



Classificação e filtragem adaptativa de *swell noise* através de rede neural e filtro de frequências 1D

Anderson S. Santos¹, Pablo Carvalho³, Nathalia Azevedo³, Gilmário Maciel¹, Rodrigo Portugal³, Pablo Barros², André Bulcão²;

(1) Petrobras-GDGEOF, (2) Petrobras-CENPES (3) Fundação Gorceix

Copyright 2022, SBGf - Sociedade Brasileira de Geofísica.

Este texto foi preparado para a apresentação no IX Simpósio Brasileiro de Geofísica, Curitiba, 4 a 6 de outubro de 2022. Seu conteúdo foi revisado pelo Comitê Técnico do IX 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

O dado sísmico adquirido é inevitavelmente contaminado por vários tipos de ruídos, como por exemplo, o *swell noise*. A identificação destes ruídos nos dados sísmicos constitui uma tarefa onerosa visto que envolve o pré-processamento e processamento de um grande volume de dados. Para que sejam possíveis o imageamento e uma interpretação adequada, é necessário atenuar estes ruídos. Neste trabalho, técnicas de aprendizado profundo são utilizadas para a otimização do processo de identificação e classificação de um tipo de ruído muito comum em dados sísmicos marinhos, o *swell noise*. Foi criada, pelo Centro de Pesquisas Leopoldo Américo Miguez de Mello (CENPES) e pela gerência de gestão de dados geofísicos da Petrobras, uma ferramenta que utiliza uma rede neural artificial convolucional treinada para identificação e classificação dos traços sísmicos contaminados com *swell noise* em levantamentos sísmicos marinhos. Após a identificação e classificação dos traços sísmicos contaminados com o ruído, um filtro passa-banda é aplicado em cada traço onde o ruído é identificado. Essa nova abordagem que apresentamos é mais eficiente quando comparada com a abordagem clássica, visto que o volume de dados onde é aplicado o filtro é muito menor e o sinal presente nos traços não contaminados não é afetados durante a aplicação do filtro.

Introdução

A atividade de exploração de hidrocarbonetos envolve a aquisição e o processamento de um grande volume de dados sísmicos, e durante a etapa de processamento uma quantidade considerável de ruídos deve ser atenuada a fim de que a seção sísmica empilhada apresente a maior razão sinal-ruído possível (Yilmaz Doherty, 2001). Durante a aquisição sísmica marinha, um tipo de ruído muito comum registrado é o *swell noise*. Este ruído é caracterizado por conter altas amplitudes e está localizado na faixa de baixa frequência do sinal sísmico (Elboth et al., 2009). Apesar de possuir várias fontes, o *swell noise* está relacionado com os movimentos do navio e as oscilações das ondas do mar nos cabos de aquisição (*streamers*) e um número considerável de trabalhos tem apresentado métodos para atenuá-lo.

Com o aumento do volume de dados e do poder

computacional, os métodos de aprendizado de máquinas ganharam popularidade. Os métodos, que podem ser supervisionados ou não supervisionados, têm mostrado um grande potencial de aplicação na solução de problemas geofísicos. Almeida et al. (2019) aplicaram diferentes redes neurais artificiais para a identificação e classificação do ruído *swell*, Farmani Pedersen (2020) usaram uma rede neural convolucional U-net para atenuar o *swell noise* e You et al. (2020) usaram uma rede neural convolucional no domínio da frequência usando a transformada curta de Fourier para atenuar esse mesmo ruído. Já Jia et al. (2019) usaram uma rede neural convolucional para atenuar o ruído coerente terrestre *ground-roll*, nesse artigo os autores utilizaram a rede CNN (*Convolutional Neural Network*) para fazer uma separação entre o ruído coerente e as reflexões de interesse. Yuan et al. (2021) utilizaram uma rede neural convolucional com blocos assimétricos para atenuar eventos lineares em dados sísmicos de reflexão.

Uma grande quantidade de dados sísmicos de bacias sedimentares marítimas brasileiras é adquirida durante uma atividade de exploração. Esse imenso volume de dados vem contaminado com uma série de ruídos e um desses ruídos é o *swell*, que contamina o registro sísmico com altas amplitudes e baixas frequências. Os métodos convencionais para atenuação desse ruído envolvem a construção de filtros que operam no domínio da frequência, quando definida as zonas de corte, eles eliminam o evento indesejado e atenuam as reflexões de interesse. As técnicas que usam aprendizado de máquinas supervisionado tentam reconhecer o ruído através de um processo de rotulagem que envolve ensinar para a rede neural artificial as características do ruído e dos eventos de interesse que devem ser preservados. Nesse trabalho nós apresentamos uma abordagem híbrida para a atenuação do *swell noise* que identifica e classifica o ruído usando uma rede neural artificial convolucional (CNN) seguida de uma multicamada Perceptron (MLP) e por fim é realizada a filtragem utilizando um passa-banda nos traços contaminados identificados pela rede neural. Essa abordagem é mais eficiente quando comparada com a convencional que envolve a aplicação do filtro passa-banda em todo o dado sísmico, pois além de evitar o grande custo computacional envolvido no processo, a abordagem híbrida fornece uma maior razão sinal-ruído, pois o filtro passa-bandas adaptativo não é aplicado nas reflexões presentes nos traços sísmicos não-contaminados.

Arquitetura da Rede CNN

As redes neurais convolucionais são arquiteturas muito eficientes para problemas de reconhecimento de imagem. Quando treinadas por uma quantidade razoável de exemplos, essas redes tendem a aprender feições que se assemelham a filtros *Gabor* ou filtros de manchas de cor. Nas camadas intermediárias e finais, as combinações desses filtros extraem padrões complexos da imagem (Yosinski et al., 2015). Na Figura 1 temos uma arquitetura de uma rede CNN mostrando a sua camada de entrada, em seguida as suas camadas ocultas que envolvem camadas de características e camadas de *pooling*, e por fim, seguida por uma camada toda conectada para a classificação da imagem. A Figura 2 mostra um exemplo de como funciona o aprendizado de características da imagem nas camadas ocultas de uma rede CNN.

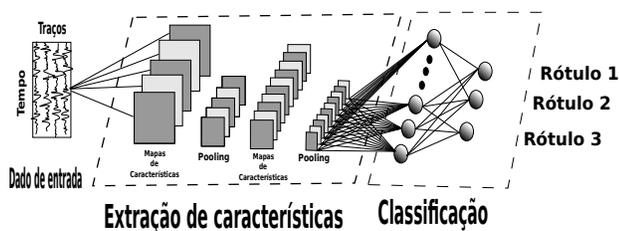


Figura 1 – Características da Rede Neural Convolucional.

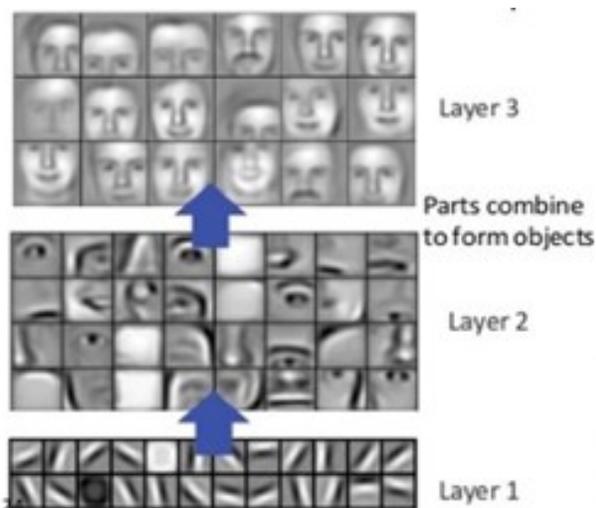


Figura 2 – Esquema ilustrativo mostrando como funciona o aprendizado de características nas camadas ocultas da rede neural convolucional artificial.

Fonte: *Understanding of a Convolutional Neural Network* (Saad Albawi and Tareq Abed Mohammed)

A rede criada para a identificação e classificação do *swell noise* foi uma rede CNN simples composta por 7 blocos convolucionais, 3 blocos lineares, e um bloco de saída, onde cada bloco convolucional é composto de uma

camada convolucional com N filtros 3x3, uma camada de batch normalization, uma camada de ativação *ReLU* e uma camada de *pooling*, que é um *MaxPool* de dimensões [2,1] em todas as camadas menos na última, onde é um *MaxPool* adaptativo. (N = [8, 8, 8, 16, 16, 24, 32]). Cada bloco linear é composto de uma camada *fully connected* (com respectivamente [32, 16, 8] neurônios em cada um dos três blocos), uma camada de ativação *ReLU* e uma camada de *dropout*. Já o bloco de saída é composto por apenas uma camada *fully connected* de 3 neurônios, um para cada uma das 3 classes de saída. A entrada da rede é composta por 11 traços, centrados no traço anotado (ou seja, uma matriz 11 x ns, onde ns é o número de amostras por traço), que alimenta a parte convolucional da rede. As camadas de *MaxPool* dos blocos reduzem a dimensão dos *feature maps*, mantendo a primeira dimensão igual a 11 e reduzindo a segunda pela metade a cada bloco. O bloco convolucional final aplica um *pooling adaptativo*, transformando cada *pooling adaptativo* para um único número, esses 32 números, um para cada camada, compõem a entrada da rede *fully connected*, que funciona como um MLP com 3 saídas, que podem ser comparadas às probabilidades do traço

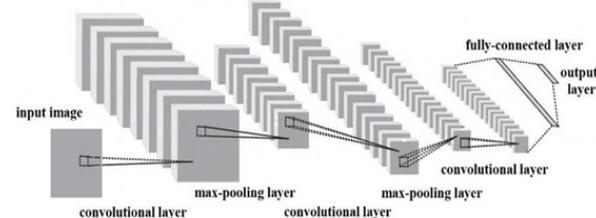


Figura 3 – Imagem ilustrativa da arquitetura da rede neural convolucional artificial seguida de rede multicamada perceptron usada para identificação e classificação do *swell noise*.

Treinamento da Rede CNN

A etapa de treinamento da rede se deu com a entrada de aproximadamente 21.7 milhões de matrizes, cada uma das quais é classificada como "limpo", "ruído fraco" e "ruído forte", conforme uma classificação automática aplicada em seu traço central. Onde 30% desses dados de entrada foram separados para validação, e os 70% restantes foram utilizados para o treinamento da rede.

Resultados

A Figura 4 mostra uma comparação entre a filtragem passa-banda clássica aplicada em todos os traços e o mesmo tipo de filtragem aplicada somente nos traços contaminados com o ruído *swell*. Na Figura 4(a) é mostrada a seção de tiro comum original sem aplicação de filtros, nessa seção nós podemos ver o ruído *swell* contaminando os traços sísmicos com diferentes intensidades, na Figura 4(b) é apresentada a mesma família de tiro comum após a filtragem passa-banda clássica com um trapézio de frequência de f1=2 Hz, f2=12 Hz, f3=100 Hz e f4=110 Hz para todos os traços e finalmente a Figura 4(c) apresenta o resultado da aplicação do filtro passa-bandas somente nos traços

classificado com o *swell noise*, uma vez que cada traço foi classificado com diferentes intensidades do ruído, uma diferente abertura do filtro foi aplicada, sendo $f1=2$ Hz, $f2=8$ Hz, $f3=100$ Hz e $f4=110$ Hz para o *swell* fraco e $f1=2$ Hz, $f2=12$ Hz, $f3=100$ Hz e $f4=110$ Hz para o *swell* forte.

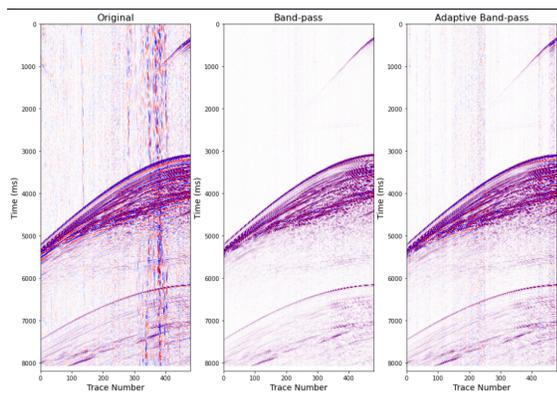


Figura 4 – Da esquerda para a direita temos a seção sísmica original, seção sísmica com passa banda, e por último a seção sísmica com filtro apenas nos dados identificados *swell*

A Tabela 1 mostra uma comparação do tempo computacional da aplicação para um dado sísmico relativamente grande da aplicação do filtro passa-banda para o dado completo e à aplicação do filtro passa-banda somente nos traços identificados pela ferramenta com o ruído. Notamos um ganho no tempo computacional da abordagem que apresentamos quando comparada com a abordagem clássica.

| Dado | Tamanho | Completo | Adaptativo |
|--------------|---------|----------|------------|
| Arquivo1.sgy | 15GB | 00:11:19 | 00:01:27 |
| Arquivo2.sgy | 64GB | 00:24:03 | 00:13:24 |
| Arquivo3.sgy | 100GB | 01:10:49 | 00:18:17 |

Tabela 1 – Comparação do tempo de duração quando aplicado o filtro passa-banda completo e o adaptativo.

A Figura 5 mostra a comparação dos espectros de magnitude das 3 seções da família de tiro comum. Podemos notar que a aplicação do filtro somente nos traços contaminados com o *swell noise* preserva melhor as amplitudes na banda do sinal, o que pode proporcionar uma melhor razão sinal-ruído na seção sísmica empilhada.

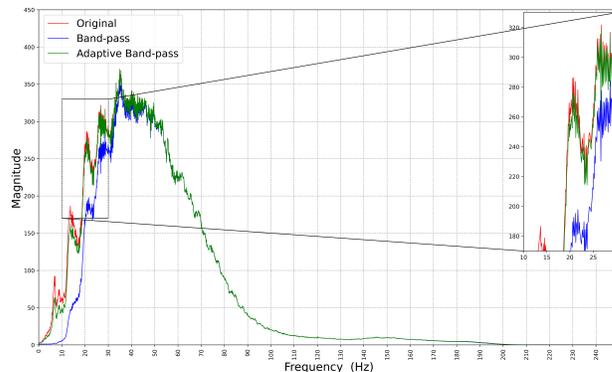


Figura 5 – Espectro de magnitude do dado original em vermelho, do dado filtrado com o passa banda clássico em azul e em verde o dado com a aplicação de passa banda nos traços classificados.

A figura 6 mostra a comparação dos resíduos da filtragem passa-bandas clássico e o passa-bandas adaptativo. É fácil de ver que apesar da limitação do filtro clássico passa-bandas a abordagem adaptativa que aplica o filtro somente nos traços classificados pela rede neural preserva muito mais as amplitudes do sinal sísmico.

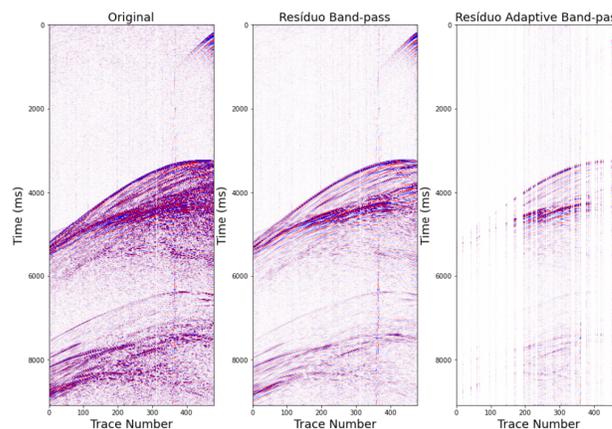


Figura 6 – Seção de tiro comum do dado original e seus resíduo aplicado o passa banda tradicional e o passa banda adaptativo.

Finalmente, a Figura 7 mostra a mesma comparação dos métodos no espectro de amplitudes do sinal sísmico. As amplitudes são muito mais preservadas usando a abordagem adaptativa que apresentamos.

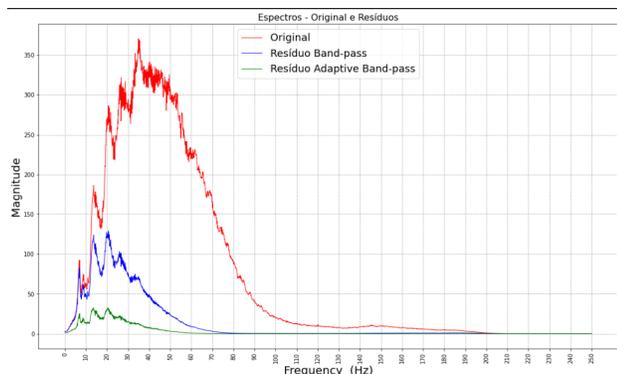


Figura 7 – Espectro de magnitude do dado original em vermelho, do resíduo com o passa banda clássico em azul e em verde o resíduo com a aplicação de passa banda nos traços classificados.

Conclusões

O método que apresentamos se mostrou bastante eficiente na identificação e atenuação do *swell noise*, assim como na metodologia de um filtro de frequências que por ser aplicado somente nos traços contaminados com o ruído preservam as amplitudes das baixas frequências dos traços sísmicos onde a ferramenta identificou a presença do evento indesejado. Um dos principais ganhos dessa metodologia que apresentamos é ganho no tempo computacional, visto que a aplicação do filtro somente nos traços que foram classificados com o ruído evita aplicação do filtro em um grande volume de dados, que para o caso apresentado nesse trabalho evita a aplicação de transformadas de Fourier e funções de transferências em traços não contaminados. A aplicação do filtro somente nos traços contaminados com o *swell noise* preservou melhor as amplitudes na banda do sinal na família de tiro comum, o que pode proporcionar uma melhor razão sinal-ruído na seção sísmica empilhada. O objetivo foi mostrar que mesmo aplicando um método convencional como a filtragem passa-banda, boa parte da banda do sinal pode ser preservada e nada impede que a aplicação de filtros mais eficientes possa ser acrescentada usando essa nova metodologia.

Agradecimentos

Os autores agradecem a Petrobras e a Fundação Gorceix pela permissão e incentivo para publicar esse trabalho. Os autores também agradecem pelo apoio e suporte de Valério C. L. Dutra, Jéferson S. da Rocha e Gabriel S. Lana da TIC/OI/SSH/SAD Petrobras.

Referências

Almeida, I.N., Vargas, M., Neto, C.S., Nobre, L., Silva, B., Bulcão, A., Dias, B.P., Landau, L., Evsukoff, A., 2019. Machine learning applied in swell noise classification, Rio de Janeiro, Brasil.

Elboth, T., Geoteam, F. Hermansen, D., 2009. Attenuation of noise in marine seismic data, in: 2009 SEG Annual Meeting, OnePetro, Houston, EUA.

Farmani, B. Pedersen, M. W., 2020. Application of a convolutional neural network to classification of swell noise attenuation, in: SEG Technical Program Expanded Abstracts 2020, Society of Exploration Geophysicists, 2868–2872.

Jia, Z., Lu, W., Zhang, M. Miao, Y., 2019. Separating ground-roll from land seismic record via convolutional neural network, in: SEG 2018 Workshop: SEG Maximizing Asset Value Through Artificial Intelligence and Machine Learning, Beijing, China, 17-19 September 2018, Society of Exploration Geophysicists and the Chinese Geophysical Society, 60–63.

Yilmaz, O. Doherty, S., 2001. Seismic data analysis: Processing, Inversion, and Interpretation of Seismic data, vol. 2.

Yosinski, J., Clune, J., Nguyen, A., Fuchs, T. Lipson, H., 2015. Understanding neural networks through deep visualization, arXiv preprint arXiv:1506.06579.

You, J., Xue, Y., Cao, J. Li, C., 2020. Attenuation of seismic swell noise using convolutional neural networks in frequency domain and transfer learning, Society of Exploration Geophysicists and American Association of Petroleum, vol. 8, T941–T952.

Yuan, Y., Zheng, Y. Si, X., 2021. Attenuation of linear noise based on denoising convolutional neural network with asymmetric convolution blocks, Exploration Geophysics: 1–15.