

Análise de Arquiteturas de Redes Neurais Para Segmentação Semântica de Dados Sísmicos

Gabriel Silva, João Dias e Luciana Falleti

Resumo— Com o avanço da tecnologia, a caracterização dos reservatórios petrolíferos tem se tornado mais precisa e com isso aumentado sua complexidade, principalmente, com a obtenção de dados sísmicos em 3D. Nesse artigo são apresentadas duas arquiteturas de rede neural profunda aplicadas a segmentação semântica de imagens sísmicas. São usadas apenas 100 imagens para treinamento da rede. Com a proposta de utilizar clusterização e o filtro *CLAHE* na arquitetura U-Net, foi possível aumentar seu desempenho e alcançar 99,37% de precisão superando com isso o estado-da-arte obtido pela arquitetura Danet-FCN3 que havia alcançado uma precisão de 98,13%.

Palavras-Chave— U-Net, Danet-FCN3, Segmentação Semântica.

Abstract— With the advancement of technology, the characterization of oil reservoirs has become more accurate and with that its complexity has increased, mainly with the acquisition of 3D seismic data. In this article, two deep neural network architectures applied to semantic segmentation of seismic images are presented. Only 100 images are used for training the network. With the proposal to use clustering and CLAHE filter in the U-Net architecture, it was possible to increase its performance and reach 99.37% of accuracy, thus surpassing the state-of-the-art obtained by the Danet-FCN3 architecture, which had reached an accuracy of 98.13%.

Keywords— U-Net, Danet-FCN3, Semantic Segmentation.

I. INTRODUÇÃO

Os dados sísmicos podem ser adquiridos de diversas formas, o método mais comumente utilizado é o método de reflexão, que consiste em um conjunto de vários tiros sísmicos realizados em diferentes pontos (latitude e longitude) utilizando as coordenadas Universal Transversa de Mercator (UTM) e a reflexão é captada na superfície por hidrofones ou geofones [1].

Como as ondas são adquiridas de maneira indireta, possuem uma grande quantidade de ruído, como os ruídos produzidos pelas marés e pelos ventos, dificultando a interpretação. [1]. A reconstrução de um dado sísmico é um enorme desafio, mesmo com o avanço tecnológico na aquisição e processamento de dados. Com isso, cada vez mais a inteligência artificial possui um papel importante para o processamento desses dados [2].

Os geocientistas das indústrias de petróleo e gás trabalham analisando dados sísmicos para encontrar reservatórios de petróleo ou gás natural e já estão acostumados a trabalhar utilizando uma grande quantidade de dados, entretanto, para poder desfrutar do total potencial desses dados é necessário que as classes (*labels*) do banco de dados sejam muito bem definidas e que possuam uma boa qualidade, para que se possa utilizar as técnicas de aprendizagem profunda [3].

Um estudo foi publicado sobre a classificação das fácies sísmicas e como se pode dividi-las para a melhor compreensão

por uma rede neural [4]. Também foi mostrado que é possível utilizar transferência de aprendizado (*transfer learning*) para acelerar e melhorar o treinamento das redes [5]. E como trabalho posterior, conseguiram aplicar essas técnicas para a realização da segmentação semântica das camadas rochosas [6]. Em [7] foi proposto uma melhoria na rede U-Net utilizando *dilated attention* e diminuindo os parâmetros da rede e melhorando o resultado da mesma.

Entretanto, em todos os artigos citados acima falta informação sobre os ajustes dos hiper-parâmetros, tais como, o otimizador utilizado, a taxa de aprendizagem, etc.

Nesse artigo foi proposta uma arquitetura para otimizar o desempenho da rede U-net para realizar a segmentação semântica em dados sísmicos. Com isso, foi possível superar o estado-da-arte obtido pela arquitetura Danet-FCN3 [8].

Este trabalho está organizado da seguinte forma: as arquiteturas de segmentação semântica são apresentadas na seção II; na seção III são descritas as informações geológicas; na seção IV são descritas as preparações dos bancos de dados; na seção V são feitas os experimentos e na seção VI, as conclusões.

II. ARQUITETURAS DE SEGMENTAÇÃO SEMÂNTICA

Nesta sessão serão descritas as duas arquiteturas de rede neural utilizadas para a realização dos testes, que são as arquiteturas U-Net e Danet-FCN3 aplicadas para a segmentação de dados sísmicos.

A. U-Net

Pode-se definir a arquitetura U-Net como uma versão estendida das redes totalmente convolucionais (FCN), de forma a proporcionar segmentações mais precisas com conjuntos de treinos pequenos. A principal diferença em relação à FCN se faz nas camadas de *decoders*, onde há um número grande de mapas de características, tendo como consequência uma simetria em relação às camadas de *encoders*. Assim, tomando um formato de "U", como mostra a Figura 1. A forma adotada para aumentar o número de mapas de características nos *decoders* é concatenar a saída de uma camada de *unpooling* com a saída da camada de convolução dos *encoders* correspondente [9]. Desta forma, a rede aprende o conteúdo da informação da imagem e onde este conteúdo está localizado na imagem.

A U-Net consiste na aplicação repetida de duas convoluções 3x3 cada uma seguida por uma unidade linear retificada (ReLU) e uma operação de max pooling 2x2 com stride 2 para downsampling. Em cada etapa de downsampling, é dobrado o número de canais de características. Cada passo no caminho expansivo consiste em um upsampling do mapa de características seguido por uma convolução 2x2 (up-convolution) que

reduz pela metade o número de canais de características, uma concatenação com o mapa de características correspondentemente recortado do path de contração e duas convoluções 3x3, cada uma seguida por uma ReLU. O recorte é necessário devido à perda de pixels de borda em cada convolução. Na camada final, uma convolução 1x1 é usada para mapear cada vetor de características de 64 componentes para o número desejado de classes.

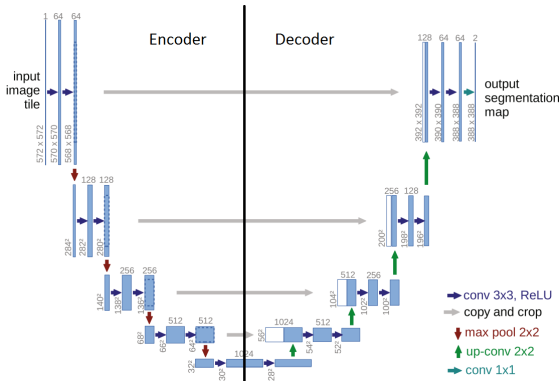


Fig. 1. Funcionamento de arquitetura U-Net, separando o *encoder* do *decoder* [9].

Em relação à tarefa de segmentação, é necessário que a rede neural seja capaz de combinar a informação da localização com a informação contextual dos mapas de características da imagem a ser predita. A arquitetura U-Net é capaz de juntar as informações contextuais obtidas do caminho de contração (*encoder*) com as informações de localização adquiridas do caminho de expansão (*decoder*) com um bom desempenho [9]. Entretanto, para melhorar o desempenho da arquitetura U-Net foi utilizado um pré-processamento nas imagens, que será descrito na seção IV.

B. Danet-FCN3

A arquitetura Danet-FCN3 foi baseada na topologia VGG-FCN, onde os autores conseguiram converter uma camada totalmente conectada no final da rede em convoluções de 1x1. Essa arquitetura utiliza blocos residuais para extrair as características, que seria o *encoder* e uma unidade transposta da mesma estrutura para recriar a imagem original com todas as suas *labels*, que seria o *decoder* [10].

A Figura 2 mostra todas as camadas da arquitetura Danet-FCN3. Onde o *S* é o *stride*, *#CH* é o número de canais (filtros) utilizado em todas as operações dentro do bloco. Assim, a primeira entrada C5 S2 64, significa uma convolução com 64 filtros de tamanho 5x5 e *stride* de 2.

Res e Rest são compostos por 3 blocos de unidade residual e unidade residual transposta, respectivamente. O bloco Res possui uma unidade residual com *stride* igual a 2, seguido de duas unidades residuais com o *stride* igual a 1. O bloco Rest possui duas unidades residuais transpostas com *stride* igual a 1, seguido de uma unidade residual transposta com o *stride* igual a 2.

Ru e Rut são as unidades residual e residual transposta, respectivamente, como é mostrado na Figura 3. Cada




Fig. 2. Topologia do modelo Danet-FCN3. Na direita está a descrição de cada bloco [10].

unidade residual é composta de uma convolução seguida do *Batch Normalization* (Conv+BN), ativação ReLU e Conv+BN somado a entrada (*Shortcut*) e uma ativação ReLU. A unidade residual transposta segue a mesma arquitetura, porém, com a convolução transposta. Os parâmetros utilizados podem ser encontrados em [11].

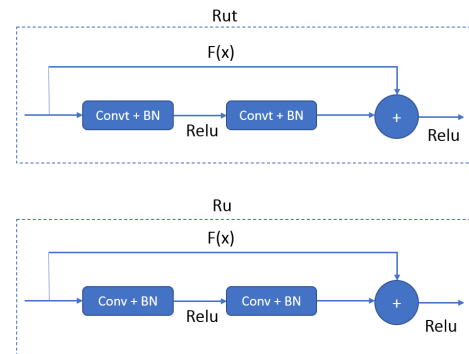


Fig. 3. O bloco Ru é a unidade residual e o bloco Rut é a unidade residual transposta [10].

III. INFORMAÇÕES GEOLÓGICAS

O banco de dados Mar do Norte da Holanda F3, é um levantamento sísmico de aproximadamente 384 km², é um banco de dados público na Bacia de Graben, situada a 180 km da costa da Holanda, que pode ser acessado no repositório [12].

A imagem sísmica na Figura 4 mostra que os cortes *inlines* são perpendiculares ao eixo *inline* e os *crosslines* são as imagens ao longo da profundidade do eixo perpendicular *crossline*. O banco de dados sem pré-tratamento possui 1602 cortes, nesses 384 km² de extensão, existem 651 *inlines* e 951 *crosslines*. Os *inlines* possuem uma dimensão de 951 x 462 e os *crosslines* 651 x 462. Dentre as imagens do banco, foram removidas as imagens de baixa qualidade ou danificadas, para não atrapalhar a aprendizagem da rede. As imagens *inlines*

e *crosslines* possuem suas *labels* já fornecidas pelo autor do banco de dados.




Fig. 4. Exemplo de *inlines* e *crosslines* em um bloco sísmico 3D.

Na Figura 5 pode-se ver uma foto de um *inline* de um bloco sísmico 3D separado pelas classes.




Fig. 5. Em (A) mostra a imagem original e em (B) mostra a imagem com as 10 classes separadas.

Os geólogos identificaram 9 interfaces no banco de dados, o número cresce de acordo com a profundidade indo de H1 até H9. As fácies sísmicas podem ser descritas como: - Classe 1: Oceano; - Classe 2: A camada refletiva superior é uma face sísmica em camadas, e a camada refletiva inferior é uma face sísmica homogênea; - Classe 3: As fácies sísmicas consistem em refletores de baixa amplitude e emissores contínuos, e estão principalmente associadas a ambientes neríticos dominados por depósitos de argila; - Classe 4: Os refletores exibem principalmente características em forma de montículos descontínuos; - Classe 5: Os refletores são predominantemente subparalelos e apresentam amplitudes variáveis; - Classe 6: Os refletores têm uma configuração progradacional sigmóide de baixa energia e amplitude de média a baixa; - Classe 7: As fácies sísmicas entre H6 e H5 consistem principalmente em refletores paralelos de alta amplitude; - Classe 8: Essas fácies apresentam reflexos semicontínuos e de baixa amplitude, o que dificulta sua identificação; - Classe 9: Este intervalo apresenta fácies contorcidas a montículos e de baixa amplitude; - Classe 10: As fácies entre H9 e H8 são ruidosas, possivelmente devido a ruído de aquisição ou falha de processamento sísmico.

IV. PREPARAÇÃO DOS BANCOS DE DADOS

Como levantado em [13] e [14], pode-se identificar diferentes tipos de substratos utilizando as características das texturas das imagens sísmicas. Com isso, pode-se automatizar o processo utilizando um modelo de rede neural para que se consiga distinguir as texturas nas imagens sísmicas.

O primeiro passo foi utilizar um filtro na imagem, o *Contrast Limited Adaptive Histogram Equalization* (*CLAHE*), para aumentar o contraste dos pixels da imagem. Onde esse filtro é uma modificação do *Adaptive Histogram Equalization* (*AHE*).

O filtro *CLAHE*, pode ser descrito da seguinte maneira: 1 - Aquisição da imagem 2- Aquisição dos valores de entrada, como número de regiões, limite de corte, tipo de parâmetros de distribuição. 3 - A imagem original é dividida em algumas regiões (*tiles*). 4 - O processo é aplicado em todos *tiles*. 5 - Um mapa de nível de cinza é gerado e o histograma é cortado. Os níveis de cinza são divididos igualmente em cada nível de cinza, o número médio de pixels de nível de cinza é descrito de acordo com a Equação 1 [15].

$$N_{media} = (N_{CR} - X_p * N_{CR-Y_p}) / N_{cinza} \quad (1)$$

Onde, N_{media} = média do número de pixels. N_{cinza} = número de níveis de cinza em um *tile*. $N_{CR} - X_p$ = Número de pixels na direção X nos *tiles*. N_{CR-Y_p} = Número de pixels na direção Y nos *tiles*. 6 - Interpolação do mapeamento do nível de cinza para criar uma imagem aprimorada. Como resultado, os detalhes mais importantes destacados das imagens sísmicas que são as interfaces, com mais nitidez, como mostra a Figura 6.




Fig. 6. Em (A) mostra a imagem original e em (B) mostra a imagem utilizando o filtro *CLAHE* e redimensionamento.

As imagens originais possuem um nível de cor de cinza entre [-30.000 , 33.000]. Com isso, foi necessário reescalar os valores em um padrão de 8 bits inteiros, pois essa etapa faz com que amplitudes extremas sejam desconsideradas, melhorando assim a representação das imagens do banco de dados. No intervalo de 0 a 255 é ajustado para todas as 10 classes para o treinamento. A Figura 5 mostra a imagem de 8 bits e a respectiva máscara com as 10 classificações.

Para trabalhar com as imagens do banco de dados é necessário subdividi-las em pequenos *tiles*, que é um processo amplamente utilizado como em [13] e [14], pois quando se utiliza imagens grandes em entradas de redes neurais o modelo se torna muito custoso e complexo computacionalmente. Com isso, foi escolhido trabalhar com *tiles* de 128x128 a partir das imagens ampliadas de 1024x512.

Para balancear o banco de dados de treinamento foi escolhido balancear o número de amostras por classes, assim, facilitando as métricas utilizadas para medir o desempenho da rede, como Precisão ou *mIoU*.

O *mIoU* que é a Média da razão entre a área da intercessão e da área da união das classes de uma única imagem. Dentro do contexto de segmentação de imagens o *mIoU* é calculado com saída da rede convolucional e a máscara utilizada para

treino. O $mmIoU$ é a média dentre as imagens de teste. $mmIoU Max$ e $mmIoU Min$ são as médias das imagens de teste com $mmIoU$ máxima e mínima no banco de dados respectivamente. Para manter o padrão de imagens de teste como no artigo [8], foram utilizadas 100 imagens sísmicas, que gerou 3200 *tiles*, onde 70% foi utilizado para treinamento da rede e 30% para validação.

A. Cluster

A arquitetura Danet-FCN3 é mais complexa que a U-Net em situações em que o banco de dados de treino é reduzido, a arquitetura Danet-FCN3 possuiu melhor performance que a U-Net, isto é, um $mmIoU$ superior [8]. dado a menor complexidade da U-Net seu uso torna-se atrativo, assim visando melhorar o desempenho dessa rede é proposto um pré-processamento, baseado no filtro *CLAHE* e na clusterização das imagens sísmicas. A Figura 7 mostra o diagrama de pré-processamento para cada arquitetura de rede utilizada.

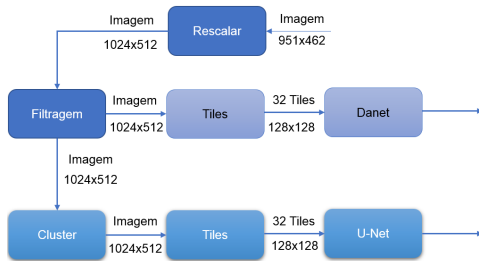


Fig. 7. Diagrama em blocos do pré-processamento utilizado.

O método de clusterização utilizado foi o $K - Means$, que é a técnica de clusterização mais simples, que normalmente está disponível em quase todos *softwares* de interpretação sísmica. Esse método visa organizar um espaço dado, N , em K *clusters*. O processo de clusterização começa com a atribuição aleatória de k centroides que podem servir como centros dos grupos que desejamos formar, onde cada centróide define um *cluster*. Em seguida, é calculada a distância entre cada ponto de dados ao centróide desse *cluster*. Um ponto estará dentro de um *cluster* se estiver mais próximo da centróide desse *cluster* do que qualquer outra centróide. Logo após esse primeiro passo, como alguma reorganização dos pontos em diferentes *clusters* ocorreu, os centróides são recalculados para cada *cluster*. Este algoritmo visa minimizar uma função objetivo, neste caso uma função de erro quadrado como mostra a Equação 2.

$$J = \sum_{j=1}^k \sum_{i=1}^n \|X_i^{(j)} - c_j\| \quad (2)$$

Onde $\|X_i^{(j)} - c_j\|$ é uma distância entre cada ponto de dado $X_i^{(j)}$ e o centro do *cluster* c_j , ou seja, é um indicador da distância dos N pontos de dados de seus respectivos centroides do *cluster* [16]. Com isso, a imagem sísmica fica dividida em 10 classes de acordo com o nível de intensidade dos pixels, reduzindo a quantidade de informação na imagem, assim, facilitando o treinamento da rede.

V. EXPERIMENTOS

Para a classificação das camadas rochosa, existem diversas abordagens utilizando aprendizagem profunda, como por exemplo em [17] e [18]. Em ambos os artigos os autores conseguiram classificar cada camada utilizando o banco de dados da Holanda [12].

Existem algumas abordagens para melhorar o desempenho de redes neurais quando treinadas com poucas imagens, que é a utilização de *data augmentation*. Uma dessas técnicas é o uso da janela deslizante nos *tiles*, gerando novos *tiles* a partir das interseção dos *tiles* existentes. Foi investigado o uso dessa técnica, porém, em ambas as arquiteturas houve uma piora de desempenho.

Para a realização dos treinamentos, foi escolhido utilizar um *Batch Size* de 128 com o número de épocas de 500. O otimizador utilizado foi o *RMSprop* por apresentar um ótimo desempenho, com a função de perda *Cross Entropy* e modos de peso temporal. Esses parâmetros foram escolhidos após a realização de diversos testes e mostraram melhor desempenho.

A arquitetura Danet-FCN3 é treinada com as imagens sem o pré-processamento, a arquitetura da U-Net utiliza um pré-processamento. A Figura 8 e Figura 9 mostram o histórico de treino da rede U-net e Danet-FCN3 respectivamente, observa-se que o treino da Danet-FCN3 possui uma maior demora para convergência, necessitando mais épocas de treinamento do que a U-net. Além disso, a arquitetura Danet-FCN3 possui fortes oscilações na precisão de validação.




Fig. 8. Histórico das épocas de treinamento da arquitetura U-Net.




Fig. 9. Histórico das épocas de treinamento da arquitetura Danet-FCN3.

A Tabela I mostra os resultados dos treinos da Danet-FCN3 e U-Net. O uso da clusterização e o filtro *CLAHE* como pré-processamento das imagens foi benéfico para a rede U-Net de forma a igualar o desempenho das 2 redes.

TABELA I

AVALIAÇÃO DO DESEMPENHO DA ARQUITETURA U-NET E DANET-FCN3

	U-Net	Danet-FCN3	U-Net+CLAHE+Cluster
Imagens	100	100	100
Precisão	99,10%	98,13%	99,37%
mIoU	86,9%	88,7%	90,09%
mmIoU	73,28%	76,74%	81,44%
mmIoU Max	74,54%	78,64%	82,41%
mmIoU Min	64,55%	66,17%	79,25%

Existem diversas formas para se medir o desempenho de uma rede convolucional, como por exemplo: Precisão, mIoU, mmIoU, mmIoU Max, mmIoU Min. A precisão consiste na proporção de avaliações corretas dentre as respostas do sistema apontando uma dada classe.

Notou-se que os erros apresentados na arquitetura Danet-FCN3 se concentraram no canto inferior esquerdo das imagens, enquanto os erros da U-Net concentraram-se nas primeiras camadas H0, H1 e H2. É necessário um estudo mais aprofundado para investigar a razão desses erros. A razão mais provável que isso ocorreu é devido ao tamanho dos *tiles*, como a camada é muito fina, os *tiles* acabam não possuindo apenas 1 classe por *tile*, assim, dificultando o treinamento da rede.

A Figuras 10 e a Figura 11 são as máscaras criadas após treinamento das redes. Mesmo utilizando poucas imagens para o treinamento das redes, o desempenho pode ser considerado bom, ainda que com algumas falhas na classificação dos *tiles*, é possível distinguir todas as 10 classes da imagem sísmica.




Fig. 10. Máscara criada a partir da arquitetura Danet-FCN3.




Fig. 11. Máscara criada a partir da arquitetura U-Net+CLAHE+Cluster.

VI. CONCLUSÕES

Nesse artigo foi visto como a interpretação de imagens sísmicas são tarefas árduas e que exigem um alto custo computacional. Entretanto, a aprendizagem profunda junto com a segmentação de imagens vem ajudando demasiadamente essa área, com técnicas cada vez mais parecidas com a percepção humana. Utilizando a clusterização e o filtro *CLAHE* a U-Net alcançou 99,37% de precisão superando a Danet-FCN3 que alcançou uma precisão de 98,13%. Para trabalhos futuros é desejável utilizar as mesmas técnicas empregada a U-Net

em novos bancos de dados para avaliar o desempenho da arquitetura. Variar o tamanho dos *tiles* para achar o tamanho ótimo para a realização do treinamento e Utilizar o mesmo processo de filtro e clusterização em outras arquiteturas para averiguar se há ganho de desempenho.

AGRADECIMENTOS

Agradecemos ao Cefet/RJ, a Faperj e ao CNPq pelo financiamento parcial do projeto que deu origem a esse trabalho.

REFERÊNCIAS

- [1] Josenilda do Nascimento Lonardelli, Augustinho Rigoti, Sidnei Pires Rostrolla, and Ciro Jorge Appi. Levantamento sísmico de reflexão rasa: um estudo dos arenitos vila velha no estado do paran , brasil. *Boletim Paranaense de Geoci ncias*, 58, 2006.
- [2] Chris Carpenter. Artificial intelligence improves seismic-image reconstruction. *Journal of Petroleum Technology*, 71(10):65–66, 2019.
- [3] Rafael C Gonzalez. *Digital image processing*. Pearson education india, 2009.
- [4] Daniel Salles Chevitarese, Daniela Szwarcman, RM Gama e Silva, and E Vital Brazil. Deep learning applied to seismic facies classification: A methodology for training. In *Saint Petersburg 2018*, volume 2018, pages 1–5. European Association of Geoscientists & Engineers, 2018.
- [5] Daniel Chevitarese, Daniela Szwarcman, Reinaldo Mozart D Silva, and Emilio Vital Brazil. Transfer learning applied to seismic images classification. *AAPG Annual and Exhibition*, 2018.
- [6] Daniel Chevitarese, Daniela Szwarcman, Reinaldo Mozart D Silva, and Emilio Vital Brazil. Seismic facies segmentation using deep learning. *AAPG Annual and Exhibition*, 2018.
- [7] Zengyan Wang, Fangyu Li, Thiab R Taha, and Hamid R Arabnia. Improved automating seismic facies analysis using deep dilated attention autoencoders. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, pages 0–0, 2019.
- [8] Daniel Civitarese, Daniela Szwarcman, Emilio Vital Brazil, and Bianca Zadrozny. Semantic segmentation of seismic images. *arXiv preprint arXiv:1905.04307*, 2019.
- [9] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, pages 234–241. Springer, 2015.
- [10] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3431–3440, 2015.
- [11] Daniel Salles Chevitarese, Daniela Szwarcman, Emilio Vital Brazil, and Bianca Zadrozny. Efficient classification of seismic textures. In *2018 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8. IEEE, 2018.
- [12] Project f3 demo 2020, the netherlands, offshore, north sea. <https://terrannubis.com/datainfo/F3-Demo-2020>. Accessed: 2022-06-08.
- [13] Andrea Britto Mattos, Rodrigo S Ferreira, Reinaldo M Da Gama e Silva, Mateus Riva, and Emilio Vital Brazil. Assessing texture descriptors for seismic image retrieval. In *2017 30th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, pages 292–299. IEEE, 2017.
- [14] Satinder Chopra and Vladimir Alexeev. Applications of texture attribute analysis to 3d seismic data. *The Leading Edge*, 25(8):934–940, 2006.
- [15] Gyu-Hee Park, Hwa-Hyun Cho, and Myung-Ryul Choi. A contrast enhancement method using dynamic range separate histogram equalization. *IEEE Transactions on Consumer Electronics*, 54(4):1981–1987, 2008.
- [16] Motaz Alfarraj and Ghassan AlRegib. Semi-supervised learning for acoustic impedance inversion. In *SEG Technical Program Expanded Abstracts 2019*, pages 2298–2302. Society of Exploration Geophysicists, 2019.
- [17] Daniel Salles Chevitarese, Daniela Szwarcman, Emilio Vital Brazil, and Bianca Zadrozny. Efficient classification of seismic textures. In *2018 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8. IEEE, 2018.
- [18] Daniel Salles Chevitarese, Daniela Szwarcman, RM Gama e Silva, and E Vital Brazil. Deep learning applied to seismic facies classification: A methodology for training. In *Saint Petersburg 2018*, volume 2018, pages 1–5. European Association of Geoscientists & Engineers, 2018.