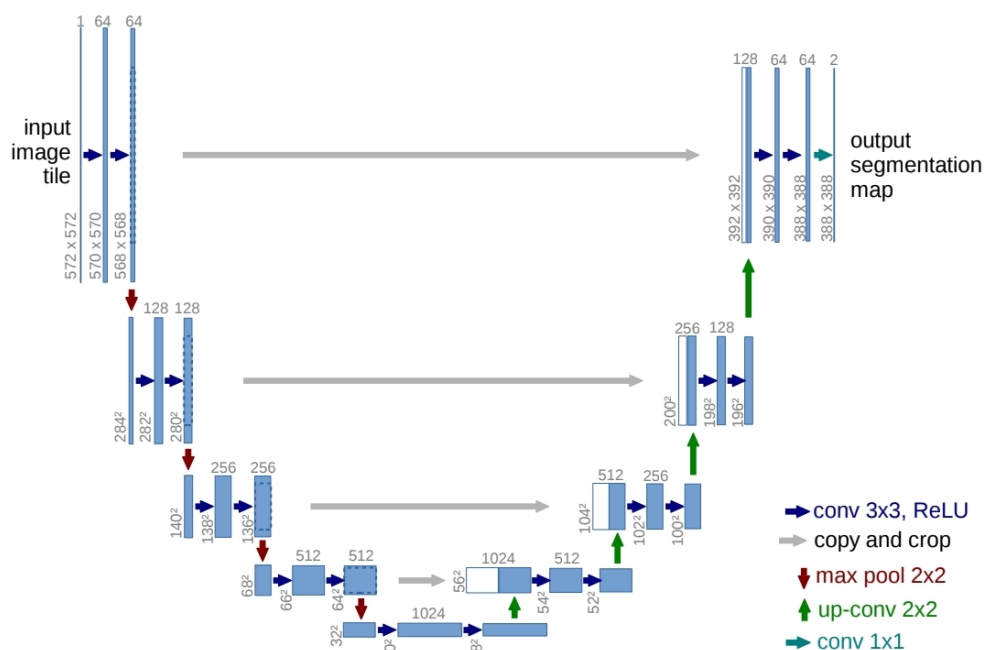
U-Net é uma rede neural convolucional proposta para segmentação semântica de imagens biomédicas. Os autores propuseram uma arquitetura totalmente convolucional com uma estratégia de aumento de dados para superar os problemas que as redes profundas podem encontrar na pequena quantidade de exemplos anotados disponíveis em problemas reais.

Ela consiste em um caminho de contratação (lado esquerdo) e um caminho expansivo (lado direito):

- **O caminho de contração** consiste em aplicações repetidas de duas convoluções 3x3 não preenchidas e, portanto, segue a arquitetura típica de redes convolucionais. Cada uma é seguida por uma operação de *maxpooling* 2x2 com unidade linear retificada (do inglês, *Rectified Linear Unit*, ReLU). A ReLU é comumente utilizada em redes neurais profundas (AGARAP, 2018). Além disso, a rede possui passo 2 nas operações de *downsampling*. A cada passo de redução, o número de canais de recursos dobra.
- **O caminho expansivo** consiste em um *upsampling* do mapa de recursos seguido por uma convolução 2x2 que divide o número de canais de recursos, uma concatenação com o mapa de recursos correspondentemente recortado do caminho de contração e duas convoluções 3x3, cada uma seguida por uma ReLU. O corte é necessário, pois os píxeis são perdidos em cada borda da dobra. A camada final usa convolução 1x1 para mapear cada vetor de características de 64 componentes para o número desejado de classes. No total, a rede possui 23 camadas convolucionais.

A Figura 6 apresenta a arquitetura da U-Net. Do lado esquerdo, podemos observar o caminho de contração com convoluções 3x3. E, do lado direito, podemos observar o caminho de expansão com convoluções 2x2.

Figura 6 – Arquitetura U-Net.



Fonte: Adaptado de (RONNEBERGER; FISCHER; BROX, 2015)

### 3.3 Métricas de Avaliação

As métricas de avaliação visam medir o desempenho dos valores preditos, conforme o modelo proposto, em relação aos valores reais, rotulados pelo especialista. Para avaliar o modelo proposto foram utilizados métricas comumente encontradas em problemas de aprendizado de máquina, como: acurácia (AC), precisão (PRE), sensibilidade (SEN), F1 score (F1), especificidade (ESP), Dice e Área sob a curva ROC (do inglês *Area under the ROC Curve*, AUC). Primeiro, é descrito a matriz de confusão. Pois, a partir de seus índices, outras métricas podem ser derivadas.

A matriz de confusão é uma forma de visualização de resultados comumente utilizada em problemas de classificação binária. Com ela podemos verificar de que forma estão distribuídos os erros e acertos do modelo em relação às classes. A Tabela 1 apresenta uma matriz de confusão e seus índices.

Tabela 1 – Matriz de confusão.

		Real	
		Positivo	Negativo
Predito	Positivo	Verdadeiro Positivo	Falso Positivo
	Negativo	Falso Negativo	Verdadeiro Negativo

Ao fim da predição, cada amostra é classificada entre um dos 4 índices mencionados na tabela. São eles:

- Verdadeiro Positivo (VP): O predito é positivo e o real também.
- Falso Positivo (FP): O predito é positivo, mas o real é negativo.
- Falso Negativo (FN): O predito é negativo, mas o real é positivo.
- Verdadeiro Negativo (VN): O predito é negativo e o real também.

A acurácia é definida como a razão entre o número de casos classificados de forma correta (VP e VN) na amostra do estudo e o número total de casos (VP + FP + FN + VN) na amostra do estudo, como mostra a Equação 3.1.

$$AC = \frac{VP + VN}{VP + FP + FN + VN} \quad (3.1)$$



A precisão é definida pela razão entre o número de casos positivos que foram corretamente classificados como positivos (VP) sobre o número total de casos positivos (VP e FP), como mostra a Equação 3.2.

$$PRE = \frac{VP}{VP + FP} \quad (3.2)$$

A sensibilidade é definida pela razão entre os positivos classificados como positivo (VP), sobre os casos positivos (VP) e os casos que deveriam ser classificados como positivos (FN), como mostra a Equação 3.3.

$$SEN = \frac{VP}{VP + FN} \quad (3.3)$$

A *F1 score* é uma métrica que visa equilibrar a precisão e a sensibilidade, como mostrado na Equação 3.4.

$$F1 = 2 * \frac{Precisão * Sensibilidade}{Precisão + Sensibilidade} \quad (3.4)$$

A especificidade é uma métrica semelhante à sensibilidade, porém ela mede a capacidade do modelo em detectar os resultados negativos, como mostrado na Equação 3.5.

$$ESP = \frac{VN}{VN + FP} \quad (3.5)$$

O Dice é um coeficiente comumente usado para avaliar técnicas de segmentação. Ele verifica a semelhança de nível de píxel entre a segmentação gerada pelo modelo e *ground truth*, como mostrado na Equação 3.6.


$$Dice = \frac{2VP}{2VP + FP + FN} \quad (3.6)$$

A AUC é derivada das curvas ROC (em inglês, *Receiver Operating Characteristic*). As curvas ROC mostram como a sensibilidade varia com a especificidade para diferentes limiares e geralmente consideram falsos positivos e falsos negativos igualmente importantes. O poder preditivo de uma variável é resumido pela área sob a curva, obtida pela integração das áreas sob os segmentos de reta. A AUC de um preditor binário é simplesmente sensibilidade vezes especificidade (MUSCHELLI, 2020).

## 4 MÉTODO PROPOSTO

O capítulo descreve as etapas necessárias para elaboração do método proposto de detecção e delimitação de gás natural em imagens sísmicas 2D. O método proposto consiste em três grandes etapas que constituem a sequência de execução necessária para o seu desenvolvimento: pré-processamento, detecção da região de gás e delimitação da região de gás, como apresentado na Figura 7.

Figura 7 – Etapas do método proposto.



Fonte: Acervo da autora.

O fluxo do método proposto inicia com o pré-processamento. Primeiro, os dados são pré-processados, nessa etapa é feita a extração de *patches*. Em seguida, os *patches* extraídos são apresentados ao modelo de detecção para classificação em *patches* que possuem gás e *patches* que não possuem gás. Para o modelo de detecção é usado um método de classificação de imagens chamado MLP-Mixer. Nesta etapa, não é feita a delimitação do gás, mas sim a detecção da região em que o gás pode estar presente. Em seguida, os *patches* também são usados para treinamento do modelo de delimitação. Na etapa de delimitação, o modelo é treinado para segmentar a região do gás natural, usando o modelo de segmentação semântica U-Net. Nas próximas seções iremos descrever com detalhes cada etapa.

### 4.1 Pré-processamento


As seções sísmicas podem conter altos valores de amplitude negativa e positiva. Como exemplo, há intervalos que variam de  $[-24514, 29921]$ . Dessa forma, a fim de normalizar os dados, as seções foram convertidas para escala de cinza usando a biblioteca *matplotlib* em *python*. A função de conversão primeiro normaliza os dados entre 0 e 1 e depois mapeia para valores de 0 a 255.

Além dos valores de amplitude, há dois pontos importantes nos dados sísmicos. Eles são poucos e as seções *inline* e *crossline* podem possuir tamanhos diferentes. Dessa forma, precisamos aumentar os dados e padronizar o tamanho das amostras de entrada para os modelos de detecção e delimitação de gás. E para isso, fez-se o uso da extração de *patches*.

Os *patches* extraídos foram de tamanho 128x128. Essa escolha ocorreu de maneira experimental. Pois, tamanhos maiores de janela diminuem a quantidade de amostras de gás que serão analisadas pelo modelo, aumentando o desbalanceamento da base. Em contrapartida, *patches* de tamanhos menores reduzem muito as informações vizinhas analisadas pelos modelos. Além disso, é importante que o tamanho do *patch* seja bom para os modelos de detecção e delimitação.

A princípio, as janelas extraídas de *patches* contém sobreposição com passo 10. A sobreposição é a configuração que diz o passo, ao nível de píxel, do próximo *patches* a ser extraído. A Figura 8 ilustra esse processo. Na imagem, a extração ocorre com sobreposição.

Figura 8 – Exemplo de extração de *patch* 2D com sobreposição.



Fonte: Acervo da autora.

Esse recurso permite aumentar ou diminuir a quantidade de amostras geradas a partir de cada imagem. Para treinamento dos modelos, as amostras que possuíam intersecção com gás maior que 0, foram rotuladas como amostras de gás.

## 4.2 Detecção da Região de Gás

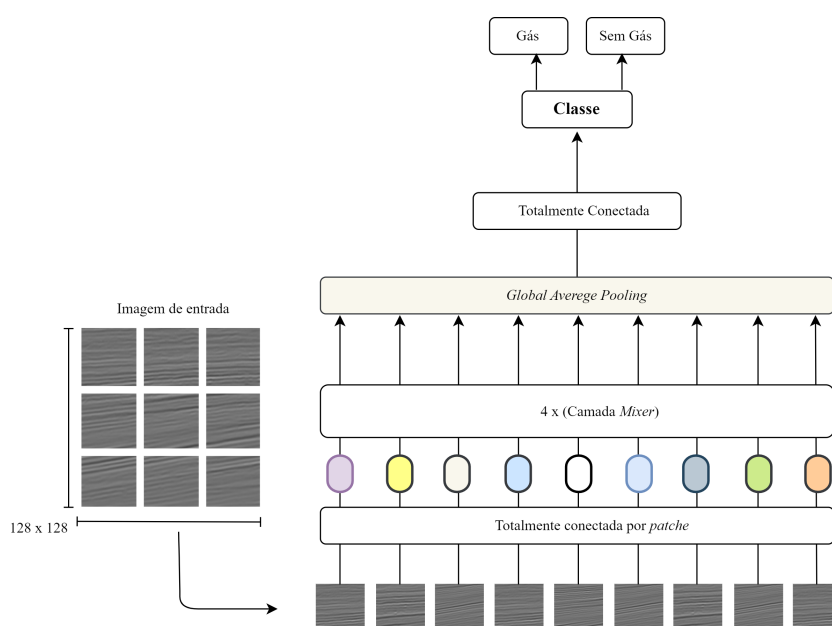
A etapa de detecção destina-se a restringir, automaticamente, a área onde o gás pode ser encontrado. Depois que os dados foram pré-processados e os *patches* rotulados para classificação, as amostras são apresentadas ao modelo de detecção da região de gás natural que usa a MLP-Mixer como proposta.

A MLP-Mixer foi escolhida para essa etapa por ter uma arquitetura simples e de rápido treinamento, pois não utiliza convoluções. Além disso, segundo os autores

Tolstikhin et al. (2021) ela apresentou resultados competitivos em relação a arquiteturas mais recentes, como a *Vision Transformers* (DOSOVITSKIY et al., 2020), HaloNets (VASWANI et al., 2021) e *Big Transfer* (KOLESNIKOV et al., 2020), por exemplo.

A MLP-Mixer, descrita na Seção 3.2.2.1, é uma rede de classificação com arquitetura baseada somente em *perceptrons* multicamadas. É uma alternativa competitiva que não usa convoluções ou auto atenção. E sua arquitetura é baseada inteiramente em *perceptrons* multicamadas que são repetidamente aplicados em locais espaciais ou canais de recursos (TOLSTIKHIN et al., 2021). A Figura 9 apresenta as etapas.

Figura 9 – Arquitetura da MLP-Mixer proposta.



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

Conforme a arquitetura inicial proposta pelos autores, podemos descrever a solução proposta com a seguinte sequência: entrada, blocos de camada mixer e classificação.

A entrada consiste na extração de mini *patches*. Um ponto importante, é que a dimensão da imagem fornecida ao modelo deve ser divisível pelo número de *patches* que serão extraídos. A dimensão do nosso dado de entrada é  $128 \times 128$  e o tamanho do *patch* da MLP-Mixer é 8, também escolhido de forma experimental. Além disso, os *patches* mantêm a sua dimensionalidade.

Na camada mixer, há duas camadas MLP, onde cada uma consiste em duas camadas totalmente conectadas e uma não linearidade GELU (do inglês, *Gaussian Error Linear Unit*). A MLPs de mistura de canais e MLPs de mistura de tokens. As de mixagem


de canal permitem a comunicação entre canais diferentes. A mistura de *tokens* permite a comunicação entre diferentes localizações espaciais.

E por fim, após a camada mixer, a classificação é composta por *Global average pooling*, camada totalmente conectada e *softmax* para classificação das amostras em: 0 (sem gás) e 1 (com gás).

### 4.3 Delimitação da Região de Gás

A etapa de delimitação é a mais difícil, ocorre imediatamente após a etapa de detecção e destina-se à segmentação semântica do gás natural. O modelo utilizado é o U-Net descrita na Seção 3.2.3.1. U-Net foi projetada especialmente para a segmentação de imagens médicas, mas por mostrar bons resultados em outros campos, foi escolhida para delimitar a extensão de gás. Além disso, se baseia no forte uso de aumento de dados (RONNEBERGER; FISCHER; BROX, 2015). A Figura 10 apresenta a arquitetura.

Figura 10 – Arquitetura da U-Net proposta.



Fonte: Adaptado de (RONNEBERGER; FISCHER; BROX, 2015)

Em sísmica, muitos trabalhos encontrados com abordagem 2D utilizam alguma rede de convolução para detectar objetos sísmicos, como em: Cunha et al. (2020), Zini, Rizk e Awad (2019) e Souza et al. (2019). E em Souza et al. (2020) também é utilizada uma arquitetura U-Net. A vantagem de utilizar a U-Net na etapa de delimitação é que sua arquitetura é amplamente utilizada em diversos campos para segmentação semântica e pode ser treinada de ponta a ponta a partir de poucas imagens.

No método proposto, a U-Net segue a arquitetura típica proposta pelos autores, exceto que o número de filtros é menor no início e segue durante todo o modelo. No caminho de contração, há convoluções 3x3 com a ReLU, operações de subamostragem (*pooling*). No caminho de expansão, há convolução ascendente 2x2, concatenação do mapa de recursos. E por fim, convoluções 1x1 mapeadas para o vetor de características para o número de classes.

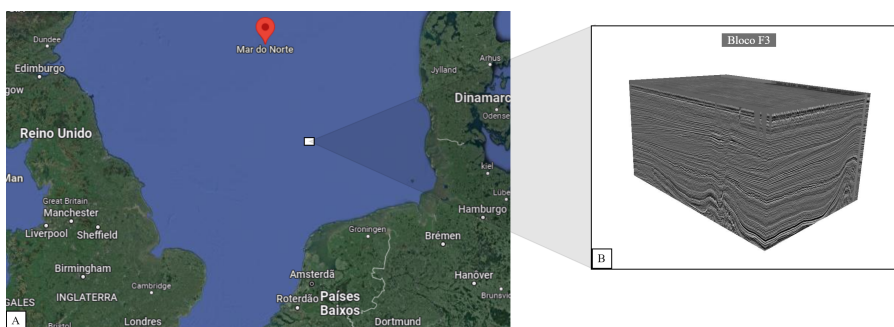
## 5 RESULTADOS E DISCUSSÃO

Este capítulo apresenta e discute os experimentos e resultados alcançados pelo método desenvolvido para detecção e delimitação de gás nas imagens sísmicas. A sequência de análise do capítulo é composta por: 1) Base de Dados *Netherlands F3-Block*, 2) Configuração dos experimentos, 3) Pré-processamento, 4) Detecção da região de gás, 5) Delimitação da região de gás, 5) Discussão e 6) Visualização dos resultados.

### 5.1 Base de Dados *Netherlands F3-Block*

Para análise do método foi utilizado a base pública intitulada de *Netherlands F3-Block*. A base é um bloco no setor holandês localizado no Mar do Norte e coberto por sísmica 3D adquirida para explorar gás natural (NUBIS, 1987). As linhas *crosslines* são linhas perpendiculares (SCHLUMBERGER, 2021), enquanto as linhas *inlines* são na mesma direção em que os dados foram adquiridos. A Figura 11 apresenta de forma ilustrativa o bloco 3D e a localização aproximada dos dados.

Figura 11 – Imagem ilustrativa. A) Localização aproximada da *Netherlands F3-Block* e B) *Netherlands F3-Block* 3D visualizada com *OpendTect*.



Fonte: Adaptada de A) (SCIENCES, 2021), (GOOGLE, 2022) e B) (SCIENCES, 2022)


O Instituto Tecgraf <sup>1</sup> disponibilizou os dados convertidos em 2D e as marcações feitas pelo especialista para as linhas *inlines* e *crosslines* que também foram usados em Santos et al. (2019).

Além disso, o cubo sísmico 3D foi delimitado a fim evitar adicionar dados ruidosos, pois a concentração primária do índice de gás é restrita principalmente perto de estratos sigmoidais (SANTOS et al., 2019).

<sup>1</sup> Instituto de Tecnologia em Computação Gráfica localizado do departamento de informática da Pontifícia Universidade Católica do Rio de Janeiro.  
<https://www.tecgraf.puc-rio.br>

A Figura 12 apresenta em (A) o cubo sísmico em sua forma original visualizada com o software de visualização de dados sísmicos *OpendTect* (SCIENCES, 2022). Em (B) temos a visualização do corte da região de interesse feita por Santos et al. (2019).

Figura 12 – Imagem ilustrativa. A) Cubo sísmico, B) Região de interesse e C) Seções sísmicas 2D e marcações do especialista



Fonte: A) e B) Adaptado de (SANTOS et al., 2019). C) Acervo da autora.

Em (C) temos as seções sísmicas *crossline*, *inline*(1) e marcações feitas pelo especialista (2). Como podemos observar, as linhas *crossline* e *inline* não possuem as mesmas dimensões, devido à característica do cubo sísmico.

No total, a base contém 242 linhas *crossline* e 449 linhas *inline*. As linhas *crossline* foram divididas aleatoriamente em 162 para treino, 40 para validação e 40 para teste. Do mesmo modo, as linhas *inline* foram divididas em 329 para treino, 60 para validação e 60 para teste. As proporções foram mantidas de acordo com Santos et al. (2019) para fins comparativos.

Em seguida, veremos os resultados do pré-processamento, a etapa que padroniza as estradas dos modelos com a extração de *patches*.

## 5.2 Configuração dos Experimentos

Todas as implementações desenvolvidas utilizaram a linguagem de programação *Python* na versão 3.7. Na fase de pré-processamento, foram utilizadas bibliotecas como *Numpy*, *Opencv* e *Matplotlib* para manipular os dados. *Keras* e *Tensorflow* também foram usados para o *MLP-Mixer* e U-Net nas etapas de detecção e delimitação do gás. A máquina usada possui hardware que consiste em uma CPU Intel(R) Core(TM) i7-6700 @ 3,40 GHz, 16 GB de RAM e uma GPU *GeForce GTX 1060* de 6 GB.



### 5.3 Pré-processamento

Para a entrada dos modelos de Detecção da região de gás foram extraídos *patches* 128x128 com sobreposição de 10, pois mostraram melhores resultados na MLP-Mixer em relação aos resultados sem sobreposição. A quantidade de amostras geradas para treino, validação e teste nas linhas *crossline* e *inline* estão apresentadas na Tabela 2.

Tabela 2 – Quantidade de amostras geradas para os modelos de Detecção da região de gás.

	<b>Amostras</b>	<b>Gás</b>	<b>Sem Gás</b>	<b>Total</b>
<i>Crossline</i>				
Treinamento	162	4133	16279	20412
Validação	40	1057	3983	5040
Teste	40	64	336	400
<i>Inline</i>				
Treinamento	329	10112	51082	61194
Validação	60	1809	9351	11160
Teste	60	164	796	960

Para entrada do modelo de Delimitação da região de gás foram extraídos *patches* 128x128 sem sobreposição, pois não mostraram melhoras significativas para U-Net e aumentaram de forma significativa o tempo de treinamento. A quantidade de amostras geradas para treino, validação e teste nas linhas *crossline* e *inline* estão apresentadas na Tabela 3.

Tabela 3 – Quantidade de amostras geradas para os modelos de Delimitação da região de gás.

	<b>Amostras</b>	<b>Gás</b>	<b>Sem Gás</b>	<b>Total</b>
<i>Crossline</i>				
Treinamento	162	263	1357	1620
Validação	40	68	332	400
Teste	40	64	336	400
<i>Inline</i>				
Treinamento	329	876	4388	5264
Validação	60	152	808	960
Teste	60	164	796	960

### 5.4 Detecção da Região de Gás

Na etapa de detecção de região de gás foram gerados dois modelos: um para as linhas *inline* e outro para as linhas *crossline*, conforme a divisão da Tabela 2. A MLP-Mixer é uma arquitetura de classificação supervisionada. Desse modo, para o treinamento

dos modelos (*crossline* e *inline*), os *patches* extraídos foram rotulados em *patches* que continham gás e *patches* que não continham gás.

Para esse trabalho, foi usada uma implementação da MLP-Mixer com *Keras* de (ETHEREDGE, ) e a Tabela 4 apresenta as configurações utilizadas.

Tabela 4 – Configurações usadas na MLP-Mixer.

Parâmetro	Valor
Entrada	128x128x1
<i>Patch size</i>	8
Dimensão MLP <i>token</i>	64
Dimensão MLP canal	128
Dimensão oculta	32

A configuração do treinamento foi definido para 25 épocas, usando *sparse categorical crossentropy* como função de *loss* e *F1 score* como métrica de avaliação. A Tabela 5 apresenta os resultados para a detecção de região de gás nas imagens sísmicas.

Tabela 5 – Resultado da etapa de Detecção da região de gás

	MLP-Mixer					
	AC (%)	SEN(%)	ESP(%)	AUC (%)	PRE(%)	F1 (%)
<i>Crossline</i>	96,15	87,61	98,27	92,94	92,61	90,04
<i>Inline</i>	98,55	95,24	99,2	97,22	95,87	95,56

Para fins comparativos, outros modelos também foram usados para a mesma tarefa de delimitação, foram eles: ResUnet (ZHANG; LIU; WANG, 2018) e a DenseNet (HUANG et al., 2017). A ResUnet e a DenseNet foram usados para extrair características, em seguida foram acrescentadas em ambas as redes um bloco de classificação. As configurações desse bloco de classificação são apresentados na Tabela 6.

Tabela 6 – Bloco de classificação para os modelos de comparação do Detecção da região de gás.

Camada	Configuração	Função de ativação
<i>Dense</i>	512	Relu
<i>Dropout</i>	0,5	-
<i>Dense</i>	256	Relu
<i>Dense</i>	2	<i>Softmax</i>

A Tabela 7 apresenta os resultados para a detecção de região de gás nas imagens sísmicas com os modelos de comparação. Como podemos observar, a MLP-Mixer obteve os melhores resultados de detecção de gás em comparação aos modelos ResUnet e DenseNet.

Com exceção da sensibilidade e AUC na *crossline*, onde a DenseNet obteve um resultado maior.

Tabela 7 – Tabela de comparação de métodos para detecção de gás.

Modelo	Base	AC (%)	SEN (%)	ESP (%)	AUC (%)	PRE (%)	F1 (%)
MLP-Mixer-Proposto	<i>Crossline</i>	96,15	87,61	98,27	92,94	92,61	90,04
MLP-Mixer-Proposto	<i>Inline</i>	98,55	95,24	99,2	97,22	95,87	95,56
ResNet50	<i>Crossline</i>	90,6	59,94	98,19	79,07	89,15	71,68
ResNet50	<i>Inline</i>	98	94,15	98,76	96,45	93,69	93,92
DenseNet121	<i>Crossline</i>	95,54	88,91	97,18	93,04	88,65	88,78
Densenet121	<i>Inline</i>	97,03	88,35	98,74	93,54	93,19	90,71

Além dos resultados, a MLP-Mixer apresentou um desempenho superior significativo em relação ao tempo de treinamento, como apresentado na Tabela 8. Isso ocorre porque a MLP-mixer não tem aumento de profundidade (*channel*) ao longo das camadas, como as redes convolucionais.

Tabela 8 – Comparação dos modelos em relação ao tempo de treinamento.

	Tempo (minutos)	
	<i>Crossline</i>	<i>Inline</i>
MLP-Mixer-Proposto	33	101
ResNet	529	1308
DenseNet	837	2421

A MLP-Mixer mostrou-se um excelente classificador para imagens sísmicas. Apesar de não usar os mecanismos de convolução e atenção, como os principais modelos atualmente, obteve resultados competitivos em um tempo muito menor de processamento.

## 5.5 Delimitação da Região de Gás

Na etapa de delimitação também foram gerados dois modelos, um para as linhas *inline* e outro para as linhas *crossline*. Como a U-Net é uma rede de segmentação semântica, para o treinamento dos modelos também foram extraídos *patches* de 128x128 das respectivas máscaras binárias de gás e não gás.

A configuração do treinamento da U-Net foi definido para 50 épocas com o tamanho do *batch* igual a 4, a função de otimização Adam com a taxa de aprendizado de 0,00001, *decay* de 0,000001 e Dice como função de *loss* e métrica de avaliação da validação.

A Tabela 9 apresenta o resultado do método proposto. Esse resultado é a combinação da etapa de detecção e da etapa de delimitação. O método para linha *inline* apresenta resultados superiores ao método *crossline* na etapa de detecção e delimitação,

uma razão para isso é a quantidade superior de imagens de treinamento para a linha *inline*.

Tabela 9 – Resultado do método proposto.

Base	F1 (%)	AC (%)	PRE (%)	SEN (%)	ESP (%)	AUC (%)	Dice (%)
<i>Inline</i>	84,18	99,6	84,0	86,85	99,79	93,32	84,18
<i>Crossline</i>	80,3	99,55	80,49	82,74	99,73	91,23	80,3

A Tabela 10 apresenta a comparação dos resultados em relação aos trabalhos encontrados fortemente conectados com nosso tema. Em Andrade et al. (2021) não foram apresentados resultados experimentais. Em Diniz et al. (2022) os autores utilizam uma base diferente da base utilizada no modelo proposto. Por isso, este trabalho será comparado diretamente apenas com Santos et al. (2019). Vale ressaltar que Santos et al. (2019) não apresenta métricas de precisão, Dice e F1 *score*.

Tabela 10 – Comparação do método proposto com outro trabalho da literatura

Método	Base	AC (%)	SEN (%)	ESP (%)	AUC (%)
(Santos et al., 2019)	<i>Inline</i>	97,16	97,83	97,15	98,8
(Santos et al., 2019)	<i>Crossline</i>	96,83	94,77	96,87	98,71
Proposto	<i>Inline</i>	99,6	86,85	99,79	93,32
Proposto	<i>Crossline</i>	99,55	82,74	99,73	91,23

Em Santos et al. (2019), observaram-se avanços na acurácia com 99,6% (*inline*) e 99,55% (*crossline*); especificidade 99,79% (*inline*) e 99,74% (*crossline*) mostrando que o modelo proposto conseguiu diminuir o número falsos de positivos. Entretanto, não conseguiu superar a sensibilidade.

## 5.6 Discussão

Nesta seção, são analisados os resultados de pré-processamento, detecção e delimitação da região de gás natural. Além disso, comparamos o método proposto com os trabalhos encontrados e destacamos os pontos importantes da metodologia proposta.

A primeira etapa consiste no pré-processamento dos dados. Essa etapa contou a conversão para escala de cinza das seções e a extração de *patches*. O primeiro caso possibilita a normalização de imagens que podem ter valores muito diferentes. O segundo tem por objetivo a padronização das entradas. Há outras maneiras de padronizar tamanho de imagens, mas a extração de *patches* tem a vantagem de não distorcer os dados, como o

redimensionamento. Além disso, usar essa técnica possibilita o aumento de amostras, sem precisar recorrer ao aumento de dados.

Na etapa de detecção o objetivo é detectar áreas que podem ocorrer acumulação de gás, diminuindo o campo de busca do modelo de delimitação. A MLP-Mixer se mostrou eficiente nessa missão. A precisão mostra que o modelo proposto conseguiu diminuir o número de falsos positivos. Outro ponto importante, é que além da simplicidade do modelo, o método é rápido se comparado a modelos convolucionais profundos.

Na etapa de delimitação, a U-Net se mostrou competitiva e com bom resultados de segmentação, porém a sensibilidade mostra que a delimitação feita pela U-Net sofreu com a quantidade de amostras de gás. Há muito a se avançar para resultados excelentes. O primeiro ponto que gostaríamos de destacar, é que modelos convolucionais profundos sofrem com a pouca quantidade de dados. E nesse caso, usar a sobreposição de dados ou mesmo usar algumas técnicas de aumento de dados proposto pela própria U-Net não apresentaram ganhos significativos.

Podemos observar, que os modelos *inlines* possuem resultados melhores que os modelos *crossline*, uma vez que há quase o dobro de seções sísmicas *inlines*. Pela própria natureza do gás, há poucas ocorrências de amostras de gás. O aumento de dados com sobreposição beneficia muito mais a vasta região das imagens sem gás. A seguir, veremos os principais pontos com relação aos trabalhos relacionados.

Santos et al. (2019) propôs uma abordagem para detectar indicadores de hidrocarbonetos em dados sísmicos usando traço sísmico e uma rede neural LSTM importante. Essa abordagem do Santos et al. (2019) de trabalhar com traço sísmico (1D) tem grande contribuição, pois a maioria dos trabalhos tem uma abordagem 2D, como é citado pelo autor. Os resultados se mostram de forma equilibrados 7. Se examinarmos de maneira geral, o método proposto por Santos et al. (2019) tem uma arquitetura mais simples, visto que possui um único modelo para chegar a detecção do gás. Além disso, a abordagem 1D tem a vantagem de possuir mais amostras de treino, teste e validação para o modelo.


Em contrapartida, o impacto dessa abordagem tem maior evidencia na sensibilidade. Pois, o modelo proposto com abordagem 2D consegue detectar mais amostras corretamente, como podemos ver na acurácia, bem como possuíamos boa precisão. Isso indica que nosso modelo consegue diminuir os falsos positivos, sendo esses os casos mais prejudiciais, financeiramente, na indústria de petróleo e gás.

## 5.7 Visualização dos Resultados

Nesta seção, são apresentados e comentados os resultados gráficos que exemplificam os tópicos anteriormente discutidos. Para todas as imagens abaixo, a marcação do especialista está em vermelho, a detecção da região de gás está com o *bounding box* roxo e delimitação da região de gás está em verde.

O primeiro caso a ser observado é o caso da Figura 13, onde temos o resultado de dois casos na mesma imagem. No primeiro caso (A), o resultado não possui etapa de detecção. Podemos observar na imagem que a U-Net localizou presença de gás de forma errada em lugares distantes das verdadeiras acumulações. Já no segundo caso (B), com a etapa de detecção, o exemplo apresenta um caso em que fica evidente a contribuição da *MLP-Mixer* na diminuição dos falsos positivos, pois impediu que a U-Net errasse a região de gás.

Figura 13 – *Crossline* 909: Resultado geral.



Fonte: Acervo da autora.

A Figura 13 tem outro ponto interessante: delimitação feita pela U-Net sofreu com a quantidade de amostras de gás. As imagens de erro dos modelos, em sua grande maioria, demonstram falha da U-Net em detectar a região de gás.

A seguir, veremos outros exemplos de resultados do método proposto, e veremos essa limitação do modelo. A Figura 14 apresenta um resultado onde a MLP-Mixer conseguiu detectar a região de gás. E a U-Net segmentar com precisão o gás. A Figura 15 também apresenta um bom resultado da MLP-Mixer, mas com a diferença de que existem falsos negativos na predição da U-Net. A Figura 16 apresenta um resultado onde

a MLP-Mixer conseguiu detectar a região de gás. E a U-Net segmentar com precisão o gás.

Figura 14 – *Inline* 597: Caso bom.






Figura 15 – *Inline* 221: Caso ruim.



Fonte: Acervo da autora.

Figura 16 – *Crossline* 511: Caso bom.



Fonte: Acervo da autora.

## 6 CONCLUSÃO

O trabalho proposto teve como objetivo detectar e delimitar gás natural em imagens sísmicas 2D usando técnicas de aprendizado de máquina, especificamente DL. Essa é uma tarefa difícil porque as ocorrências de depósitos de gás natural podem variar de tamanho e localização. Além disso, os dados públicos são escassos e possuem ruídos derivados do processo de aquisição. Essas características tornam a detecção desses objetos por meio do aprendizado profundo uma tarefa desafiadora, visto que essa localização é difícil, inclusive, para especialistas.

Para mitigar esses problemas, o trabalho é dividido em três fases principais: pré-processamento, detecção e delimitação. A extração de *patches* no pré-processamento é um elemento importante para o aumento de dados. A etapa de detecção destina-se a resolver o problema de localização. Para fazer isso, usamos a MLP-Mixer para detectar uma região de interesse que possa conter gás. Esta etapa reduz falsos positivos e facilita a etapa de delimitação do gás. E a etapa de delimitação utiliza a U-Net para segmentação do gás. Essa arquitetura também visa combater o problema de escassez de dados para treinamento. Pois, se baseia no uso de aumento de dados.

Na detecção da região de gás, a MLP-Mixer teve grande importância para o método. Pois, ela conseguiu ter um bom desempenho na classificação automática das regiões que possuem gás. E, conseqüentemente, contribuiu para a delimitação do gás somente nas regiões corretas. Além do bom desempenho, a MLP-Mixer tem a vantagem de ter uma arquitetura simples e de rápido treinamento.

A delimitação da região de gás é a tarefa mais complexa. Apesar do desbalançamento entre a quantidade de amostras de gás e de não gás, a U-Net conseguiu ter um desempenho relevante para o método. Entretanto, algumas operações de aumento de dados propostas pela arquitetura não contribuíram de forma significativa para o problema.

De forma geral, os resultados para detecção e delimitação de regiões de gás validados com a F3 *Dataset* foram promissores, obtendo avanços na acurácia com 99,6% (*inline*) e 99,55% (*crossline*); especificidade 99,79% (*inline*) e 99,74% (*crossline*), comparados ao trabalho de (SANTOS et al., 2019) com abordagem 1D. Dessa forma, considera-se que o objetivo proposto por essa dissertação foi alcançado. Como principais contribuições, ressaltamos: primeiro, o uso da rede de classificação, MLP-Mixer, para detecção automática



de regiões de interesse em imagens sísmicas 2D. E, segundo, um método 2D automático de classificação e segmentação de hidrocarbonetos.

## 6.1 Trabalhos Futuros

O trabalho proposto obteve resultados promissores. Entretanto, há melhorias que podem ser empregadas a fim de tentar obter melhores resultados. Destacamos:

- O uso de algoritmos de otimização, como *particle swarm optimization*, para definição de parâmetros e hiperparâmetros que foram definidos de forma empírica. Como exemplo, o passo da sobreposição na extração de patches; ou, os hiperparâmetros da MLP-Mixer e U-Net.
- O estudo de técnicas aumento de dados com modelos generativos, como as *Generative Adversarial Networks*, conseguindo gerar novas amostras a partir da base de dados.
- Utilizar técnicas de transferência de aprendizado usando outras bases sísmicas, dado que os dados sísmicos são escassos, os modelos de DL são muito sensíveis à quantidade de dados e aumento de dados com transformações geométricas teve pouca contribuição nos testes experimentais.
- Usar outras técnicas de segmentação semântica para delimitação do gás disponível na literatura;
- E, por fim, o uso bases sísmicas de outras regiões a fim de testar a generalização do modelo proposto.

## 6.2 Produções Científicas

A Tabela 11 apresenta a lista de artigos científicos publicados que possuem relação com o método proposto neste trabalho.

Além dos trabalhos relacionados com o método proposto, durante o desenvolvimento dessa pesquisa foram publicados, com coautoria, outros trabalhos envolvendo aprendizado de máquina. Apesar de serem aplicados em outras áreas: como medicina e eletricidade, foram de extrema importância, pois possibilitaram uma maior experiência com técnicas computacionais de aprendizado. No total, foram 2 conferências e 3 periódicos.

Tabela 11 – Artigos publicados que possuem relação com o tema proposto.

Local	Artigo	Status
Conferência	<b>CIPRIANO., C.</b> ; JUNIOR., D.; DINIZ., P.; MARIN., L.; PAIVA., A.; DINIZ., J.; SILVA.,A. Detection and delimitation of natural gas in seismic images using mlp-mixer and u-net. In: INSTICC. Proceedings of the 24th International Conference on EnterpriseInformation Systems - Volume 1: ICEIS,. [S.l.]: SciTePress, 2022. p. 578–585. ISBN978-989-758-569-2. ISSN 2184-4992.	Publicado
Congresso	JUNIOR., D.; DINIZ., P.; SEPULVEDA., L.; <b>CIPRIANO., C.</b> ; GATTASS., M.; SANTOS.,L.; QUEVEDO., R.; MICHELON., D.; SIEDSCHLAG., C.; RIBEIRO., R. Automatic gasdetection using seismic data and transformer neural networks. In: Resumos expandidosSBGf, 17th International Congress of the Brazilian Geophysical Society. [S.l.]: Congress, 2021.	Publicado

## REFERÊNCIAS

- AGARAP, A. F. Deep learning using rectified linear units (relu). **arXiv preprint arXiv:1803.08375**, 2018.
- AL-SHUHAIL, A. A.; AL-DOSSARY, S. A.; MOUSA, W. A. **Seismic data interpretation using digital image processing**. [S.l.]: John Wiley & Sons, 2017.
- ALOYSIUS, N.; GEETHA, M. A review on deep convolutional neural networks. In: IEEE. **2017 international conference on communication and signal processing (ICCSP)**. [S.l.], 2017. p. 0588–0592.
- 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.
- ASHCROFT, W. **A petroleum geologist's guide to seismic reflection**. [S.l.]: John Wiley & Sons, 2011.
- BACON, M. Seismic surveys. In: SELLEY, R. C.; COCKS, L. R. M.; PLIMER, I. R. (Ed.). **Encyclopedia of Geology**. Oxford: Elsevier, 2005. p. 151–158. ISBN 978-0-12-369396-9. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B0123693969001106>>.
- BARATI, R.; ALHUBAIL, M. M. **Unconventional Hydrocarbon Resources: Techniques for Reservoir Engineering Analysis**. [S.l.]: John Wiley & Sons, 2020. v. 1.
- BOOBIER, T. **Advanced analytics and AI: impact, implementation, and the future of work**. [S.l.]: John Wiley & Sons, 2018.
- COX, M. **Static corrections for seismic reflection surveys**. [S.l.]: Society of Exploration Geophysicists, 1999.
- CUNHA, A.; POCHE, A.; LOPES, H.; GATTASS, M. Seismic fault detection in real data using transfer learning from a convolutional neural network pre-trained with synthetic seismic data. **Computers & Geosciences**, Elsevier, v. 135, p. 104344, 2020.
- 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.
- DIXIT, A.; MANDAL, A. Detection of gas chimney and its linkage with deep-seated reservoir in poseidon, nw shelf, australia from 3d seismic data using multi-attribute analysis and artificial neural network approach. **Journal of Natural Gas Science and Engineering**, Elsevier, v. 83, p. 103586, 2020.
- 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.

ECCO, D. **Remoção de ruídos sísmicos utilizando transformada de wavelet 1D e 2D com software em desenvolvimento**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2011.

ETHEREDGE, B. **mlp-mixer-keras**, year = 2021, publisher = GitHub, journal = GitHub repository, howpublished = <<https://github.com/Benjamin-Etheredge/mlp-mixer-keras>>, commit = 3091a82f955db9e5996ad8a357a0c20b663f4f77.

FATH, A. H.; MADANIFAR, F.; ABBASI, M. Implementation of multilayer perceptron (mlp) and radial basis function (rbf) neural networks to predict solution gas-oil ratio of crude oil systems. **Petroleum**, Elsevier, v. 6, n. 1, p. 80–91, 2020.

GARDNER, M. W.; DORLING, S. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. **Atmospheric environment**, Elsevier, v. 32, n. 14-15, p. 2627–2636, 1998.

GOOGLE. **Mar do norte**. 2022. Disponível em: <<https://goo.gl/maps/Asd679oF95wKzZmT9>>.

GU, J.; WANG, Z.; KUEN, J.; MA, L.; SHAHROUDY, A.; SHUAI, B.; LIU, T.; WANG, X.; WANG, G.; CAI, J. et al. Recent advances in convolutional neural networks. **Pattern recognition**, Elsevier, v. 77, p. 354–377, 2018.

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.

HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001.

HU, G.; HU, Z.; LIU, J.; CHENG, F.; PENG, D. Seismic fault interpretation using deep learning-based semantic segmentation method. **IEEE Geoscience and Remote Sensing Letters**, IEEE, 2020.

HUANG, G.; LIU, Z.; MAATEN, L. V. D.; WEINBERGER, K. Q. Densely connected convolutional networks. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2017. p. 4700–4708.

IEA. **World Energy Outlook 2022**. 2022. Disponível em: <<https://www.iea.org/reports/world-energy-outlook-2022>>.

ISLAM, M. R.; HOSSAIN, M. E.; ISLAM, A. O. **Hydrocarbons in basement formations**. [S.l.]: John Wiley & Sons, 2018.

JENKINS, N.; EKANAYAKE, J. **Renewable Energy Engineering**. [S.l.]: Cambridge University Press, 2017.

KEAREY, P.; BROOKS, M.; HILL, I. **An introduction to geophysical exploration**. [S.l.]: John Wiley & Sons, 2002. v. 4.

KOLESNIKOV, A.; BEYER, L.; ZHAI, X.; PUIGSERVER, J.; YUNG, J.; GELLY, S.; HOULSBY, N. Big transfer (bit): General visual representation learning. In: **SPRINGER. European conference on computer vision**. [S.l.], 2020. p. 491–507.

- KROGH, A. What are artificial neural networks? **Nature biotechnology**, Nature Publishing Group, v. 26, n. 2, p. 195–197, 2008.
- MITCHELL, T. **Machine Learning**. [S.l.]: McGraw Hill, 1997.
- MUSCHELLI, J. Roc and auc with a binary predictor: a potentially misleading metric. **Journal of classification**, Springer, v. 37, n. 3, p. 696–708, 2020.
- NUBIS, T. **Project F3 Demo 2020**. 1987. Disponível em: <<https://terranubis.com/datainfo/F3-Demo-2020>>.
- O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. **arXiv preprint arXiv:1511.08458**, 2015.
- 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**, v. 14, n. 6, p. 1571–1578, 2008.
- PINKUS, A. Approximation theory of the mlp model in neural networks. **Acta numerica**, Cambridge University Press, v. 8, p. 143–195, 1999.
- PONTI, M. A.; COSTA, G. B. P. D. Como funciona o deep learning. **arXiv preprint arXiv:1806.07908**, 2018.
- RAMYA, J.; SOMASUNDARESWARI, D.; VIJAYALAKSHMI, P. Gas chimney and hydrocarbon detection using combined bbo and artificial neural network with hybrid seismic attributes. **Soft Computing**, Springer, v. 24, n. 3, p. 2341–2354, 2020.
- RIZK, Y.; PARTAMIAN, H.; AWAD, M. Toward real-time seismic feature analysis for bright spot detection: a distributed approach. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, v. 11, n. 1, p. 322–331, 2017.
- ROJAS, R. The backpropagation algorithm. In: \_\_\_\_\_. **Neural Networks: A Systematic Introduction**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1996. p. 149–182. ISBN 978-3-642-61068-4. Disponível em: <[https://doi.org/10.1007/978-3-642-61068-4\\_7](https://doi.org/10.1007/978-3-642-61068-4_7)>.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. **International Conference on Medical image computing and computer-assisted intervention**. [S.l.], 2015. p. 234–241.
- SANTOS, L. F.; SILVA, R. M. G. E.; GATTASS, M.; SILVA, A. C. Direct hydrocarbon indicators based on long short-term memory neural network. In: **SEG Technical Program Expanded Abstracts 2019**. [S.l.]: Society of Exploration Geophysicists, 2019. p. 2373–2377.
- SCHLUMBERGER. **Oilfield Glossary**. 2021. Disponível em: <<https://glossary.oilfield.slb.com/en/terms/c/crossline>>.
- SCIENCES dGB E. **Introduction To OpendTect OpendTect Pro**. Nijverheidstraat, Holanda, 2021.

\_\_\_\_\_. **OpendTect software**. 2022. Disponível em: <<https://dgbes.com/software>>.

SHANTHAMALLU, U. S.; SPANIAS, A. Machine and deep learning algorithms and applications. **Synthesis Lectures on Signal Processing**, Morgan & Claypool Publishers, v. 12, n. 3, p. 1–123, 2021.

SHI, Y.; WU, X.; FOMEL, S. Automatic salt-body classification using a deep convolutional neural network. In: **SEG Technical Program Expanded Abstracts 2018**. [S.l.]: Society of Exploration Geophysicists, 2018. p. 1971–1975.

SHINDE, P. P.; SHAH, S. A review of machine learning and deep learning applications. In: **2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)**. [S.l.: s.n.], 2018. p. 1–6.

SMIL, V. **Natural gas: fuel for the 21st century**. [S.l.]: John Wiley & Sons, 2015.

SOUZA, J. F. L.; SANTANA, G. L.; BATISTA, L. V.; OLIVEIRA, G. P.; ROEMERS-OLIVEIRA, E.; SANTOS, M. D. Cnn prediction enhancement by post-processing for hydrocarbon detection in seismic images. **IEEE Access**, IEEE, v. 8, p. 120447–120455, 2020.

SOUZA, J. F. L.; SANTOS, M. D.; MAGALHÃES, R. M.; NETO, E.; OLIVEIRA, G. P.; ROQUE, W. L. Automatic classification of hydrocarbon “leads” in seismic images through artificial and convolutional neural networks. **Computers & Geosciences**, Elsevier, v. 132, p. 23–32, 2019.

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

TOLSTIKHIN, I.; HOULSBY, N.; KOLESNIKOV, A.; BEYER, L.; ZHAI, X.; UNTERTHINER, T.; YUNG, J.; STEINER, A.; KEYSERS, D.; USZKOREIT, J. et al. Mlp-mixer: An all-mlp architecture for vision. **arXiv preprint arXiv:2105.01601**, 2021.

VASWANI, A.; RAMACHANDRAN, P.; SRINIVAS, A.; PARMAR, N.; HECHTMAN, B.; SHLENS, J. Scaling local self-attention for parameter efficient visual backbones. In: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2021. p. 12894–12904.

WANG, Z.; DI, H.; SHAFIQ, M. A.; ALAUDAH, Y.; ALREGIB, G. Successful leveraging of image processing and machine learning in seismic structural interpretation: A review. **The Leading Edge**, Society of Exploration Geophysicists, v. 37, n. 6, p. 451–461, 2018.

XIONG, W.; JI, X.; MA, Y.; WANG, Y.; ALBINHASSAN, N. M.; ALI, M. N.; LUO, Y. Seismic fault detection with convolutional neural network. **Geophysics**, Society of Exploration Geophysicists, v. 83, n. 5, p. O97–O103, 2018.

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

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

ZHOU, H.-W. **Practical seismic data analysis**. [S.l.]: Cambridge University Press, 2014.

ZINI, J. E.; RIZK, Y.; AWAD, M. A deep transfer learning framework for seismic data analysis: A case study on bright spot detection. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, 2019.