



Latin American Journal of Energy Research – Lajer (2023) v. 10, n. 2, pp. 13–22
<https://doi.org/10.21712/lajer.2023.v10.n2.p13-22>

Elaboração da interpretação automática de fraturas nos perfis de imagem utilizando a Inteligência Artificial

Development of automatic interpretation of fractures in image profiles using Artificial Intelligence

Victoria Almeida Conrado^{1*}, Mariléa dos Gomes Santos Ribeiro²

¹ Aluna de Graduação em Engenharia de Petróleo, Universidade Federal do Espírito Santo – Ufes, campus São Mateus, ES, Brasil

² Professora da Universidade Federal do Espírito Santo – Ufes, campus São Mateus, ES, Brasil

*Autor para correspondência, E-mail: victoria.conrado@edu.ufes.br

Received: 7 October 2023 | Accepted: 4 December 2023 | Published online: 28 December 2023

Resumo: A Inteligência Artificial (IA) abrange diversos subconjuntos, com destaque para o aprendizado de máquina (*Machine Learning* - ML), que possui grande potencial na indústria de petróleo e gás, especialmente na análise e interpretação de dados. A indústria de petróleo enfrenta desafios tecnológicos significativos, dada a sua complexidade, onde a análise da formação geológica por perfilagem petrofísica de poço desempenha um papel fundamental para a melhoria da avaliação dessas formações. A minimização de danos e redução de custos na etapa de perfuração de poços é uma atividade de grande importância. A identificação de fraturas naturais e induzidas é essencial para compreender os reservatórios, e tanto a IA, como o ML, podem analisar as características qualitativas e quantitativas das formações geológicas. O objetivo deste trabalho consiste em automatizar a interpretação de falhas por perfis de imagem usando da Inteligência Artificial, aprimorando a eficiência, a precisão e a velocidade desses processos. A linguagem de programação Python e a ferramenta Jupyter Notebook foram utilizadas para desenvolver o programa de IA, onde se coletou dados e imagens, que foram processados e analisados usando bibliotecas como OpenCV, Numpy e Sklearn.svm. Os resultados obtidos demonstram a eficácia da IA na identificação de fraturas em diferentes tipos de perfis de imagem, incluindo imagens acústicas e resistivas. A Inteligência Artificial conseguiu identificar com precisão fraturas naturais, fraturas de baixa amplitude, fraturas internas e outros eventos geológicos. No entanto, o sucesso da IA depende da qualidade e quantidade dos dados de treinamento. O desafio originado da complexidade geológica e a resolução das imagens ainda precisam ser superados. A aplicação da IA na interpretação automática de fraturas em imagens na indústria de petróleo oferece melhorias significativas na eficiência e rapidez do processo, contribuindo para a compreensão das características das formações rochosas. O resultado obtido neste trabalho reflete a inovação da técnica e a sua importância para a agilidade dos processos, diminuindo etapas para o intérprete do perfil de imagem. Palavras-chave: Inteligência Artificial, *Machine Learning*, Petróleo e Gás, Fraturas, Interpretação Automática.

Abstract: Artificial Intelligence (AI) covers several subsets, with emphasis on machine learning (ML), which has great potential in the oil and gas industry, especially in data analysis and interpretation. The oil industry faces significant technological challenges, given its complexity, where the analysis of geological formation through petrophysical well logging plays a fundamental role in improving the evaluation of these formations. Minimizing damage and reducing costs in the well drilling stage is an activity of great importance. The identification of natural and induced fractures is essential to understanding reservoirs, and both AI and ML can analyze the qualitative and quantitative characteristics of geological formations. The objective of this work is to automate the interpretation of faults through image profiles using Artificial Intelligence, improving the efficiency, precision and speed of these processes. The Python programming language and the Jupyter Notebook tool were used to develop the AI program, where data and images were collected, which were processed and analyzed using libraries such as OpenCV, Numpy and Sklearn.svm. The results obtained demonstrate the effectiveness of AI in identifying fractures in different types of image

profiles, including acoustic and resistive images. Artificial Intelligence was able to accurately identify natural fractures, low-amplitude fractures, internal fractures and other geological events. However, the success of AI depends on the quality and quantity of training data. The challenge arising from geological complexity and image resolution still needs to be overcome. The application of AI in the automatic interpretation of fractures in images in the petroleum industry offers significant improvements in the efficiency and speed of the process, contributing to the understanding of the characteristics of rock formations. The result obtained in this work reflects the innovation of the technique and its importance for the agility of processes, reducing steps for interpreting the image profile.

Keywords: Artificial Intelligence, Machine Learning, Oil and Gas, Fractures, Automatic Interpretation.

1 Introdução

A Inteligência Artificial (IA), é uma abordagem de processamento de dados que se aprimora por meio da análise de informações, detectando padrões e realizando prognósticos com pouca interferência do ser humano (Cuddy, 2021). A IA é um campo amplo que possui diversos subconjuntos, dentre os existentes, o *machine learning* (ML) ou aprendizado de máquina, que tem grande potencial em aplicações na indústria de óleo e gás, especialmente quando se trata de análise e interpretação de dados. Algoritmos de ML que foram efetivamente aplicados a tarefas no setor petrolífero incluem *Support Vector Machine* (SVM), Redes Neurais Artificiais (RNA), *Deep Learning* (DL) e Algoritmos Genéticos (AG) (Hanga, 2019).

A indústria de petróleo sempre portou grandes fronteiras e, com isso, imensos desafios tecnológicos. Por ser uma indústria extremamente complexa, requer um constante avanço tecnológico das ferramentas utilizadas. Um estágio crucial desse processo é a análise de formação geológica por meio da técnica de perfilagem, buscando sempre melhorar a avaliação das formações rochosas, minimizando danos e reduzindo custos, a fim de posicionar adequadamente o poço e otimizar a produção (Paes, 2013).

Grandes influências no efeito de desenvolvimento dos reservatórios, especialmente os não convencionais, podem ser trazidas pelas fraturas naturais e pelas fraturas artificiais formadas por fraturamento, portanto o trabalho de identificação de fraturas é de grande importância. Quase todos os reservatórios têm fraturas naturais e, na maioria dos reservatórios não convencionais, como gás de folhelho e óleo denso, muitas fraturas artificiais são formadas por fraturamento, tornando as fraturas em todos o reservatório um fator importante que afeta a produtividade (Lechner e Zangl, 2005). O estudo sobre fraturas pode geralmente ser dividido em aspectos qualitativos e quantitativos – primeiro identificar qualitativamente as fraturas e reconhecer os reservatórios e depois calcular quantitativamente a distribuição das fraturas (azimute, comprimento, abertura, porosidade da fratura, etc.). Embora muitas pesquisas tenham sido conduzidas sobre a identificação de fraturas, devido à forte heterogeneidade dos reservatórios e às complicadas características de infiltração causadas pelas fraturas, a identificação precisa das fraturas continua a ser um problema chave que aguarda ser resolvido (Li et al., 2021).

Objetivando a caracterização de fraturas naturais ou induzidas em subsuperfície é importante para o desenvolvimento de reservatórios de petróleo e gás devido ao grande impacto mecânico e hidráulico das fraturas nas rochas do reservatório. Há muito se reconhece que o transporte de fluido através de uma fratura depende da largura da fratura, tensão normal, área de contato e rugosidade das duas superfícies de contato (Zoback, 2007). Assim, a interpretação automática de certas fraturas pelo perfil de imagem passa a ser um novo momento da indústria do petróleo.

A pesquisa sobre fraturas é uma área de grande destaque na indústria do petróleo, pois se concentra principalmente nas características morfológicas, características de propriedades e características de classificação dessas fraturas. Essas informações são, em geral, utilizadas em correlação com os dados de outros perfis, amostra de calha, testemunhos e histórico de produção em estudos de caracterização de reservatórios (Li et al., 2021; Félix, 2013). O processo de identificação é complicado porque o reservatório contém fraturas naturais, fraturas artificiais e fraturas induzidas, e os parâmetros envolvidos dependem principalmente de dados da perfilagem. A aplicação da IA na identificação de fraturas é uma nova tecnologia que vem ganhando forte espaço entre as pesquisas mais recentes. A identificação e interpretação automática das fraturas nos perfis de imagem utilizando Inteligência Artificial (IA) na indústria do petróleo pode ser aplicada em diversas áreas, como a caracterização de reservatórios, análise de amostras de rochas e avaliação de fraturas em formações geológicas. A IA, especificamente o aprendizado de máquina (*machine learning*) pode analisar a geometria, orientação, densidade e complexidade das fraturas identificadas, fornecendo informações detalhadas sobre as características das fraturas nos reservatórios, e por meio das características, a inteligência artificial pode classificar as fraturas em diferentes tipos, como por exemplo, fraturas induzidas e fraturas naturais.

1.1 Objetivos

Elaborar técnica por IA de interpretação automática das fraturas nos perfis petrofísicos de imagem, melhorando a eficiência, a precisão e a velocidade da caracterização das fraturas em formações rochosas da exploração e produção de petróleo e gás.

A caracterização de fraturas naturais em subsuperfície é importante para o desenvolvimento de reservatórios de petróleo e gás devido ao grande impacto mecânico e hidráulico originários das fraturas (naturais e induzidas) nas rochas do reservatório. Há muito se reconhece que o transporte de fluido através de uma fratura depende da largura da fratura, tensão normal, área de contato e rugosidade das duas superfícies de contato. Assim, a interpretação automática das fraturas por perfis de imagem acontece no novo momento da indústria do petróleo de agilizar os processos com o uso da inteligência artificial.

2 Embasamento teórico

Uma das mais recentes conquistas e avanço tecnológico na área da perfilagem petrofísica de poços são os perfis de imagem (Félix et al., 2013). As imagens obtidas desses perfis são de alta resolução. Estas imagens da formação (reservatório) auxiliam na identificação e delimitação de feições estruturais e/ou diagenéticos, tais como a ocorrência de fraturas, direcionamento das tensões, inclinação de camadas, litologias, discordância e porosidade, e ainda, sendo possível notar diferentes tipos de padrões texturais das informações relacionadas a estrutura rochosas (Junior, 2014). A resolução do perfil de imagem dependerá do ferramental e do método utilizado, uma vez que existe diferentes ferramentas no setor petrolífero (Fatah, 2020). Cada ferramenta possui características mecânicas distintas, que lhes conferem a capacidade de adquirir imagens de alta resolução, e neste sentido, quanto maior a resolução, maior a definição das imagens e, consequentemente, o número de estruturas identificadas aumentam (Lagraba et al., 2010).

Os registros de imagens de poços têm o potencial para interpretação direta das características dos reservatórios (Donselaar e Schmidt, 2010; Folkestad et al., 2012; Jáfari et al., 2012; Brekke et al., 2017). O desafio é criar um conjunto de critérios de diagnósticos para classificação de fácies de perfil de imagem, e pelos quais os perfis de imagem podem ser traduzidos para características sedimentares e estruturais, como estruturas sedimentares, sequências de estratificação, sucessões verticais de tamanho de grão, fraturas e orientação de tensão *in situ* (Donselaar e Schmidt, 2005, 2010; Folkestad et al., 2012; Muniz e Bosence, 2015). A fácies de registro da imagem do poço é definida como a aparência visual da imagem que inclui a combinação de sucessões de cores na imagem estática e os padrões de registro de mergulho derivados das ondas senoidais na imagem dinâmica (Donselaar e Schmidt, 2010; Wilson et al., 2013). Os critérios utilizados para interpretar a fácies da imagem incluem os padrões de variação de cores, imagens de texturas e estruturas sedimentares e estruturas estruturais nas imagens (Muniz e Bosence, 2015). As características dos reservatórios sedimentares, como litologia, estruturas sedimentares, microfácies deposicionais, falha, fratura e direção de paleocorrente poderiam, assim, ser interpretadas a partir da análise de fácies da imagem do poço (Xu et al., 2009; Donselaar e Schmidt, 2010; Muniz e Bosence, 2015; Brekke et al., 2017).

O aprendizado de máquina é um subconjunto da inteligência artificial. Nas indústrias de petróleo e gás, vários tipos de dados são coletados na superfície e no subsolo para compreender o potencial econômico e produtivo de hidrocarbonetos em qualquer data de produção de um campo. É necessário traçar e analisar dados com análise técnica e intervenção. Os métodos de aprendizado de máquina fornecem relacionamento entre variáveis de entrada e preveem a saída. No aprendizado de máquina, o comportamento físico do sistema não sofre interferência. Os dados associados às indústrias de petróleo e gás são enormes e o processo é complicado para correlações de dados (Ali, 1994).

3 Metodologia

Este estudo é classificado como uma pesquisa aplicada na indústria do petróleo com o objetivo de elaborar e identificar as fraturas contidas nos perfis de imagem utilizando a Inteligência Artificial para automatizar a interpretação, o que auxilia na redução da variável tempo. A linguagem Python foi adotada como a principal linguagem para inserir a IA e a utilizá-la para identificar as fraturas nos perfis.

Para desenvolver o programa em Python, foi necessário realizar a coleta de dados e imagens, as quais foram armazenadas no computador. O ambiente Jupyter Notebook está organizado em pastas, e as imagens específicas utilizadas neste projeto foram inseridas em uma dessas pastas dentro dessa ferramenta. Os dados obtidos pela perfilagem, os perfis de imagem, devem ter um controle de qualidade com a melhor acurácia

possível e, deve-se verificar a orientação e os determinados tipos de ferramentas que foram aplicadas para obter o registro de imagem.

O desenvolvimento do programa em Python seguiu uma lógica específica, adotada da seguinte maneira: para o processamento de imagens, foi importado a biblioteca OpenCV, usada para analisar as imagens e para a detecção de objetos (fraturas); também foi importada a biblioteca Numpy, essa biblioteca permite processar, analisar, manipular e visualizar grandes quantidades de dados de forma rápida e eficiente. A biblioteca OS também utilizada, forneceu funções para criar e remover um diretório (pasta), buscar seu conteúdo, alterar e identificar o diretório atual. No código desenvolvido, para implementar a inteligência artificial, precisamente, o aprendizado de máquina (*machine learning*), foi necessária a importação de uma biblioteca de chamada específica Sklearn.svm, ela habilita o programa para realizar tarefas de aprendizado de máquina. O Sklearn.svm se concentra em algoritmos de máquinas de vetor de suporte (*Support Vector Machines* ou SVMs).

As máquinas de vetor de suporte são uma classe de algoritmo de aprendizado de máquina usada em tarefas de classificação, regressão e detecção de anomalias. Elas são particularmente eficazes em problemas que envolvem a separação de dados em classes diferentes. Os SVMs encontram uma "fronteira" que melhor separa as classes, permitindo que o programa classifique novos dados com base em sua posição em relação a essa fronteira.

A importação da biblioteca Sklearn.svm disponibiliza os recursos e algoritmos necessários para a aplicação de SVMs no programa. Isso permite que o programa tire proveito do poder do aprendizado de máquina para resolver problemas específicos, como classificar imagens, prever valores futuros com base em dados históricos ou detectar anomalias em conjuntos de dados. As máquinas de vetores de suporte (SVMs) são métodos de aprendizado de máquina supervisionados poderosos, porém flexíveis, usados para classificação, regressão e detecção de valores discrepantes.

Seguidamente das importações das bibliotecas, foi criada uma pasta inserindo as imagens utilizadas ao decorrer do desenvolvimento desse projeto. Como está sendo trabalhado uma sequência de dados, e, para lidar com o carregamento da imagem, o loop for foi introduzido no programa para executar o conjunto dos itens que foram estabelecidos. Dentro do loop for, foi executado: o redimensionamento da imagem, a normalização dos valores de pixels, a extração de características RGB, a criação do conjunto de treinamento, a criação e o treinamento do classificador SVM, a previsão das cores da imagem, o redimensionamento das previsões para a forma original da imagem, o redimensionamento das máscaras para a forma original da imagem, o destaque da cor marrom claro em amarelo, o destaque da cor marrom escuro para azul e por fim, a exibição da imagem resultante.

4 Resultados e discussão

A utilização de Inteligência Artificial, especialmente o Aprendizado de Máquina (ML), para interpretação automática de fraturas em perfis de imagens, representa um avanço tecnológico significativo na indústria, como já comentado no texto acima. A precisão e a rapidez fornecidas pelo modelo de SVM são importantes para uma interpretação mais confiável das características das formações rochosas. Isso pode levar a decisões mais informadas em projetos de exploração na indústria do petróleo, resultando em otimização de recursos e aumento da eficiência operacional. No entanto, é essencial notar que a qualidade dos resultados está diretamente relacionada à qualidade e quantidade dos dados de treinamento. A obtenção de conjuntos de dados representativos e bem rotulados é um desafio crítico para o sucesso dessa abordagem. Além disso, melhorias contínuas no modelo, incorporando outras e novas técnicas de processamento de imagem e explorando outras arquiteturas de IA, podem levar a um desempenho ainda melhor e aprimoramento do sistema de interpretação automática de fraturas, acurácia.

A interpretação dos registros de imagens elétricas auxilia na identificação e na orientação “exata” (existe sempre uma margem de erro que deve ser calculada – não sendo o objetivo neste trabalho) das fraturas naturais, como pode-se observar na Figura 1A, na primeira coluna da esquerda e na Figura 1B. As fraturas naturais são importantes condutos de fluxo de fluidos e são fundamentais para a produção de hidrocarbonetos (Khoshbakht et al., 2009; Zeng, 2010). As fraturas podem aumentar a permeabilidade do reservatório e desempenham um papel importante na acumulação de hidrocarbonetos (Lyu et al., 2017).

Para a interpretação das fraturas, o programa na linguagem Python apenas sinalizou em um contraste em azul as fraturas encontradas no registro de imagem, as figuras foram colocadas juntas com a finalidade de analisar e comparar o resultado obtido no programa em Python. Dessa forma, a inteligência artificial e o *machine learning*, automatiza a análise de fraturas nas figuras originais, processando um grande volume de dados em tempo reduzido melhorando a eficiência e a velocidade dos processos.

Na Figura 1a e 1b, na terceira coluna, observa-se um exemplo de imagem acústica; imagens estas, obtidas pela ferramenta onde podemos observar uma população de fraturas naturais semelhante, na forma senoidal, porém são imagens de pequenas fraturas e não revelam tecido rochoso devido à sua baixa resolução. Os registros da imagem mostram um conjunto de fraturas naturais abertas, fechadas e semi-abertas, como observado na Figura 1a. Na Figura 1b se percebe a ocorrência dos mesmos eventos e de forma inteligente (ensinado), o que define o alcance aos objetivos deste trabalho.

As fraturas abertas são caracterizadas por uma coloração marrom escuro a preto nas imagens acústicas de amplitude e coloração preta nas imagens de tempo de trânsito, formando, assim, sinusóides completas e por vezes sinusóides parciais. Já as fraturas parcialmente abertas são caracterizadas por sinusóides parciais a completas de coloração marrom clara a amarelo escuro nas imagens acústicas e por cinza claro ou sem contraste nas imagens de tempo de trânsito; estas características da Figura 1a podem ser observadas e descritas pela cor azul na Figura 1b.

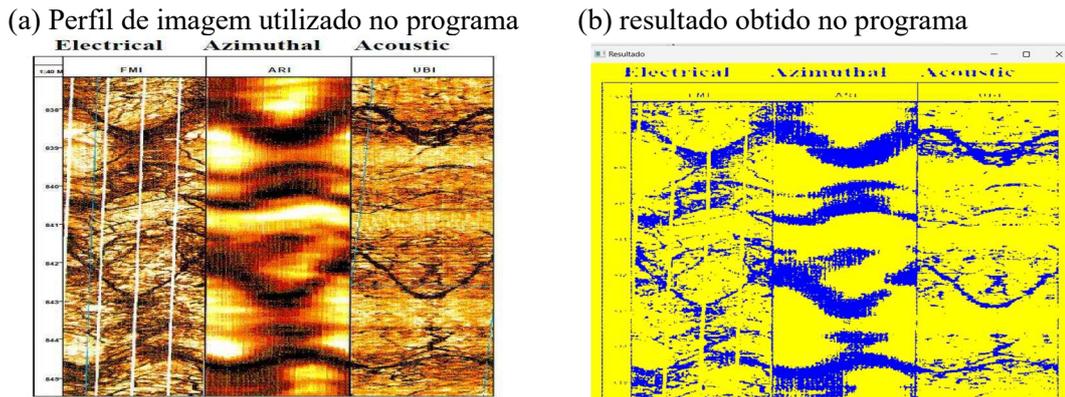


Figura 1. Imagem mostrando diferentes respostas das fraturas a diferentes ferramentas (a) (Schlumberger, 1999). Resultado destacando as fraturas na cor azul (b).

Em alguns casos, acontecem eventos múltiplos nos perfis de imagem, como fraturas pequenas e pouco espaçadas ou leitos finos, como pode observar na Figura 2. Fraturas pequenas e próximas umas das outras podem se sobrepor, dificultando a identificação individual e a avaliação de suas características. Isso pode afetar a precisão na determinação de sua orientação, comprimento e densidade. Além disso, quando se trata de leitos finos, a resolução da imagem pode não ser suficiente para capturar detalhes importantes, levando a uma representação imprecisa ou a uma interpretação ambígua da estrutura geológica. O SVMs (máquina de vetores de suporte) obteve um bom resultado na caracterização desses eventos múltiplos contidos na Figura 2a. Na Figura 2b a inteligência pode identificar os mesmos eventos, obviamente com uma certa margem de erro (o que não é o objetivo deste trabalho), mas erros possivelmente aceitáveis no momento.

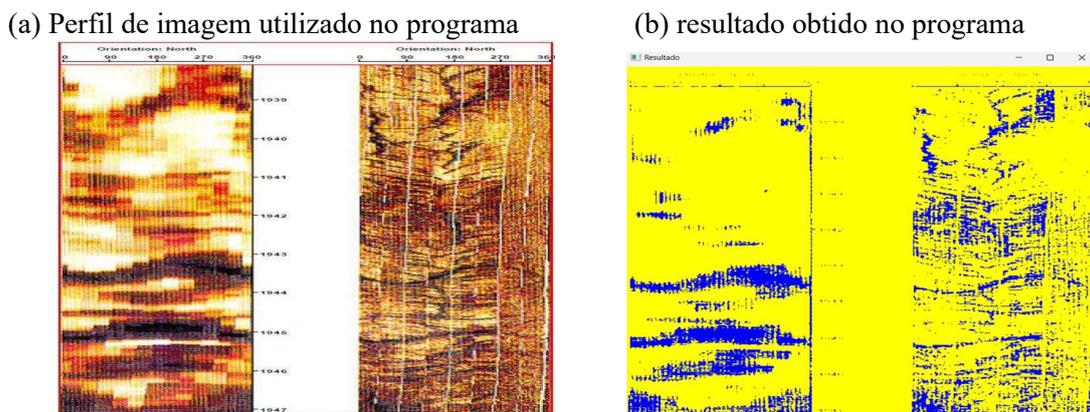


Figura 2. Comparação de imagens ARI com imagens FMI na mesma seção do poço (a), extraído de Schlumberger (1999). Resultado destacando as fraturas pequenas e espaçadas (b).

Na Figura 3, está inserido dois tipos de ferramentas: FMS (*Fullbore Formation MicroImager*) e UBI (*Ultrasonic Borehole Imager*). A ferramenta FMS fornece informações sobre a textura, estruturas, fraturas e heterogeneidade da formação rochosa, enquanto a ferramenta UBI oferece informações sobre a amplitude das reflexões, indicando variações na litologia e identificando interfaces de diferentes camadas. Quanto a aplicabilidade da ferramenta FMS, é utilizada para análise e orientação de fraturas e outras características

próximas à parede do poço, essas características são notáveis na Figura 3a e, também observadas na Figura 3b. A ferramenta UBI identifica presença de falhas e descontinuidades em formações rochosas e mapeia interfaces entre diferentes camadas. No intervalo de profundidade, 1128 a 1131 metros, o programa não conseguiu identificar com maior exatidão as características presentes no perfil de imagem da Figura 3a, porque, possivelmente, pode ser um arrombamento na parede do poço ou outro evento litológico ou operacional. Para identificar nesta região que evento está realmente acontecendo é necessário a contribuição dos outros perfis. As faixas de resistividade na imagem original dificultam a interpretação pelo programa, resultando em áreas sem fraturas.

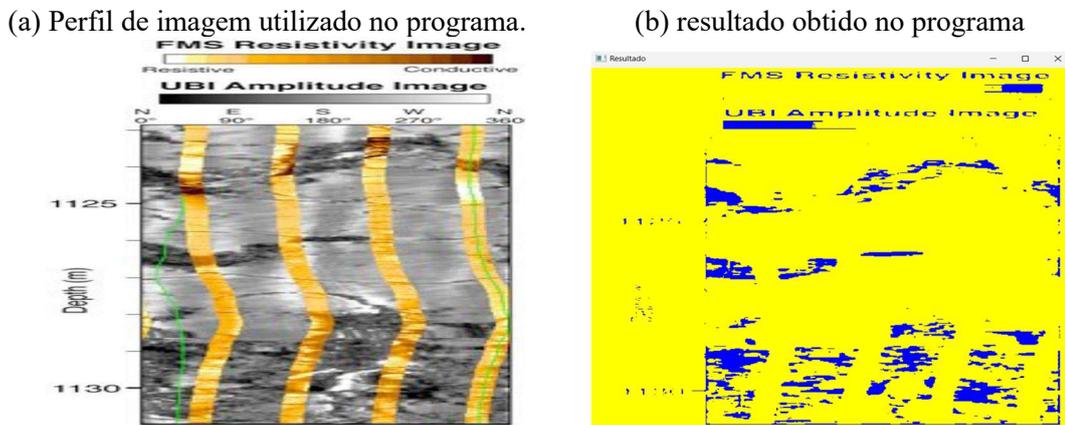


Figura 3. Comparação entre as ferramentas FMS e UBI (a), extraído de Liu (2017). Resultado obtido (b).

A litologia na Figura 4a, consiste em carbonatos fraturados e é possível notar um desmoronamento entre 4079.10 metros e 4079.5 metros relacionado ao fraturamento (Liu, 2017). Observa-se também ondas sinusóides caracterizando as fraturas, essas mesmas fraturas foram identificadas no resultado gerado pelo programa, e a cor azul reproduziu de forma bastante precisa essas características, facilitando assim a sua identificação.

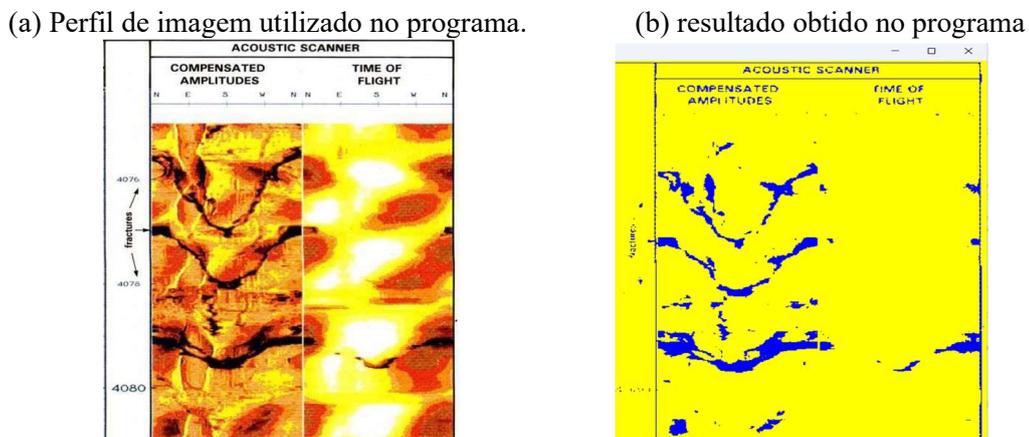


Figura 4. Imagem acústica (imagem modificada pela autora) (a), extraído de Liu (2017). Resultado obtido destacando as fraturas na imagem de amplitude (*Compensated amplitudes*) (b).

Um dos problemas com imagens acústicas em sequências sedimentares, é que os contrastes de impedância acústica entre litologias, leitos ou lâminas são pequenos. No entanto, verifica-se que os principais limites do leito são visualizados, assim como zonas estreitas ou cimentadas, que podem ser identificadas na Figura a e 5b, como esperado no desenvolvimento do programa e ainda pode-se observar que o azul replica muito bem as fraturas contidas na Figura 5a.

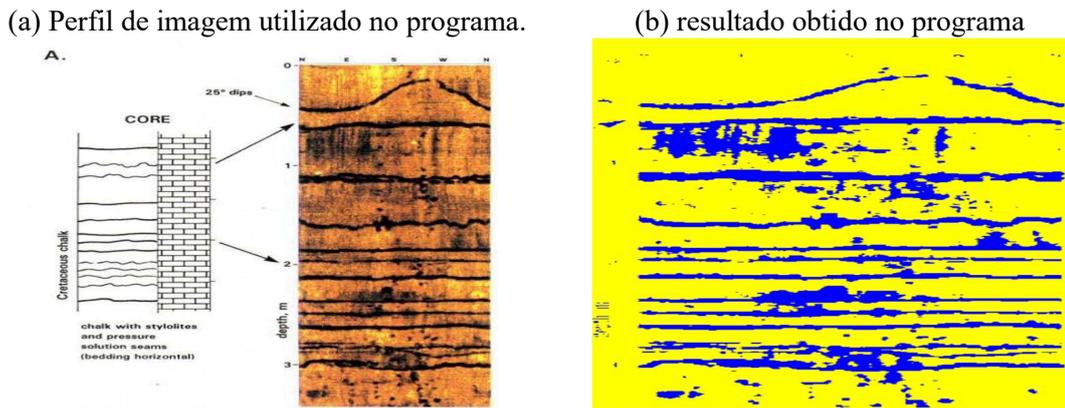


Figura 5. Litologia e feições sedimentares em imagens CBIL (a), extraído de Liu (2017). Resultado obtido destacando os principais limites de leito.

A Figura 6 representa a Imagem UBI mostrando rompimentos de poços e fraturas induzidas por perfuração; a região de espessura pequena e cor escura é fratura induzida por perfuração, quanto as regiões largas escuras são poços fugas (*breakouts*) (Alizadeh, 2015). Pode observar-se na Figura 6b, a caracterização bem definida do *breakout* e da fratura induzida representada pela cor azul, e não encontrando problemas na identificação das mesmas.

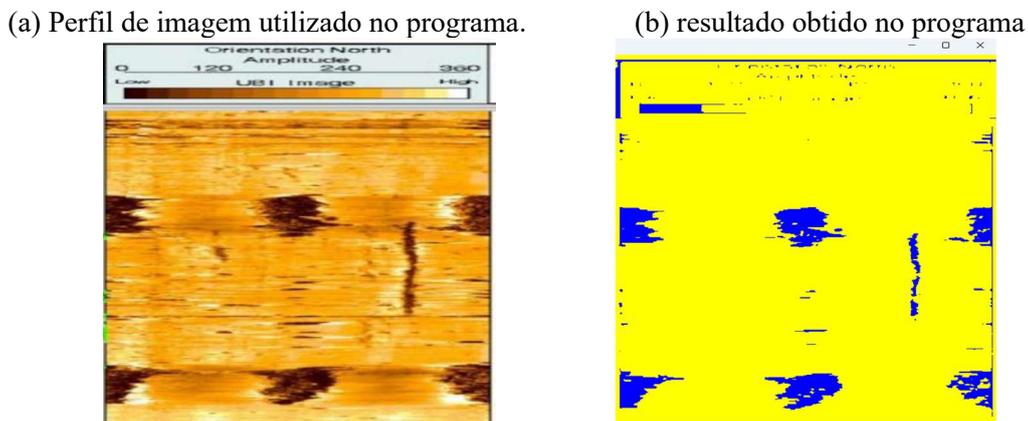


Figura 6. Imagem UBI mostrando rompimentos de poços e fraturas induzidas (a) (imagem modificada pela autora), extraído de Alizadeh (2015). Resultado obtido destacando os rompimentos e as fraturas induzidas (b).

Fraturas de baixa amplitude são representadas como anomalias sinusoidais escuras nas imagens de poço (BHIs) (Figura 7). O termo “baixa amplitude” neste contexto representa a baixa amplitude do sinal acústico refletido e não a extensão vertical física ou amplitude da sinusóide.

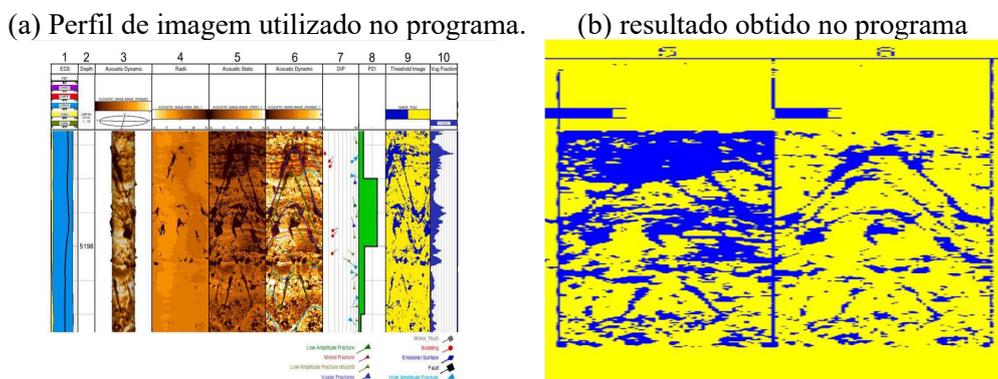


Figura 7. Da esquerda para a direita: 1) registro mineral (registro ECS), 2) profundidade medida, 3) Gráfico cilíndrico dos raios do poço do BHI acústico com BHI acústico dinâmico sobreposto, 4) Gráfico de raios, 5) BHI acústico normalizado estático, 6) BHI normalizado dinâmico com interpretação de estratificação e fraturas representadas por sinusóides, 7) Orientação de superfícies geológicas interpretadas representadas na trilha de girino, a legenda está abaixo, 8) Intensidade de fratura P21, 9) imagem segmentada para vugs, azul é vugs/fraturas vuggy e amarelo é matriz, 10) Fração vug estimada (a); extraído de Wennberg (2023). Resultado obtido destacando as fraturas da coluna 5 e 6 (a).

Em litologias carbonáticas, é provável que essas fraturas de baixa amplitude estejam abertas ao fluxo de fluido (Adams e Dart, 1998). As fraturas de baixa amplitude normalmente cruzam estratificação. Na Figura 7, observa-se uma visão geral dos principais dados utilizados e interpretações derivadas. Na Figura 7a, coluna 9, o autor (Wennberg et al., 2023), obteve um resultado aproximado como a resolução obtida no programa em Python desenvolvida pela autora. Consegue-se notar semelhanças entre ambas as figuras, identificando as fraturas expostas de baixa amplitude, a orientação principal das fraturas é na mesma direção da tendência de falha dominante, e isso indica um controle estrutural na formação de fraturas (Wennberg et al., 2023).

5 Conclusões

Após décadas de aplicações na indústria do petróleo, as interpretações geológicas dos registros de imagens permanecem subjetivas, especialmente quando o cenário geológico é complexo e/ou a qualidade da imagem (em termos de resolução, nível de ruído e contraste petrofísico) varia.

Além disso, os critérios usados para interpretar as fácies da imagem, incluindo sucessão de cores e padrões de mergulho, devem ser estabelecidos para reconhecer estruturas sedimentares de pequena escala e características estruturais de grande escala, e fornece diretrizes na interpretação de reservatórios sedimentares (Donselaar e Schmidt, 2010; Folkestad et al., 2012; Muniz e Bosence, 2015).

A detecção e caracterização de fraturas naturais através de perfis de poços têm um impacto significativo na exploração, produção e desenvolvimento de reservatórios de hidrocarbonetos, uma vez que as fraturas impactam a permeabilidade geral do reservatório e o fluxo de fluidos (Prioul et al., 2007; Tokhmchi et al., 2010; Ameen et al., 2007; Tokhmchi et al., 2010; Ameen et al., 2007; Tokhmchi et al., 2010; Kosari et al., 2015; Lyu et al., 2016; Lai et al., 2017b; Liu et al., 2017).

A interpretação automática de fraturas nos perfis de imagem utilizando Inteligência Artificial enfrenta desafios, mas oferece contribuições significativas para o avanço científico, eficiência operacional e segurança, beneficiando a indústria. A contínua pesquisa e inovação nessa área são fundamentais para superar limitações e maximizar os benefícios proporcionados por essa tecnologia. Ao decorrer desse estudo, foram encontradas dificuldades e limitações, como: a disponibilidade e qualidade dos dados, acuracidade da anotação manual, generalização para diferentes contextos geológicos e complexidade da geologia subsuperficial. Mas, apesar das dificuldades e limitações, o avanço do estudo proporcionara contribuições nos âmbitos acadêmico e profissional, como: o avanço na pesquisa científica, eficiência e produtividade na indústria, capacitação profissional e educação e a identificação das fraturas.

Em qualquer projeto de desenvolvimento de software inicial, incluindo a criação de um programa para a interpretação automática de fraturas nos perfis de imagem, é possível que ocorram falhas e erros em diferentes etapas do processo. Ao decorrer da pesquisa, a inadequação do algoritmo de IA, foi um desafio, pois a sua configuração incorreta resultou em um modelo que não conseguia generalizar bem e apresentou baixa acuracidade na interpretação das fraturas; erros e inadequações no pré-processamento dos dados impactaram negativamente a qualidade do modelo, obtendo normalização inadequada e falhas na extração das características relevantes.

Para a continuidade do trabalho de interpretação automática de fraturas nos perfis de imagem utilizando Inteligência Artificial (IA), é fundamental focar em várias direções para aprimorar e expandir a pesquisa, como o aprimoramento da precisão do modelo, integração de dados multimodais, incorporação de dados temporais (evolução temporal das fraturas). Ao seguir essas sugestões, o projeto pode evoluir e evoluirá (na continuidade do projeto), oferecendo soluções mais avançadas e eficazes para a interpretação automática de fraturas nos perfis de imagem, contribuindo para avanços significativos na indústria e na pesquisa geológica. Este trabalho foi um desafio e com iniciais e bons resultados como comentados anteriormente.

Agradecimentos

Agradeço ao CNPq, cujo apoio financeiro foi essencial para a realização deste projeto.

Referências bibliográficas

Adams, JT e Dart, C (1998) “The appearance of potential sealing faults on borehole images,” *Geological Society special publication*, 147(1), pp. 71–86. doi: 10.1144/gsl.sp.1998.147.01.05

- Ali, JK. (1994) “Neural networks: A new tool for the petroleum industry?,” in *All Days*. SPE.
- Alizadeh, M, Movahed, Z e Junin, RB (no date) *In-situ stress analysis using image logs*, *Tsijournals.com*. Available at: <https://www.tsijournals.com/articles/insitu-stress-analysis-using-image-logs.pdf> (Acesso em: 26 de setembro de 2023).
- Ameen, MS, MacPherson, K, Al-Marhoon, MI, e Rahim, Z (2012). Diverse fracture properties and their impact on performance in conventional and tight-gas reservoirs, Saudi Arabia: The Unayzah, South Haradh case study. *AAPG Bulletin*, 96(3), 459–492. <https://doi.org/10.1306/06011110148> (Acesso em: 27 de setembro de 2023).
- Brekke, H, MacEachern, JA, Roenitz, T, e Dastgard, SE (2017). *The use of microresistivity image logs for facies interpretations: An example in point-bar deposits of the McMurray Formation, Alberta, Canada*. *AAPG Bulletin*, 101(05), 655–682. doi:10.1306/08241616014
- Cuddy, S (2021) “The benefits and dangers of using artificial intelligence in petrophysics,” *Artificial Intelligence in Geosciences*, 2, pp. 1–10. doi: 10.1016/j.aiig.2021.04.001.
- Donselaar, ME. e Schmidt, JM (2005) “Integration of outcrop and borehole image logs for high-resolution facies interpretation: example from a fluvial fan in the Ebro Basin, Spain,” *Sedimentology*, 52(5), pp. 1021–1042. doi: 10.1111/j.1365-3091.2005.00737.x
- Donselaar, ME e Schmidt, JM (2010) “The application of borehole image logs to fluvial facies interpretation,” in *Dipmeter and Borehole Image Log Technology*. American Association of Petroleum Geologists, pp. 1–22. doi: <https://doi.org/10.1306/13181283M923415>
- Fatah, TYA (2020) “Análise de zonas de fraturas através de perfis de imagem em poços do pré-sal da Bacia de Santos.” Available at: https://oasisbr.ibict.br/vufind/Record/UFF-2_576d4b9b9c807be6630881af06ed96ca (Acesso em: 27 de setembro de 2023).
- Félix, FA, Nascimento, ES do e Borba, C (2013) “Perfis de imagem de poços de petróleo”, *Caderno de Graduação - Ciências Exatas e Tecnológicas - UNIT - SERGIPE*, 1(2), p. 61–78. Disponível em: <https://periodicos.set.edu.br/cadernoexatas/article/view/525> (Acesso em: 27 de setembro de 2023).
- Folkestad, A, Veselovsky, Z e Roberts, P (2012) “Utilising borehole image logs to interpret delta to estuarine system: A case study of the subsurface Lower Jurassic Cook Formation in the Norwegian northern North Sea,” *Marine and petroleum geology*, 29(1), pp. 255–275. doi: 10.1016/j.marpetgeo.2011.07.008.
- Hanga, K M. e Kovalchuk, Y (2019) “Machine learning and multi-agent systems in oil and gas industry applications: A survey,” *Computer science review*, 34(100191), p. 100191. doi: 10.1016/j.cosrev.2019.08.002
- Ja'fari, A, Kadkhodaie-Ilkhchi, A, Sharghi, Y, e Ghanavati, K (2012) Fracture density estimation from petrophysical log data using the adaptive neuro-fuzzy inference system. *Journal of Geophysics and Engineering*, 9(1), 105-114. doi: <https://doi.org/10.1088/1742-2132/9/1/013>
- Roedel Júnior, J (2014). *Aplicação dos Perfis de Imagem na Indústria do Petróleo*. SILO of research documents. Available at: <https://silo.tips/download/aplicacao-dos-perfis-de-imagem-na-industria-do-petroleo> (Acesso em: 27 de setembro de 2023).
- Lagraba, JOP, Hansen, SM, Spalburg, M, e Helmy, M (2010). Borehole image tool design, value of information, and tool selection. *Dipmeter and borehole image log technology*, 92, 15-38. doi: <https://doi.org/10.1306/13181275M923403>
- Lai, J, Wang, G, Fan, Z, Wang, Z, Chen, J, Zhou, Z, e Xiao, C (2017). Fracture detection in oil-based drilling mud using a combination of borehole image and sonic logs. *Marine and Petroleum Geology*, 84, 195-214. doi: <https://doi.org/10.1016/j.marpetgeo.2017.03.035>
- Lechner, JP. e Zangl, G (2005) “Treating uncertainties in reservoir performance prediction with neural networks,” in *All Days*. SPE, p. SPE-94357-MS.
- Li, H, Yu, H, Cao, N, Tian, H, e Cheng, S (2021) “Applications of artificial intelligence in oil and gas development,” *Archives of Computational Methods in Engineering. State of the Art Reviews*, 28(3), pp. 937–949. doi: 10.1007/s11831-020-09402-8
- Liu, H (2017) *Principles and applications of well logging*. Berlin, Heidelberg: Springer Berlin Heidelberg.

- Liu, J, Ding, W, Wang, R, Yin, S, Yang, H, e Gu, Y (2017) “Simulation of paleotectonic stress fields and quantitative prediction of multi-period fractures in shale reservoirs: A case study of the Niutitang Formation in the Lower Cambrian in the Cen’gong block, South China,” *Marine and petroleum geology*, 84, pp. 289–310. doi: 10.1016/j.marpetgeo.2017.04.004
- Lyu, W, Zeng, L, Liu, Z, Liu, G, e Zu, K. (2016) “Fracture responses of conventional logs in tight-oil sandstones: A case study of the Upper Triassic Yanchang Formation in southwest Ordos Basin, China,” *AAPG bulletin*, 100(09), pp. 1399–1417. doi: 10.1306/04041615129
- Lyu, W, Zeng, L, Zhang, B, Miao, F, Lyu, P, e Dong, S (2017) “Influence of natural fractures on gas accumulation in the Upper Triassic tight gas sandstones in the northwestern Sichuan Basin, China,” *Marine and petroleum geology*, 83, pp. 60–72. doi: 10.1016/j.marpetgeo.2017.03.004
- Muniz, MC e Bosence, DWJ (2015) “Pre-salt microbialites from the Campos Basin (offshore Brazil): image log facies, facies model and cyclicity in lacustrine carbonates,” *Geological Society special publication*, 418(1), pp. 221–242. doi: 10.1144/sp418.10
- Paes, M da R (2016) “Aplicação do sistema LWD em poços horizontais.” Available at: <https://app.uff.br/riuff/handle/1/1438> (Acesso em: 27 de setembro de 2023).
- Prioul, R, Donald, A, Koepsell, R, Marzouki, ZE, e Bratton, T (2007) “Forward modeling of fracture-induced sonic anisotropy using a combination of borehole image and sonic logs,” *Geophysics*, 72(4), pp. E135–E147. doi: 10.1190/1.2734546
- Support vector machine (SVM) explained* (no date) *Mathworks.com*. Available at: <https://www.mathworks.com/discovery/support-vector-machine.html> (Acesso em: 28 de outubro de 2023).
- Tokhmchi, B, Memarian, H e Rezaee, MR (2010) “Estimation of the fracture density in fractured zones using petrophysical logs,” *Journal of petroleum science & engineering*, 72(1–2), pp. 206–213. doi: 10.1016/j.petrol.2010.03.018
- Wennberg, OP, Ramalho, FDO, Mafia, MV, Lapponi, F, Chandler, AS, Cartesio, LG, e Hunt, DW (2023) “The characteristics of natural open fractures in acoustic borehole image logs from the pre-salt Barra Velha formation, Santos Basin, Brazil,” *Journal of structural geology*, 167(104794), p. 104794. doi: 10.1016/j.jsg.2023.104794
- Wilson, ME, Lewis, D, Holland, D, Hombo, L, e Goldberg, A. (2013) “Development of a Papua New Guinean onshore carbonate reservoir: A comparative borehole image (FMI) and petrographic evaluation,” *Marine and petroleum geology*, 44, pp. 164–195. doi: 10.1016/j.marpetgeo.2013.02.018
- Xu, C, Cronin, TP, McGinness, TE, e Steer, B (2009) “Middle Atokan sediment gravity flows in the Red Oak field, Arkoma Basin, Oklahoma: A sedimentary analysis using electrical borehole images and wireline logs,” *AAPG bulletin*, 93(1), pp. 1–29. doi: 10.1306/09030808054
- Zeng, L (2010) “Microfracturing in the Upper Triassic Sichuan Basin tight-gas sandstones: Tectonic, overpressure, and diagenetic origins,” *AAPG bulletin*, 94(12), pp. 1811–1825. doi: 10.1306/06301009191
- Zoback, MD (2007) *Reservoir Geomechanics*. Cambridge University Press, New York, 3-55.