

# ESTIMANDO O MODELO INICIAL DE VELOCIDADES PARA FWI USANDO DEEP LEARNING

Luan Rios Campos<sup>1</sup>; Peterson Nogueira Santos<sup>2</sup>; Erick Giovani Sperandio Nascimento<sup>3</sup>

<sup>1</sup> Mestrando em Modelagem Computacional e Tecnologia Industrial; Mestrado – EMPRAPII;  
luan.rios.campos@gmail.com

<sup>2</sup> Mestre em Geofísica; Centro de Supercomputação SENAI CIMATEC / UFBA; Salvador-BA;  
nogueirapeterson@gmail.com

<sup>3</sup> Doutor em Engenharia Ambiental; Centro Universitário SENAI CIMATEC; Salvador-BA;  
erick.sperandio@fieb.org.br

## RESUMO

A construção de modelos iniciais de velocidade que sejam satisfatórios é uma tarefa crucial para que atinja-se bons resultados utilizando o método de inversão completa da forma de onda (FWI), sem que haja gasto excessivo de recursos computacionais. Recentemente, pesquisadores têm experimentado o uso de técnicas de *deep learning* para construção de modelos de velocidade, mas não necessariamente com o intuito de usá-los na FWI. Este trabalho tem dois objetivos: 1) usar uma *fully convolution network* (FCN) para estimar um modelo inicial de velocidades e 2) avaliar o modelo resultante em uma implementação multi-escada da FWI. Os modelos produzidos pela FCN carecem de certos detalhes quando comparadas com o modelo ideal, como estruturas de falhas e posicionamento de algumas camadas, mas estes problemas foram corrigidos após a aplicação da FWI. A conclusão que pode-se chegar é que os resultados produzidos pela FCN provaram ser modelos iniciais satisfatórios para a FWI.

**PALAVRAS-CHAVE:** *deep learning*, modelo de velocidades inicial, FWI, FCN

## 1. INTRODUÇÃO

A FWI, do inglês *full waveform inversion*, é um método de alta resolução para inversão de parâmetros de uma subsuperfície e requer um modelo inicial satisfatório já que ela tenta resolver um problema não linear.<sup>1</sup> Na indústria de exploração de óleo e gás, é comum gerar um modelo inicial para a FWI através de tomografia de reflexão e análise de velocidades baseada em migração. A maioria dos métodos propostos para este procedimento são baseados na tomografia de tempo de viagem, mas é desejável evitar tais métodos porque eles podem exercer tarefas que demandam bastante tempo. Alternativas que usam métodos globais de busca, como algoritmos genéticos<sup>2</sup> e *simulated annealing*<sup>3</sup>. Entretanto, conforme o tamanho do modelo de velocidade e o tamanho da população utilizada aumenta, mais etapas de modelagem são necessárias, aumentando, conseqüentemente, o custo computacional. Iniciativas recentes têm crescido quanto ao uso de métodos de *deep learning* para solucionar uma variedade de problemas em diferentes áreas do conhecimento, incluindo aplicações em geofísica.<sup>4 5 6</sup>

Neste contexto, este trabalho tem os objetivos de usar uma rede totalmente convolucional para estimar um modelo inicial de velocidades e avaliar o modelo resultante em uma implementação multi-escada da FWI. Com isso, analisou-se o uso de uma FCN para gerar modelos iniciais que possam ser utilizados na FWI. Implementou-se um método para a FWI no domínio do tempo usando uma abordagem multi-escala, no domínio da frequência, aplicando-se o método de diferenças finitas para solucionar a equação acústica da onda. A FCN segue a arquitetura usada por<sup>7</sup> com modificações no otimizador e nas métricas utilizadas para treinamento. Houve mudanças também no posicionamento das fontes e receptores durante a modelagem sísmica, de forma a simular uma aquisição mais convencional.

## 2. METODOLOGIA

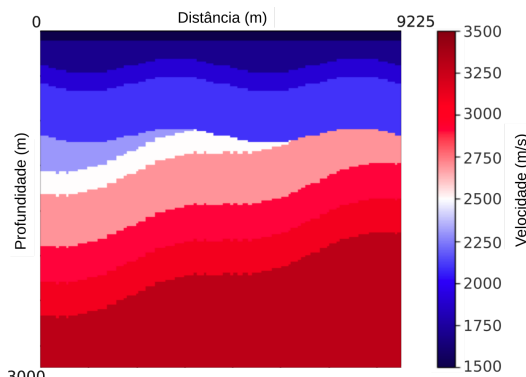
Neste trabalho utilizamos uma FCN bastante similar com a que foi discutida por<sup>7</sup>, possuindo: uma seção de codificação (*encoder*) que consiste em sucessivas camadas de convoluções 3x3, utilizando normalização do *batch* e a função de ativação ReLU, mais *max-pooling* de 2x2; uma seção de decodificação (*decoder*) tendo camadas de *up-sampling* 2x2, em conjunto com convoluções 2x2, seguidas de camadas de convolução 3x3; e uma última seção onde aplica-se uma camada de convolução 1x1 sobre um recorte do resultado da última convolução da camada anterior para que possa-se produzir o modelo de velocidade. Enquanto as camadas de convolução organizam os mapas de atributos que executam as operações de

filtragem, de forma similar à convolução discreta, e as camadas de *pooling* combinam os atributos correlacionados<sup>8</sup>, as camadas de *up-sampling*, ao contrário das de *pooling*, realizam operações que permitem aumentar a resolução de saída da rede. Este modelo de rede foi treinado em duas GPUs NVIDIA Tesla P100-SMX2 de 16GB de RAM cada durante 200 épocas e com um *batch* de 5 amostras.

Nossa abordagem, quando comparada com a de <sup>7</sup>, possui algumas diferenças. Nossos testes consideraram a utilização do otimizador Adam<sup>9</sup> em vez do *Stochastic Gradient Descent* (SGD). Além disso, como este problema se caracteriza como uma regressão, o treinamento e avaliação da rede foi feita com base em outras 4 métricas além do erro quadrático médio (MSE) (função de *loss*), sendo elas: erro absoluto médio (MAE), coeficiente de determinação ( $R^2$ ), coeficiente de correlação ( $r$ ) e fator de 2. Outra importante diferença está no fato de utilizarmos modelos de velocidades maiores e uma diferença estratégica para a modelagem dos dados sísmicos: fontes igualmente espaçadas e receptores posicionados no mesmo nível de profundidade que as fontes para condizer com uma simulação de aquisição de dados mais realísticos.

Os modelos de velocidade representam a seção de uma subsuperfície de 3000 metros de profundidade por 9225 metros de comprimento e foram gerados a partir de uma configuração pré-definida de velocidades máximas e mínimas (de 1500 a 3500 m/s) e número de camadas variando entre 8 e 12 (Figura 1) .

Figura 1 - Modelo de velocidade gerado com 10 camadas, ondulações e inclinação, mas sem estruturas de falhas




### 3. RESULTADOS E DISCUSSÃO

A FCN demorou 18 horas para treinar todas as 200 épocas, mas a previsão um novo modelo levou menos de um segundo. Isto mostra que, assim que um dado sísmico for adquirido, a produção do modelo de velocidade é quase instantânea. O treinamento da rede tem como objetivo minimizar os valores de MSE e MAE, ao passo que as outras métricas devem estar o mais próximo possível de 1. Os valores obtidos ao fim da avaliação do modelos construído de MSE, MAE,  $R^2$ ,  $r$  e fator de 2 são, respectivamente: 10188; 65,6; 0,97; 0,98 e 1. É possível perceber com estas métricas que: as velocidades dos modelos previstos diferem em média até 65 m/s com relação ao modelo original e os modelos previstos estão correlacionados com o modelo original (Figuras 2a e 2b). Entretanto, o alto valor do MSE indica uma certa falta de precisão ao determinar o posicionamento de algumas camadas (setas na Figura 2b) e a detecção de falhas (contorno na Figura 2b).

O próximo passo foi utilizar a FWI com o modelo inicial produzido pela FCN. Notamos que, após a execução da FWI, os problemas de posicionamento e detecção de estruturas de falhas do modelo inicial foram corrigidos (Figura 2c). Além disso, podemos ver na Figura 2d que o modelo inicial já possui um baixo valor de raiz do erro quadrático médio (RMS), o que indica que o modelo inicial de fato é ótimo e que a FWI irá demandar menos recursos computacionais para conseguir inverter o dado sísmica e encontrar uma solução mais próxima do modelo original.

Figura 2 - Comparação do a) modelo ideal, b) do resultado da FCN, c) do modelo após FWI e exibição do d) erro RMS por cada iteração do FWI



#### 4. CONSIDERAÇÕES FINAIS

A FCN demonstrou ser uma boa ferramenta para construir modelos iniciais ótimos de velocidade para o FWI. Apesar de o modelo inicial gerado por esta técnica não possuir detalhes de estruturas de falhas e ter dificuldades em determinar o posicionamento de algumas camadas inclinadas, uma vez que o modelo está totalmente treinado e as etapas de validação foram executadas, a inferência de novos modelos ocorre de forma quase instantânea, requerendo menos recursos computacionais e interferência humana quando comparado com métodos mais convencionais. Além disso, sua utilização em conjunto com a FWI oferece uma combinação que mira prever o modelo final de velocidade com correções no posicionamento de camadas e nas estruturas de falhas em menos tempo, já que a alta resolução do modelo inicial auxilia o processo da FWI. Estudos futuros apontam para a melhoria da FCN, a comparação com outras técnicas, como algoritmo genético e otimização por enxame de partículas, utilização de outros métodos de *deep learning* e modelos mais complexos.

#### Agradecimentos

Gostaríamos de agradecer à Empresa Brasileira de Pesquisa e Inovação Industrial (EMBRAPPII), Shell e ao Centro de Supercomputação para Inovação Industrial do Senai CIMATEC pelo suporte a esta pesquisa.

#### 5. REFERÊNCIAS

- <sup>1</sup> VIRIEUX, Jean; OPERTO, Stéphane. **An overview of full-waveform inversion in exploration geophysics.** *Geophysics*, v. 74, n. 6, p. WCC1-WCC26, 2009.
- <sup>2</sup> SAJEVA, Angelo et al. **Estimation of acoustic macro models using a genetic full-waveform inversion: Applications to the Marmousi model.** *Geophysics*, v. 81, n. 4, p. R173-R184, 2016.
- <sup>3</sup> DATTA, Debanjan et al. **Global 3D acoustic Full Waveform Inversion using sparse model parameterization.** In: *SEG Technical Program Expanded Abstracts 2017*, p. 1599-1603. Society of Exploration Geophysicists, 2017.
- <sup>4</sup> LEWIS, Winston; VIGH, Denes. **Deep learning prior models from seismic images for full-waveform inversion.** In: *SEG Technical Program Expanded Abstracts 2017*, p. 1512-1517. Society of Exploration Geophysicists, 2017.
- <sup>5</sup> ARAYA-POLO, Mauricio et al. **Deep-learning tomography.** *The Leading Edge*, v. 37, n. 1, p. 58-66, 2018.
- <sup>6</sup> WU, Yue; LIN, Youzuo; ZHOU, Zheng. **InversionNet: Accurate and efficient seismic waveform inversion with convolutional neural networks.** In: *SEG Technical Program Expanded Abstracts 2018*, p. 2096-2100. Society of Exploration Geophysicists, 2018.
- <sup>7</sup> WANG, Wenlong; YANG, Fangshu; MA, Jianwei. **Velocity model building with a modified fully convolutional network.** In: *SEG Technical Program Expanded Abstracts 2018*, p. 2086-2090. Society of Exploration Geophysicists, 2018.
- <sup>8</sup> LECUN, Yann et al. **Backpropagation applied to handwritten zip code recognition.** *Neural computation*, v. 1, n. 4, p. 541-551, 1989.
- <sup>9</sup> KINGMA, Diederik P.; BA, Jimmy. **Adam: A method for stochastic optimization.** arXiv preprint arXiv:1412.6980, 2014.