Interpretação sísmica de falhas utilizando *deep learning* no campo de Búzios.

Matheus Nilo*[1], Fábio Júnior Damasceno Fernandes[1], Eberton Rodrigues de Oliveira Neto[3], Leonardo Teixeira[3], Wagner Moreira Lupinacci[12], [1]GIECAR-UFF, [2]INCT-GP, [3]Petrobras

Copyright 2024, SBGf - Sociedade Brasileira de Geofísica

Este texto foi preparado para a apresentação no IX Simpósio Brasileiro de Geofísica, Salvador, 08 a 10 de outubro de 2024. Seu conteúdo foi revisado pelo Comitê Técnico do X SimBGf, mas não necessariamente representa a opinião da SBGf ou de seus associados. É proibida a reprodução total ou parcial deste material para propósitos comerciais sem prévia autorização da SBGf.

Resumo

Neste artigo aplicamos algoritmos de aprendizado de máquina para auxiliar na interpretação sísmica de falhas. O estudo destaca a eficiência dos algoritmos de detecção de falhas, particularmente aqueles baseados em arquiteturas avançadas como *U-Net* e descreve uma metodologia onde aborda-se a detecção de falhas como um problema de segmentação binária de imagem. Desta maneira rotulamos uma imagem sísmica 3D com valores de um nas falhas e zeros no restante. Utilizamos uma rede neural convolucional (CNN) totalmente supervisionada para realizar uma segmentação de falhas de forma eficiente. Para treinar a rede, desenvolvemos um conjunto de dados sintético baseado na construção de um modelo estrutural aleatório, preenchendo-a com simulações estocásticas baseadas em geoestatística e realizando a modelagem direta através da *point-spread function* (PSF). Variações do modelo de CNN e seus parâmetros são comparadas e aplicadas em diferentes campos demonstrando que a rede pode prever falhas em seções sísmicas de maneira precisa e eficiente reduzindo assim o tempo do fluxo de interpretação.

Introdução

A interpretação sísmica de falhas desempenha um papel fundamental na caracterização de reservatórios dentro da indústria de petróleo e gás. Métodos convencionais abrangem uma variedade de técnicas, incluindo análise visual de atributos sísmicos, análise geométrica e abordagens baseadas em horizontes. No entanto, esses métodos enfrentam desafios como resolução limitada, subjetividade na interpretação visual e dependência da qualidade dos dados, tornando-os demorados. Assim, algoritmos de detecção de falhas funcionam de forma eficiente na delimitação de estruturas de falhas. Este trabalho fornece uma visão geral dos métodos baseados em aprendizado profundo empregados na interpretação de falhas sísmicas. Ao aproveitar redes neurais convolucionais (CNNs) e arquiteturas avançadas como U-Net, os pesquisadores alcançaram sucesso notável na automação de tarefas de detecção e segmentação de falhas (Wu et al., 2019; An et al., 2021; An e Dong, 2023). A metodologia envolve treinar um modelo CNN em um conjunto de dados abrangente e gerar dados sintéticos para melhorar o treinamento da rede. Essas abordagens para geração de dados sísmicos sintéticos apresentam problemas e limitações quando aplicadas para representar conjuntos de dados pré-sal. Logo, para contornar essa limitação, o modelo direto adotado na geração sísmica sintética deve incorporar efeitos de migração e abertura de aquisição para produzir modelos confiáveis. Para isso, construímos um modelo estrutural aleatório, preenchendo-o com simulações estocásticas baseadas em geoestatística e realizando a modelagem direta baseada na *point-spread function* (PSF). Repetindo a rotina de geração várias vezes com parâmetros de controle aleatórios cria um conjunto de dados generalista para resolver várias aplicações de interpretação sísmica quantitativa.

Neste trabalho, utilizamos uma CNN, modificada a partir da *U-Net* proposta por (Wu et al., 2019), para extrair um volume de probabilidade de falha em dados sísmicos 3D. Adotamos a função de perda de entropia cruzada balanceada para otimizar os parâmetros do nosso modelo e para treinar e validar a rede foram utilizados 180 e 20 pares de dados sintéticos, respectivamente. Embora treinado usando apenas conjuntos de dados sísmicos sintéticos, podemos notar qualitativamente que os modelos de CNN podem funcionar muito melhor e de forma mais eficiente do que os métodos convencionais para detecção de falhas em 3D em conjuntos de dados sísmicos reais.

Metodologia

Estabelecendo um fluxo de trabalho para desenvolver uma arquitetura que otimize o processo de identificação de falhas, concentramos nossos esforços em três etapas: conjunto de dados de treinamento, arquitetura da rede e pré-condicionamento dos dados.

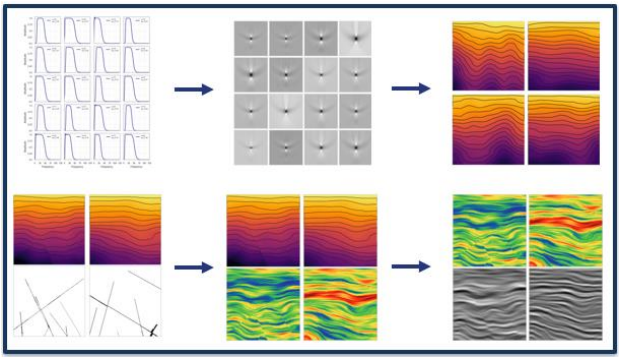

Figura 1 – Fluxo de trabalho proposto para geração dos dados sintéticos.

Para gerar os dados sintéticos, começamos criando seções transversais com pseudo-RGTs (*Relative Geologic Time*) aleatórios, introduzindo falhas normais usando a metodologia proposta por Wu et al., 2019, e realizando transformada rápida de Fourier com média móvel (FFT-MA) para simulações estocásticas de impedância acústica e realizando modelagem direta convolvendo o modelo de refletividade com várias PSF's, conforme proposto inicialmente por Lecomte (2003) e posteriormente por Jing et al. (2023). Essa modificação visa aumentar o realismo do conjunto de dados de treinamento, uma vez que a resolução das imagens de convolução 1D não é razoável, enquanto as imagens de convolução PSF estão mais próximas das imagens sísmicas atuais (Figura 1). Este método é reconhecido por produzir dados sísmicos sintéticos que se assemelham de perto aos dados sísmicos PSDM reais, incluindo imagens de Migração no Tempo Reverso (RTM) (Jensen et al., 2021).

Utilizando essa metodologia, criamos 200 pares de dados sintéticos 3D com tamanho de 128x128x128 (Figura 2). Poderíamos criar uma quantidade maior de dados, porém para efeito de comparação com trabalhos propostos anteriormente por outros autores, nos restringimos a essa quantidade. Porém, técnicas de aumento de dados foram aplicadas como rotação em 90º, 180º e 270º.

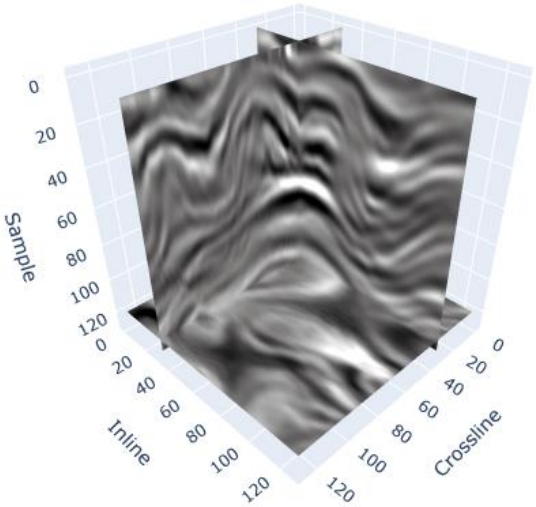

Figura 2 – Dado sintético 3D gerado pela convolução PSF.

Uma vez que lidamos com a detecção de falhas como um problema de segmentação binária, implementamos uma rede que possui arquitetura baseada na *U-Net* simplificada proposta por Wu et al., 2019 (Figura 3). No caminho de contração (lado esquerdo), cada etapa é composta por duas camadas convolucionais 3 × 3 × 3, seguidas por uma ativação *ReLU* e um operação de *maxpooling* 2 × 2 × 2 com *stride* 2 para *downsampling*. Cada passo no caminho de expansão (lado direito) contém uma operação de *transposed convolution* 2 × 2 × 2, uma concatenação com os padrões do caminho de contração e duas camadas convolucionais 3 × 3 × 3 seguidas por uma ativação ReLU. Por acreditar se tratar de um problema mais complexo, adicionamos uma camada a mais, tornando a rede mais profunda. A operação de *transposed convolution* é implementada usando a função *Conv3DTranspose* definida em Keras (Chollet, 2015). Fizemos teste utilizando batch normalization e adicionando camadas de *dropout*, porém não obtivemos melhora no resultado. A camada de saída final é uma camada convolucional 1 × 1 × 1 com uma ativação sigmoide.

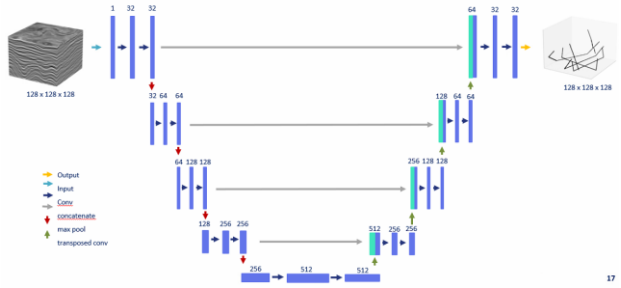

Figura 3 – Uma representação esquemática da arquitetura U-net para detecção de falhas 3D.

Inicialmente utilizou-se a *Binary-CrossEntropy* como função de perda por ser bastante popular em tarefas de segmentação binária. Contudo, notou-se que apesar da rede atingir valores satisfatórios de acurácia, qualitativamente as predições tinham baixa continuidade e probabilidade. Sendo assim, utilizamos a *Balanced-CrossEntropy* proposta por Wu et al., 2019:

$$L = -\beta \sum_{i=0}^{i=N} y_i \log(p_i) - (1 - \beta) \sum_{i=0}^{i=N} (1 - y_i)\, log\,(1 - p_i) \qquad (1)$$

Desta maneira, é possível ajustar o desequilíbrio para que a rede não seja treinada ou convergida para prever apenas zeros. Treinamos o modelo utilizando *batch size* de 4, o método Adam (Kingma and Ba, 2014) como otimizador dos parâmetros da rede e taxa de aprendizado de 0,0001, durante 200 épocas.

Para avaliar quantitativamente o desempenho da rede, calculamos as perdas e acurácia nos dados de treinamento e validação definidos durante os processos de treinamento. A Figura 4 mostra as variações das métricas ao longo das épocas. A curva de acurácia para o treinamento e validação aumentam gradualmente para mais de 93%, enquanto todas as perdas convergem para níveis estáveis. No entanto, é possível notar lacunas entre as curvas de perda e acurácia tanto no treinamento quanto na validação, sendo maior neste último. Uma possível justificativa, de acordo com Jing et al., 2023, seria pelo fato das características de falha nos dados de

convolução PSF variarem muito devido à influência das frequências e velocidades dominantes, o que pode explicar as lacunas entre as curvas de treinamento e validação.

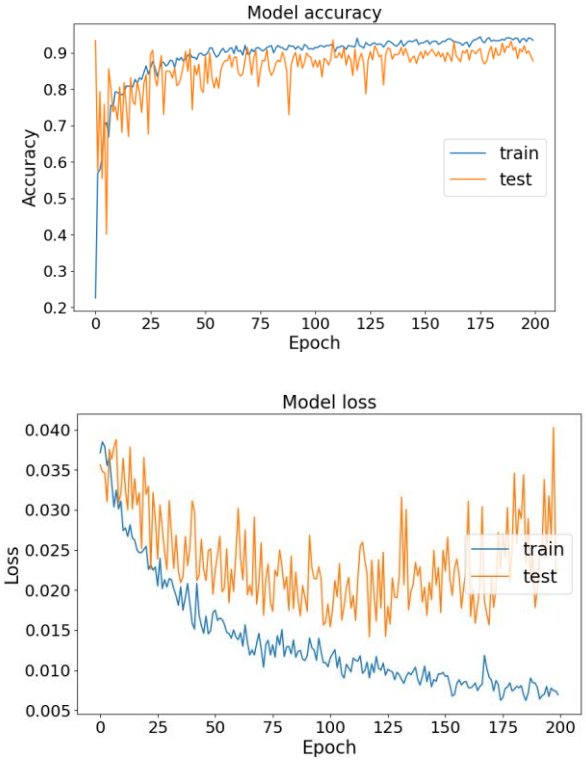

Figura 4 – Curvas da função de perda e acurácia para treinamento e validação

Apesar do dado sintético ser mais parecido visualmente com o nosso dado real de aplicação, para alcançar uma melhor performance, faz-se necessário alinhar as características dos dados de aplicação com o conjunto de dados de treinamento, que geralmente não pode representar totalmente os verdadeiros aspectos dos dados sísmicos reais.

Para isso, aplicamos alguns processos de filtragem e *plugins* disponíveis no OpendTect. Inicialmente, utilizamos um modelo pré-treinado (3D U-Net) da AkerBP (Lundin-Geolab), que aprendeu a reduzir ruído aleatório e

otimizar o conteúdo de amplitude-frequência. Posteriormente, aplicamos o *Dip-Steered median filter* para melhorar eventos sísmicos lateralmente contínuos, filtrando ao longo do mergulho estrutural dos refletores. Embora eficaz em reduzindo o ruído, esses filtros de suavização tendem a desfocar as bordas e comprometer a fidelidade de imagens importantes. características. Para resolver isso, empregamos o *Edge Preserver Smoothing Filter* (EPS), com o objetivo de encontrar um equilíbrio entre redução de ruído e preservação de estruturas geológicas detalhadas.

Entretanto, o filtro EPS padrão, que utiliza informações do atributo sísmico coerência, tem uma desvantagem porque, apesar de destacar descontinuidades, pode deformar formas de falhas devido à forma das descontinuidades. Para superar esse desafio, aplicamos um fluxo de trabalho chamado *Bootstrap (*Nilo et al., 2024). Nesta abordagem, utilizamos a probabilidade de falha predita pela CNN como entrada para estimar a o atributo *Fault Likelihood, que agora* possuirá informações de *dip* e *strike*. Ao incorporar esse atributo como um guia para o filtro EPS, aprimoramos seu desempenho, permitindo uma aplicação mais eficaz do rede (Figura 4).

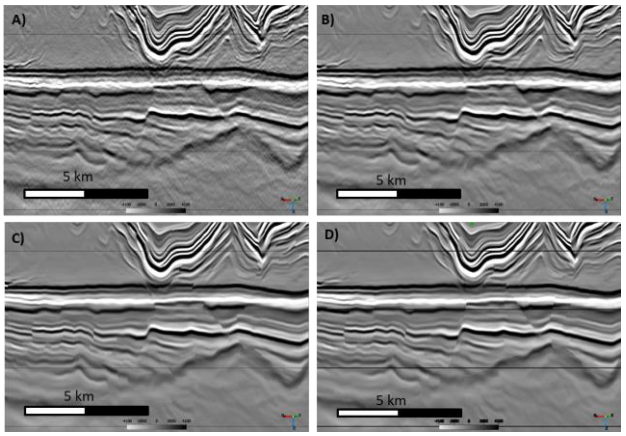

Figura 5 – Em A) temos a seção sísmica sem filtro; B) CNN pré-treinada para remoção de ruídos e Dip-Steered Median Filter; C) Filtro Edge-Preserving Smooth filter; D) Fluxo "Bootstrap".

Resultados

O campo de Búzios é um dos principais produtores do pré-sal brasileiro (figura 5). Os reservatórios carbonáticos do pré-sal foram depositados sob uma espessa camada de sal em grandes profundidades (aproximadamente 5.000 metros), representando um desafio para imageamento sísmico e iluminação. O dado de aplicação deste trabalho possui uma aquisição sísmica *ocean-bottom nodes* (OBN) com espectro de banda larga, capturando informações geológicas em frequências mais baixas e mais altas em comparação com dados antigos, onde a largura de banda é mais estreita.

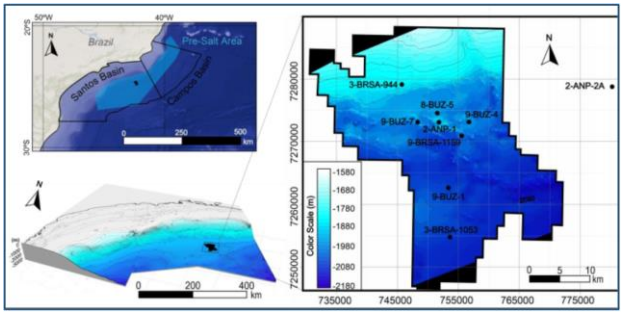

Figura 6 – Localização do campo de Búzios

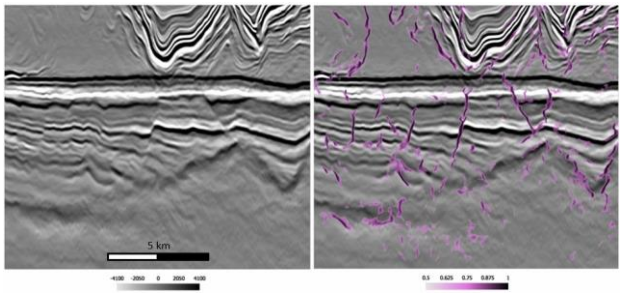

Figura 7 – Probabilidade de falha extraída na seção sísmica cross-line de Búzios após remoção de ruídos e dip-steered median filter

Avaliando a performance da rede qualitativamente, notamos que foi capaz de captar diferentes *trends* de falhas. As descontinuidades que possuem maior deslocamento estão muito bem segmentadas. Um grande número de falhas com deslocamentos relativamente pequenos se desenvolve dentro deste volume de imagem sísmica 3D e a rede foi capaz de predizer em algumas regiões. A detecção precisa destas falhas continua a ser um desafio, mas quando compara-se com os métodos convencionais, a diferença na quantidade de artefatos é bem significativa, assim como as predições são mais assertivas, do ponto de vista qualitativo (Figuras 8 e 9).

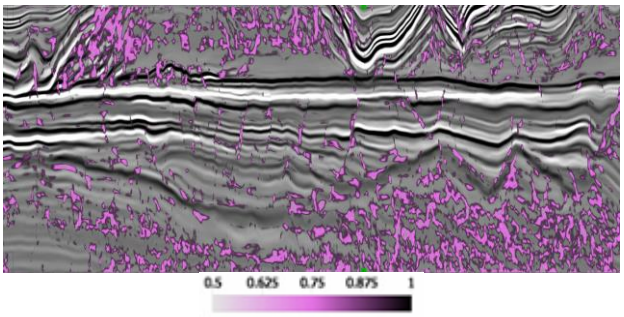

Figura 8 – Probabilidade de falha extraída a partir do atributo sísmico Semblance

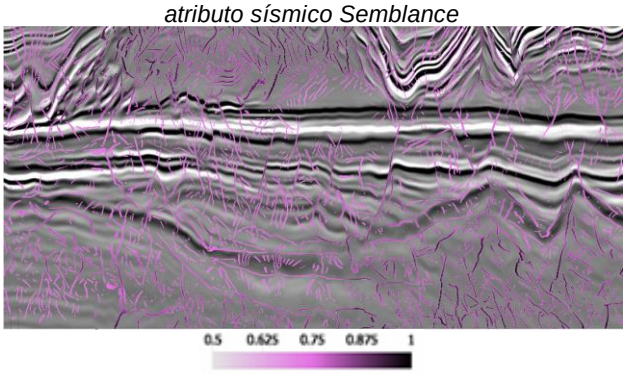

Figura 9 – Probabilidade de falha extraída a partir do Fault Likelihood na seção sísmica cross-line de Búzios após o fluxo Bootstrap

Após o pré-condicionamento, há uma melhoria significativa mesmo quando comparado apenas à filtragem de ruído (Figura 7), uma vez que a previsão de falhas é mais contínua e com menos artefatos (Figura 10). Porém, como todo processo de filtragem, podemos perder informações úteis. No nosso caso, o filtro suprime características de pequena escala relacionadas a falhas sub-sísmicas.

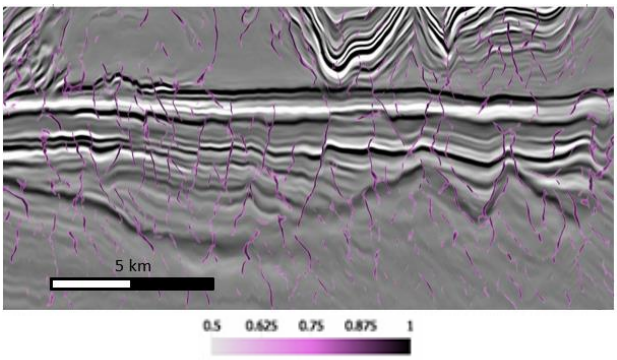

Figura 10 – Probabilidade de falha extraída na seção sísmica cross-line de Búzios após Bootstrap

Por fim, para melhor visualização, extraímos o volume de probabilidade de falha no horizonte sísmico referente a base do sal no eixo Z.

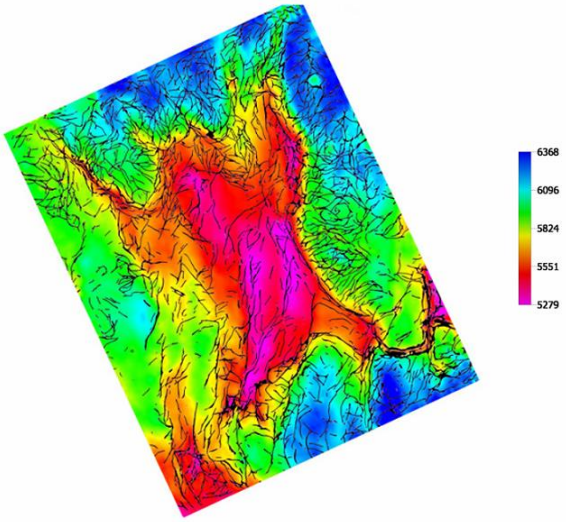

Figura 11 – Probabilidade de falha extraída na base do sal no Campo de Búzios

Conclusões

Desenvolvemos rotinas para criar conjuntos de dados sísmicos sintéticos 2D e 3D para treinar redes neurais profundas simulando cenários complexos como o pré-sal brasileiro. Logo, concentrar-se no conjunto de dados de treinamento parece ser uma estratégia rápida e eficaz

para melhorar as predições de redes neurais. Contudo, pré-condicionar os dados pode ser demorado, porém mostra-se eficiente para modelos pré-treinados nos dados sintéticos.

Agradecimentos

Os autores agradecem à Petrobras pelo financiamento do projeto de P&D em parceria com o GIECAR e pelo fornecimento dos dados utilizados nesta pesquisa

Referências

An, Y. and Dong, R. [2023] Understanding the Effect of Different Prior Knowledge on CNN Fault Interpreter. IEEE Access, 11, 15058–15068.

An, Y., Guo, J., Ye, Q., Childs, C., Walsh, J. and Dong, R. [2021] Deep convolutional neural network for automatic fault recognition from 3D seismic datasets. Computers Geosciences, 153, 104776.

Jing, J., Yan, Z., Zhang, Z., Gu, H. and Han, B. [2023] Fault detection using a convolutional neural network trained with point-spread function-convolution-based samples. Geophysics, 88(1), IM1– IM14.

Lecomte, I., Gjøystdal, H. and Åsmund Drottning [2003] Simulated prestack local imaging: A robust and efficient interpretation tool to control illumination, resolution, and time-lapse properties of reservoirs. 1525–1528

LeCun, Yann, B.Y.H.G. [2015] Deep learning. Nature, 521, 1476–4687.

Nilo, M., Rodrigues, E., Fernandes, F., Teixeira, L. and Lupinacci, W. [2024] A Preconditioning Workflow for Seismic Fault Interpretation Using Deep Learning Applications in the Brazilian Pre-Salt. 2024(1), 1–5.

Vizeu, F., Zambrini, J. and Canning, A. [2023] The impact of the synthetic seismic data generation method on automated AI-based horizon interpretation. 831–834.

Wu, X. and Hale, D. [2016] 3D seismic image processing for faults. GEOPHYSICS, 81(2), IM1– IM11.

Wu, X., Liang, L., Shi, Y. and Fomel, S. [2019] FaultSeg3D: Using synthetic data sets to train an endto-end convolutional neural network for 3D seismic fault segmentation. GEOPHYSICS, 84(3), IM35– IM45.