

**UNIVERSIDADE FEDERAL FLUMINENSE**  
**INSTITUTO DE GEOCIÊNCIAS**  
**PROGRAMA DE PÓS GRADUAÇÃO EM DINÂMICA DOS**  
**OCEANOS E DA TERRA**

**JOÃO BRUNO FERREIRA ALVES CUNHA**

**APRIMORAMENTO DOS DADOS DE SÍSMICA DE ALTA  
RESOLUÇÃO DA BACIA DE BRANSFIELD  
(ANTÁRTICA) UTILIZANDO APRENDIZADO DE  
MÁQUINA PROFUNDO (DEEP LEARNING)**

**Niterói-RJ,**

**2020**

JOÃO BRUNO FERREIRA ALVES CUNHA

**APRIMORAMENTO DOS DADOS DE SÍSMICA DE ALTA-  
RESOLUÇÃO DA BACIA DE BRANSFIELD (ANTÁRTICA)  
UTILIZANDO APRENDIZADO DE MÁQUINA PROFUNDO (DEEP-  
LEARNING)**

Tese de Doutorado apresentada ao  
Programa de Pós-Graduação em  
Dinâmica dos Oceanos e da Terra da  
Universidade Federal Fluminense,  
como parte dos requisitos necessários à  
obtenção do título de Doutor em  
Geofísica. Área de concentração:  
Geociências.

**Orientador: Prof. Dr. Arthur Ayres Neto**

Niterói-RJ,

2020

Ficha catalográfica automática - SDC/BIG  
Gerada com informações fornecidas pelo autor

C972a Cunha, João Bruno  
APRIMORAMENTO DOS DADOS DE SÍSMICA DE ALTA RESOLUÇÃO DA  
BACIA DE BRANSFIELD (ANTÁRTICA) UTILIZANDO APRENDIZADO DE  
MÁQUINA PROFUNDO (DEEP-LEARNING) / João Bruno Cunha ; Arthur  
Ayres Neto, orientador ; Climent Nadeu, coorientador.  
Niterói, 2020.  
119 f. : il.

Tese (doutorado)-Universidade Federal Fluminense, Niterói,  
2020.

DOI: <http://dx.doi.org/10.22409/PPGDOT.2020.d.09494450701>

1. Aprendizado de máquina. 2. Atributo sísmico. 3.  
Inversão sísmica. 4. Geofísica marinha. 5. Produção  
intelectual. I. Ayres Neto, Arthur, orientador. II. Nadeu,  
Climent, coorientador. III. Universidade Federal Fluminense.  
Instituto de Geociências. IV. Título.

CDD -

Bibliotecária responsável: Yolle Vacariuc Bittencourt - CRB7/6040

JOÃO BRUNO FERREIRA ALVES CUNHA

**APRIMORAMENTO DOS DADOS DE SÍSMICA DE ALTA-  
RESOLUÇÃO DA BACIA DE BRANSFIELD (ANTÁRTICA)  
UTILIZANDO APRENDIZADO DE MÁQUINA PROFUNDO (DEEP-  
LEARNING)**

Tese de Doutorado apresentada ao  
Programa de Pós-Graduação em  
Dinâmica dos Oceanos e da Terra da  
Universidade Federal Fluminense,  
como parte dos requisitos necessários à  
obtenção do título de Doutor em  
Geofísica. Área de concentração:  
Geociências, Geofísica Aplicada.

Aprovada em 30 de março de 2020

BANCA EXAMINADORA

---



Prof. Dr. Arthur Ayres Neto  
Universidade Federal Fluminense

---



Prof. Dr. Cleverson Guizan Silva  
Universidade Federal Fluminense

---



Prof. Dr. Wagner Moreira Lupinacci  
Universidade Federal Fluminense

---



Prof. Dr. Cosme Ferreira da Ponte-Neto  
Observatório Nacional

À minha esposa Natacha e meu filho  
Caetano.

## **AGRADECIMENTOS**

Agradeço ao Estado Brasileiro pela minha formação gratuita e de qualidade, através do CEFET de 1997 a 2000 e aqui na Universidade Federal Fluminense desde 2002. Foi um prazer retribuir o investimento feito gerando riquezas para o Brasil através de sua petroleira de 2012 a 2019.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES), a qual gostaria de agradecer pelo investimento na forma do PDSE (Programa de Doutorado-Sanduíche no Exterior) o qual me permitiu conhecer a pesquisa realizada no exterior e ter a satisfação de saber que estamos nivelados em qualidade a ela, além do privilégio de transmitir esses conhecimentos através desse trabalho e das disciplinas que ministrei como convidado aqui na UFF.

Sou grato a minha mãe e a minha esposa pelo apoio, aos mestres que me iluminaram nessa jornada, em especial ao meu orientador Prof. Dr. Arthur Ayres Neto, ao meu orientador estrangeiro Ph.D. Climent Nadeu, a Alexandra Elbakyan, e aos amigos Ludwig Von Houegnigan, Alejandro de Paoli, Diego São Bento, Carlos Eduardo Rebuá, Felipe Jaber Castro, Luís Filipe Xavier e Fernanda Viana.

*“... I know I was born, and I know I'll die.  
The in-between is mine. I am mine...”*

Eddie Vedder

## RESUMO

Antes de instalar qualquer infraestrutura no fundo do mar, como dutos, *manifolds*, cabos, plantas eólicas ou novos poços produtores, as companhias fazem levantamentos para fornecer informações precisas sobre o fundo do mar e os primeiros cem metros de geologia abaixo do fundo para engenheiros e geólogos submarinos. As aquisições sísmicas de ultra-alta-resolução, realizadas no passado com perfiladores de sub-fundo, foram armazenadas apenas como envelope sísmico (amplitude instantânea) em vez da forma de onda sísmica, e isso levou a um enorme passivo de dados sem informações de fase. Para recuperar a forma de onda sísmica de um envelope, apresentamos o algoritmo *un-envelope* baseado em duas redes neurais convolucionais profundas. Ele foi testado em dados reais na Bacia de Bransfield, na Antártica, e conseguiu uma reconstrução com pelo menos 90% de correspondência. O principal objetivo de recuperar a forma de onda sísmica completa de um dado envelope é o uso de atributos sísmicos nela. Computamos para dados de sub-fundo os atributos sísmicos: envelope, fase instantânea, frequência instantânea, cosseno da fase, RMS e TecVA. Realizamos, pela primeira vez nesse tipo de dados, uma inversão colorida para estender o espectro da sísmica de ultra alta resolução, usando uma linha sísmica adquirida no Atlântico Sul com um perfilador de sub-fundo e uma amostra perfilada com *MSCL* (*multi-sensor core logger*). O novo espectro de frequência a partir da inversão colorida evidencia a geologia, proporcionando um resultado melhor do que o obtido com o atributo de envelope sísmico. Também foi usada modelagem direta para calcular um traço sintético para amarrar a sísmica com os perfis multi-sensor core logger e assim extrapolar as informações da amostra geotécnica através da sísmica. Essa abordagem pode ser usada na modelagem numérica em estudos geotécnicos, fornecendo precisão vertical e exatidão nas interpretações sísmicas. O risco para instalações submarinas pode ser mitigado usando atributos de fase na detecção de um influxo raso de água ou gás.

**Palavras-chave:** *un-envelope*, atributos sísmicos, inversão colorida, perfilador de sub-fundo.

## ABSTRACT

Companies perform an acoustic survey to provide accurate information about the seabed and the first one hundred meters of geology under the seafloor to subsea engineers and geologists, before installing any submarine infrastructures in the seafloor, like pipelines, manifolds, cables, wind farms, or new producer wells. Ultra-high-resolution seismic acquisitions performed in the past with sub-bottom profilers were stored only as seismic envelope (Instantaneous amplitude) instead of the seismic waveform, and it led to a massive amount of legacy data without phase information. To retrieve the seismic waveform from an envelope, we introduce the un-envelope algorithm based on two deep convolutional neural networks. It was tested in real data from Bransfield Basin, Antarctic, and achieved a reconstruction with at least 90% of matching. The main objective of retrieving the full seismic waveform from an envelope data is the use of seismic attributes on it. We compute for sub-bottom data these seismic attributes: the envelope, instantaneous phase, instantaneous frequency, the cosine of phase, RMS, and TecVA. We performed, for the first time in this type of data, a colored inversion to broadband the spectrum of the ultra-high-resolution seismic, using one seismic line acquired in South Atlantic with a sub-bottom profiler and one sample profiled with an MSCL (multi-sensor core logger). The new seismic spectrum from colored inversion, enhances geology features providing a result better than obtained with seismic envelope attribute. We also used forward modeling to compute a synthetic trace to match the seismic with the MSCL profiles to extrapolate the information of the geotechnical sample through the seismic. It can be used in Numerical modeling on geotechnical studies, providing vertical precision and accuracy in seismic interpretations. The risk for the installation of facilities can be mitigated using phase attributes in the detection of a shallow influx of water or gas.

**keywords:** un-envelope, seismic attributes, colored inversion, sub-bottom profiler.

# SUMÁRIO

RESUMO.....	VIII
ABSTRACT .....	IX
LISTA DE FIGURAS .....	11
INTRODUÇÃO .....	15
1.1 Caracterização do Problema .....	15
1.2 Motivação .....	18
1.3 Objetivos .....	18
EMBASAMENTO TEÓRICO .....	19
2.1 Sísmica de ultra-alta-resolução .....	19
2.2 Processamento sísmico de alta resolução .....	24
2.3 Amostragem geológica e geotécnica.....	27
2.4 MSCL – <i>Multi-sensor core logger</i> .....	30
2.5 Modelagem acústica direta.....	31
2.6 Inversão acústica.....	31
2.7 Inversão colorida .....	35
2.8 A Transformada de Fourier de curto período .....	35
2.9 Algoritmo de Griffin e Lim. ....	38
2.10 Aprendizado de máquina ( <i>Machine Learning</i> ) .....	39
2.11 Neurônio eletrônico - <i>Perceptron</i> , <i>MLP</i> e <i>RNAs</i> .....	41
2.12 Funções de ativação .....	43
2.13 <i>Backpropagation</i> .....	44
ARTIGOS .....	45
Seismic inversion of an Antarctic Sampling using python sbppy and a shallow high resolution seismic .....	50
The inverse of envelope operation. Recovering the original seismic waveform only from instantaneous amplitude using deep convolutional networks .....	59
Ultrahigh-resolution seismic enhancement. The use of colored inversion and seismic attributes on sub-bottom profiler data .....	84
CONCLUSÃO.....	108
REFERÊNCIAS .....	110

## LISTA DE FIGURAS

Figura 1- Um exemplo de amostrador por gravidade (Gravity Corer) utilizado na Operantar .....	28
Figure 2 - Study Area in Bransfield Basin, with SBP line and AM10 sample ...	52
Figure 3 - Sub-bottom Profile plotted using sbppy and matplotlib, number of samples in vertical axis and traces on horizontal axis. ....	53
Figure 4 - P-wave velocity profile, density profile and core length profile. ....	54
Figure 5 - Reflectivity and Reflectivity resampled. It is possible to note the gap between data due to corers' edges. ....	55
Figure 6 - Chirp in time and its wavelet. ....	56
Figure 7 - The Synthetic trace on top and Acquired on Bottom. ....	57
Figure 8 - A zoom in the beginning of both traces to compare phase and amplitudes. ....	57
Figure 9 - A cross-correlation between the synthetic trace, and the original trace, the misplacing is shown.....	58
Figure 10 - Localization of the eleven lines acquired with sub-bottom profiler in Bransfield Basin, Antarctic 2018.....	66
Figure 11 - One example of acquired file. All acquired traces vertically side by side generates a seismic section, in this example 550 traces with 1000 samples each. The seafloor is the stronger reflection and it is possible to see in this section about 35 meters below the seabed. Each trace is about 9 meters from each other, so the length of this section is 4950 meters.....	67
Figure 12 - The comparison between one input envelope trace in (a) and the seismic waveform in (b) which is the target trace. In (c) the Hilbert transform of (b). The envelope (a) is compound by the squared root of the squared sum of (b) and (c). (d) shows this relation among them, where the envelope is in black, the real part of the analytic signal in blue, and the imaginary part of the analytic signal in red. All signals have dimension of 1024 samples.....	68
Figure 13 - Three spectrograms of input, output, and mask. In (a) on top the magnitude spectrogram of the target signal (square modulus of STFT(seismic waveform)), in (b) the magnitude spectrogram of the envelope signal, and in (c) the magnitude of the spectrogram of the computed mask for this pair. ....	73

Figure 14 - Principal Component Analysis using 262 randomly computed masks where it is possible to see some clusters they could group. It shows they have similarity and could be learned from a network. ....	75
Figure 15 - The WinHopClassifier model design. ....	76
Figure 16 - The MaskNet model design .....	77
Figure 17-CNN Output - A convolutional filter response for a batch of 256 flattened masks. ....	78
Figure 18 - The un-envelope algorithm .....	79
Figure 19 - The Loss per epoch curve of the training and validation of the MaskNet. The values of Mean Squared error to each epoch with training set is in blue, and to validation set is in orange. We used early stop in the 50th epoch with MSE=0.21 .....	80
Figure 20 - One reconstruction example using window size =89 and hop size=24. This sample has a Pearson's r value of 0.9823. In (a) the two waveforms, the reconstructed in red to be compared with the target in blue, it is possible to see small border effects in the very beginning and end. In (b) the wrapped phase between $-\pi$ and $\pi$ to each sample. And in (c) the synchrony between the two signals, values close to one show better synchrony. The DTW was applied in this example just to illustrate the synchrony of both signals, it is shown by the 45° line in detail (d) and it was used only as a visual metric.....	81
Figure 21 - Ultrahigh-resolution seismic file acquired in South Atlantic with a sub-bottom profiler. The vertical axis is in time samples, and the sampling rate is 23 microseconds. The traces are side by side. The maximum distance between them calculated with SbpPy (CUNHA, AYRES NETO, 2019) is 1 meter. The black square is a zoom for further comparison. The strongest reflection is the seabed. ....	92
Figure 22 - Three curves profiled in MSCL. On top (a) the P-velocity profile in m/s. in the middle (b), the density measured with gamma-ray in g/cc3. And on the bottom (c), the acoustic impedance computed by the product between the two curves above. ....	93
Figure 23 - Acoustic impedance plotted according to its log10 power and frequency. In red, the function computed through linear regression, which represents the scattered data. The difference between the spectrum of the seismic and the spectrum of the Acoustic Impedance profiled sample. ....	94

Figure 24 - Spectral comparison between seismic (in red) and acoustic impedance (in blue), frequency, and power are in log10.....	95
Figure 25 - The difference between the spectrum of the seismic and the spectrum of the acoustic impedance profiled sample. All frequencies from 100 Hz and 1000 Hz were added to the spectrum.....	95
Figure 26 - The colored inversion operator in time, the vertical axis is the amplitude in Volts (V), the horizontal axis is in samples.....	96
Figure 27 - The comparison of the seismic data spectrum (in black) and the colored inverted (in blue) where it is possible to see the gain between 103Hz and 103.4Hz.....	97
Figure 28 - The result of colored inversion. A comparison using the same color bar limit values to the amplitude of the raw seismic profile (in Figure 21) is possible. The amplitude of deep reflectors is bigger in colored inversion; the resolution of shallow reflectors was also improved.....	99
Figure 29 - The difference between raw seismic and the colored inverted. One minus the other, thus, it is possible to check the amplitude difference in deep numerically.....	100
Figura 30 - The envelope seismic attribute. Zoom in the detail square will be used for comparison.....	101
Figure 31 - The instantaneous phase attribute is enhancing the continuity in angularities, high-angle faults, and folds.....	102
Figure 32 - A detailed comparison between the instantaneous phase attribute (up left) and the envelope attribute (upright). It is easier to map a reflector in the up left because it has more continuity. The position of the reflector is clear in phase change (white) in the instantaneous phase attribute, while it is not so precise in the envelope attribute. The bottom left is the raw seismic where the mapping reflector task is performed nowadays, and the bottom right is the colored inversion result. In the colored inversion, the amplitude of the reflector is higher than the raw data, and the resolution of reflectors is better than in the envelope.....	102
Figure 33 - The instantaneous frequency attribute computed from an unwrapped phase.....	103
Figure 34 -The cosine of the phase attribute varying from -1 (white) to 1 (black). .....	104

Figura 35 - The cosine of the phase in detail varying from -1 (white) to 1 (black).	104
Figura 36 - The result of the RMS attribute showing the unconformities.	105
Figura 37 - The TecVA attribute emphasized the change in sediment properties; in this case, we believe it regards the resistance to penetration of the sedimentary layer.	106

## **INTRODUÇÃO**

### **1.1 Caracterização do Problema**

A completa caracterização do assoalho marinho para projetos de engenharia submarina demanda um esforço multidisciplinar que envolve áreas como geodésia, oceanografia, geologia, geofísica, geotecnica e engenharia civil. Essa caracterização serve de insumo para diversos trabalhos de empresas e organizações que tem suas atividades desempenhadas no âmbito marinho. São exemplos no Brasil as autarquias do Ministério do Meio Ambiente – IBAMA e ICMBio, as petrolíferas, as companhias que exploram minerais e energias renováveis. Os trabalhos realizados com caracterização de fundo e subfundo são diversos e podem tratar da contabilização de corais, determinação da existência de nódulos polimetálicos para a exploração mineral, fundação de planta eólica no mar, determinação de presença de artefato bélico não detonado, ou caracterização dos riscos geológicos marinhos associados a instalações de estruturas que permitam escoamento de produção de óleo e gás ou até mesmo cabos de telecomunicações (CUNHA, AYRES NETO, 2015). Independente da finalidade, o estudo é feito através do uso conjugado da acústica submarina e da amostragem geológica e geotécnica.

As amostragens geológicas e geotécnicas são métodos diretos que permitem a recuperação pontual de seções do fundo e subfundo marinhos (LIPPSETT, 1999). Com o material recuperado, os geólogos podem diretamente descrever os sedimentos, fragmento de rochas, fósseis, bioturbações, estruturas sedimentares, presença de fluídos etc. Além da descrição desse testemunho,

pode-se através da perfilagem geofísica em um equipamento chamado *Multi-Sensor Core Logger* obter-se de forma direta e indireta curvas relacionadas as propriedades físicas desses corpos, como velocidade de propagação da onda acústica compressional, massa específica, porosidade, resistividade elétrica, susceptibilidade magnética e radioatividade gama (GUNN, BEST, 1998). Ensaios geotécnicos nesse material recuperado podem ser realizados em laboratório para determinar parâmetros como resistência ao cisalhamento, resistência a penetração, percentual de água presente (grau de saturação), entre outros (ASTM D4318-17E1, 2017) .

A acústica submarina diferente da amostragem geológica e geotécnica não tem um caráter pontual e direto, ela é indireta e ideal para cobrir grandes áreas no caso das aquisições sísmicas convencionais com *streamers* (conjunto de hidrofones), ecobatímetros multifeixe (*MultiBeam Echosounders*), sonares de varredura lateral (*side-scan sonars*) e sonares de abertura sintética. Ou de aquisições de perfis usando sísmica de alta resolução (perfiladores de subfundo – SBP – *sub-bottom profilers*, ou *chirp profilers*) (LURTON, 2010). Em todos eles, uma fonte acústica, no caso da sísmica pode ser um ou um arranjo de canhões de ar (*airguns*), um *sparker*, ou um *boomer*. No caso dos sonares e sísmica de alta resolução, um transdutor ou um arranjo de transdutores gera uma onda acústica que interage com o fundo e subfundo. Essa onda está sujeita aos processos de reflexão, refração, transmissão, absorção e atenuação. A energia que retorna dessas interações é gravada através de hidrofones no caso da sísmica convencional e através de transdutores nos sonares e sísmica de alta resolução. Esse registro acústico gravado (no caso específico desse trabalho - perfil sísmico de alta resolução), não é tratado utilizando as técnicas

consagradas na aquisição sísmica convencional, pois esse registro bruto, por anos, foi considerado suficiente para as interpretações geológicas para as quais ele era adquirido. Na verdade, um atributo sísmico de envelope, o qual é obtido através do dado bruto, servia de produto para esse tipo de aquisição, pois com ele a quantidade de energia era exibida, facilitando assim o contraste entre feições na exibição do perfil. O dado na forma de atributo envelope, por só conter valores positivos, precisava de menos bytes para ser armazenado, e por isso também era a preferência como produto para essas aquisições.

A inversão acústica, amplamente utilizada nos métodos eletromagnéticos, gravimétricos e sísmica convencional, não é utilizada em projetos de engenharia submarina que conjugam amostragem e perfilagem acústica do fundo marinho raso. O interessante é que a sísmica convencional 2D e 3D lança mão da inversão acústica usando como *ground truth* (evidência empírica) os poços petrolíferos, por exemplo, mas os furos geotécnicos não são utilizados como análogos na sísmica rasa. O uso da informação dos furos geotécnicos é repleto de subjetividades quanto ao posicionamento de início e fim de camadas.

Atualmente derivar a informação pontual das amostragens geológicas e geotécnicas através dos perfis sísmicos de alta resolução para uma área como um todo é um trabalho manual, pouco automatizado. Envolve uma carga horária de trabalho grande e espalha imprecisões verticais e horizontais, além de ser extremamente dependente do intérprete que realiza o trabalho. A avaliação de riscos geológicos às estruturas submarinas é extremamente dependente da precisão desses trabalhos. A indústria já dispõe de métodos com grande precisão e acurácia, e é de suma importância garantir um uso adequado aos mesmos.

Discutir uma metodologia para otimizar essa extração, trazer os métodos já consagrados na indústria no tocante a reservatórios para a sísmica rasa de forma a transformar a forma de trabalho, aplicar o que já se tem como fronteira tecnológica usando *machine* e *Deep Learning* para reduzir as incertezas são objetivos desse trabalho.

## 1.2 Motivação

A motivação principal desse trabalho é expandir as possibilidades de uso dos dados acústicos marinhos rasos. Principalmente dos dados de perfiladores de sub-fundo (*SBP - sub-bottom profilers*), demonstrando sua potencialidade como dado sísmico, permitindo retirar mais informações de levantamentos já realizados no passado e, sabendo das novas possibilidades, projetar adequadamente aquisições futuras. Nobilitar seu uso para trazer mais segurança nas interpretações de *geohazards* marinhos.

## 1.3 Objetivos

Os principais objetivos são três: (1) realizar a operação inversa do atributo sísmico envelope, para se reaver a forma de onda sísmica; (2) demonstrar que essa onda sísmica tem as mesmas possibilidades de um dado sísmico mono canal de afastamento zero, ou seja, que é possível realizar além de interpretações qualitativas, interpretações quantitativas, usando atributos sísmicos; (3) mostrar que é possível fazer integração desse tipo de dado com

dados de amostragens geológicas rasas, para subsidiar estudos geotécnicos, entregando lateralidade às amostras geológicas com refletores sísmicos corretamente posicionados através de processamento sísmico e inversões sísmicas.

## **EMBASAMENTO TEÓRICO**

### **2.1 Sísmica de ultra-alta-resolução**

Perfiladores de sub-fundo são equipamentos utilizados nas campanhas de aquisição de dados acústicos referentes ao ambiente marinho que tem como objetivo sondar o assoalho e sub-fundo marinho. Eles são constituídos por transdutores cerâmicos capazes de converter energia elétrica em energia mecânica (som) e assim atuam na geração de pulsos sonoros controlados e, na recepção, convertendo o som em energia elétrica para se registrar o efeito da interferência do pulso com o meio sondado.

Os princípios de funcionamento dos perfiladores de sub-fundo são diferentes dos sonares de varredura lateral e ecobatímetros multifeixe, principalmente porque eles se baseiam na reflexão especular (isso é, no sinal que incide verticalmente para baixo na direção Nadir) ao invés do sinal de retroespalhamento (LURTON, 2010) causado por contribuições laterais à incidência normal. Enquanto os sonares operam entre 75 kHz e 1600 kHz, os ecobatímetros multifeixe trabalham entre 12 kHz e 500 kHz, e os perfiladores de sub-fundo entre 500 Hz e 24 kHz. Isso aproxima os perfiladores da sísmica

convencional de reflexão, pois registram o contraste de impedância acústica entre as camadas sedimentares do sub-fundo marinho. Se a aquisição é bem realizada, além da impedância acústica, é possível fazer inferências sobre a refletividade e o coeficiente de absorção das camadas (THEUILLOON, STÉPHAN, et al., 2008).

Os transdutores podem ser instalados no casco da embarcação (*hull mounted*), a qual realizará a sondagem, como por exemplo, em um Navio de pesquisa e serem rebocados por essas embarcações (*towed fish*) ou podem ser embarcados em veículos submarinos como ROVs (*Remote Observation Vehicles* – Veículos não tripulados de observação marinhos) e AUVs (*Autonomus Underwater Vehicule* – Veículo submarino não tripulado autônomo). Para esta pesquisa foram utilizados dados de sísmica de alta resolução adquiridos na Antártica com um sistema Kongsberg SBP 300 na modalidade *hull mounted* no Navio de Pesquisa Oceanográfica Maximiano da Marinha do Brasil. Foram utilizados também dados de sísmica de alta resolução adquiridos na Bacia de Santos com um sistema *Edge Tech* 2200 embarcado em um AUV. A vantagem do uso do AUV frente a configuração *hull mounted* é que a coluna d'água (altura de voo do AUV) que separa o sensor do fundo marinho é menor e por isso o sinal pode penetrar mais a depender do tipo de fundo. A desvantagem é que com o AUV a logística é mais complexa, pois depende dos tempos de mergulho e eventuais retornos de emergência.

Os diâmetros dos discos cerâmicos que implementam os transdutores, fisicamente determinam a faixa de frequência de operação do método, pois precisam oscilar na frequência operacional selecionada (GUO, 1989). Diferentes arranjos de transdutores são possíveis. Na modalidade *hull mounted* por

exemplo, é comum ter um design chamado *Mill Cross*, onde os transdutores responsáveis pela geração do pulso estão dispostos alinhados com a direção de navegação e os transdutores responsáveis pela captação do sinal acústico de retorno estão na direção transversal a navegação. Os perfiladores de sub-fundo trabalham em frequências na ordem de kHz. Inicialmente era utilizada uma única frequência (comumente 3,5 kHz), mas hoje trabalham em uma banda maior, o que agrega riqueza espectral. O perfilador utilizado na Antártica trabalha na banda de 2,5 kHz a 6,5 kHz e o utilizado na Bacia de Santos trabalha na faixa de 1kHz a 10 kHz.

O pulso utilizado é modulado em frequência e chama-se *chirp*, por isso, muitas vezes o perfilador de sub-fundo (*SBP – sub-bottom profiler*) é referenciado como *chirp profiler*. O *chirp* assim como o *sweep* dos caminhões que realizam aquisições em terra (conhecidos pelo nome fantasia *vibroseis*) tem uma *wavelet* (assinatura de fonte) conhecida. A variação entre a frequência mínima e máxima ocorre dentro do período determinado pelo comprimento do pulso e de maneira linear, quadrática ou customizada. É comum o uso de uma função customizada onde a janela é uma gaussiana com um pulso linear para mitigar os efeitos dos lóbulos laterais da *wavelet* (EDGETECH, 2005).

A diretividade do pulso emitido é bem diferente dos utilizados nos sonares, pois o pulso utilizado no SBP é estreito, sua área de abrangência no assoalho (*footprint*) é menor porque o ângulo de abertura é sempre de poucos graus, uma vez que o interesse é no retorno especular e que as contribuições de *Backscatter* são vistas como ruído (KONGSBERG, 2019).

Para se determinar a resolução lateral do método utiliza-se a teoria de Zonas de Fresnel e diretividade do ângulo do feixe sonoro, e para a resolução vertical a razão entre a velocidade observada no meio onde a onda se propaga e o dobro da banda de frequência.

As frequências mais altas são atenuadas mais rapidamente, pois é característica da Terra atuar como um filtro “corta alta”, com forte absorção dessas altas frequências, reduzindo a frequência de operação para um valor mais central na banda. A reflexão assim como o sinal emitido estão sujeitos aos princípios de propagação das ondas; sofrem atenuação esférica, suas frentes de ondas são entendidas como novos pontos geradores de ondas. As ondas difratam, são transmitidas, refratadas e refletidas pelas superfícies. Além disso, frequências superiores a 10 kHz tendem a ser proibitivas pela alta absorção e começam a sofrer com alta influência do retroespalhamento (*scattering*) lateral deixando o caráter especular comprometido (LURTON, 2010) .

O perfilador atira/emite os pulsos (*ping*) enquanto navega, logo a quantidade de tiros por tempo é constante (*ping rate*) de acordo com a profundidade. Porém a relação número de tiros por distância para uma mesma faixa de profundidade é variável e depende da velocidade de navegação. Normalmente a velocidade de aquisição é próxima de 4 nós. No entanto, quando a aquisição é feita com AUV, navegar a uma velocidade menor põe em risco o próprio equipamento, e velocidades muito superiores podem fazer perder a consistência do tiro devido ao efeito *doppler*. A aquisição com *sub-bottom profilers* não é tão influenciada por movimentos de *roll*, *pitch* e *heave* quanto a aquisição com ecobatímetros, porque ela visa o retorno especular e não o

retroespalhamento (LURTON, 2010). Entretanto, é preciso compensação eletrônica para esses movimentos.

A penetração do sinal é diretamente proporcional à potência da fonte geradora, inversamente proporcional à frequência utilizada, decai com o quadrado da distância percorrida pelo pulso e depende fortemente do tipo de sedimento que se atravessa. Esse coeficiente de absorção dependente do substrato e se relaciona com a frequência. Para a argila a intensidade do sinal é atenuada em 0,08 dB/λ (HAMILTON, BACHMAN, *et al.*, 1982). Como o assoalho da Bacia de Santos é lamoso, o sinal consegue penetrar dezenas de metros (há registros com até 80m abaixo do fundo do mar). Em siliciclásticos a penetração é muito baixa, podendo chegar a menos de 1 m quando os sedimentos forem muito grossos. Quando fluídos em subsuperfície são encontrados o sinal é praticamente todo refletido dado o grande contraste de impedância acústica provocado pela diferença de velocidades de propagação. O mesmo efeito é percebido em afloramentos rochosos.

Esse trabalho encoraja que o dado do perfilador de sub-fundo seja tratado como sísmica de alta resolução de afastamento nulo (*zero-offset*) e mono canal. *Zero-offset*, pois não há um segundo par fonte/receptor; as coordenadas da fonte e do receptor são as mesmas (na prática, são próximas o suficiente para que se reduza a uma só). E por isso também é dita mono canal, o disparo é percebido pelo mesmo canal emissor. É também considerada de ultra alta resolução pois o comprimento de onda com o qual se trabalha é centimétrico. Tratando o dado gerado pelo perfilador de subfundo como sísmica de ultra alta resolução, pode-se falar de fase, amplitude e atributos sísmicos. Embora não passe por um processo de empilhamento, é comum tratá-lo como dado empilhado (*post-stack*)

pelo fato de sua multiplicidade (*fold*) ser igual a um, apenas um traço por cela. O dado de *sub-bottom* é amostrado, discretizado, logo seu intervalo de amostragem ( $\Delta s$ ) define uma frequência limite (Frequência de Nyquist Eq. (1)).

$$Fn = \frac{1}{2\Delta s} \quad (1)$$

## 2.2 Processamento sísmico de alta resolução

Uma sequência de processamento foi sugerida por (LURTON, 2010) tratando o sinal do *sub-bottom profiler* com a equação do Sonar:

$$\begin{aligned} Rx = SL - 20 \log(2H + 2H_s) - 2\alpha H - 2\alpha_s + \\ + 20 \log(W_{ws}W_{sw}) + 20 \log V - NL + DI + PG , \quad (2) \end{aligned}$$

No qual  $Rx$  é o retorno percebido,  $SL$  a intensidade do sinal emitido,  $H$  a profundidade percorrida pelo sinal em coluna d'água,  $H_s$  a profundidade percorrida no sedimento,  $\alpha$  o coeficiente de absorção na água,  $\alpha_s$  o coeficiente de absorção do sedimento,  $W_{ws}W_{sw}$  o coeficiente de transmissão em dB,  $V$  o coeficiente de reflexão,  $NL$  o nível de ruído,  $DI$  a direitividade do feixe e  $PG$  o ganho dado no processamento.

As etapas deste processamento são:

1. Compensar o sinal para o nível da fonte emissora;
2. Ganhos e sensibilidade dos receptores;
3. Correlação com o sinal emitido (*Matching Filter*);
4. Correção da divergência esférica;

5. Ganho linear aplicado a partir do assoalho marinho;
6. Computo do atributo de envelope

Porém (QUINN, BULL, *et al.*, 1998) e depois (BARADELLO, 2014) mostraram ser muito mais efetivo tratar o sinal como sísmico e lançar mão de técnicas de processamento de dados sísmicos. Quinn sugere então a seguinte sequência de operações para melhorar a qualidade do dado SBP:

1. Gerar a *wavelet* de fase zero a partir do pulso (*sweep*) conhecido do *chirp*;
2. Desenhar um filtro inverso para a *wavelet* gerada;
3. Aplicar o *Matching filter* no dado bruto;
4. Deconvolução - Convolver o filtro inverso com o dado filtrado com *Matched Filter*;
5. Aplicar um filtro passa-faixa;
6. Aplicar o atributo de envelope no dado;
7. Aplicar um filtro passa-baixa;
8. Aplicar *FX-Decon*;
9. Aplicar Filtro Dinâmico de razão sinal ruído;
10. Migrar (opcional);
11. Aplicar algoritmo *Dip-Scan* (Yilmaz);
12. Aplicar ganho (AGC).

Baradello modifica esse fluxo, contemplando as técnicas aplicadas na aquisição terrestre com caminhões *sweep* (BAETEN, ZIOLKOWSKI, 1990) .

Para fazer a deconvolução (ROBINSON, SAGGAF, 2001) apontam uma forma de transformar a *wavelet* de fase zero para fase mínima, pré-requisito para usar a deconvolução de Yilmaz:

1. Gerar a *wavelet* de fase zero (Klauder) a partir da auto-correlação do pulso *chirp*;
2. Criar um filtro Wiener para transformar a *wavelet* em fase mínima;
3. Aplicar o filtro de Wiener calculado em 2 no sinal SBP bruto gerando um sinal *de-chirped*;
4. Aplicar correção de divergência esférica;
5. Aplicar Deconvolução Preditiva;
6. Aplicar *FX-Decon*;
7. Migrar usando Stolt (velocidade constante);

Para esse trabalho um novo fluxo é proposto seguindo os anteriores:

1. Computar um novo *datum* (Redatumar);
2. Gerar a Klauder;
3. Criar um filtro para tornar a *wavelet* fase mínima;
4. Remover a assinatura *chirp* do sinal (*De-Chirping*);
5. Corrigir a divergência esférica;
6. Retirar as múltiplas;
7. Aplicar *FX-Decon*;
8. Migração usando migração Kirchoff.

Entende-se por redatumar resolver uma questão inerente a geometria das aquisições realizadas com AUVs. Quando a aquisição do SBP é realizada *hull mounted* o dado é processado como sísmica marinha, pois tem *datum* no nível do mar, contudo com o AUV realizando um “voo” (navegando acompanhando o assoalho marinho a uma altura constante) que varia a profundidade da coluna d’água é preciso adotar uma estratégia para se posicionar fonte e receptor adequadamente na etapa de geometria, para posteriormente realizar a migração. *De-Chirping* é o processo de remover qualquer efeito provocado pelo uso do pulso na forma *CHIRP*. Remover a assinatura da fonte *chirp* é possível através da convolução do sinal *chirp* com um filtro Wiener inverso. Esse filtro inverso é calculado a partir da *klauder* do sinal *chirp* e objetiva a *wavelet* em fase mínima.

### 2.3 Amostragem geológica e geotécnica

A recuperação de amostras geológicas para estudo em laboratório já era utilizada na década de 40, e segundo (TUCHOLKE, SHIRLEY, 1979) são definitivas para se determinar propriedades de subsuperfície *in situ* ou em laboratório. (EMERY, DIETZ, 1941) descrevem o funcionamento do amostrador de fundo por gravidade – *Gravity Corer*. Na Figura 1, um amostrador por *gravity corer* pode ser visto.

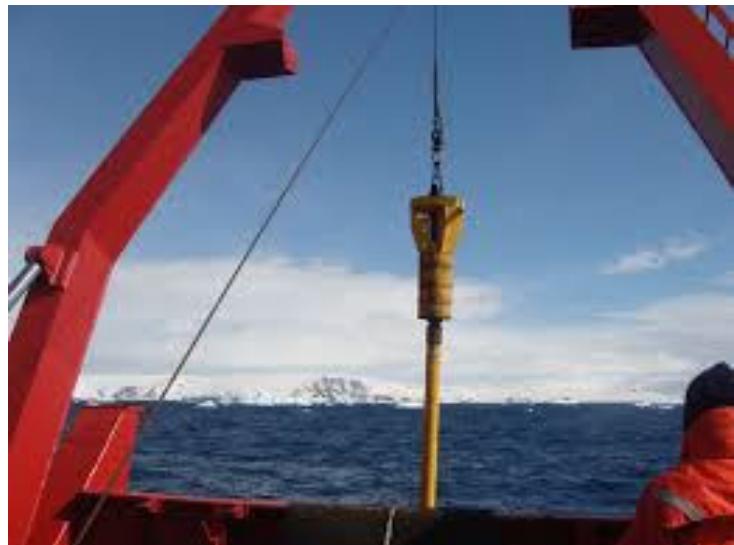


Figura 1- Um exemplo de amostrador por gravidade (*Gravity Corer*) utilizado na Operantar.

As amostras da Antártica utilizadas neste trabalho foram coletadas com esse dispositivo. Como seu próprio nome diz, ele é lançado do navio de aquisição e acelerado pela gravidade até tocar o fundo quando começa a penetrar por inércia sendo desacelerado pelo atrito proporcionado pelo tipo de material presente no fundo marinho. Dependendo do material presente no fundo, a resistência a penetração do amostrador será maior e impactará diretamente na profundidade recuperada. O tipo de retentor utilizado na extremidade do *gravity corer* é escolhido de acordo com o tipo de fundo esperado, o número de anilhas de peso que determinarão a velocidade da operação e o comprimento do *shaft* – tubo amostrador – são os parâmetros da amostragem por *gravity-corer*. O lançamento do *gravity-corer* tem um posicionamento preciso dado pelo Navio de pesquisa, porém não é possível ter a mesma acurácia do ponto amostrado no fundo, devido ao dinamismo da operação e das correntes marinhas. Logo a incerteza do ponto de recuperação é grande. Essa incerteza pode ser mitigada com o uso de sistemas de posicionamento acústico que podem determinar a coordenada do ponto amostrado no fundo. Porém, com *gravity corers* não é

possível recuperar exatamente o ponto previsto em projeto, pois a descida não é controlada.

O avanço da robótica levou a produção de sistemas de teste e amostragem baseados na perfuração com robôs no assoalho marinho. Empresas como a Benthic Geotech e o grupo Fugro atuam com esses sistemas, os quais melhoraram consideravelmente a taxa de recuperação e qualidade das amostras. A Benthic Geotech lançou em 1997 (NGUYEN, LUNNE, *et al.*, 2013) a sonda de perfuração portátil operada remotamente (PROD – *portable remotely operated drill*), enquanto a Fugro lançou a sonda de perfuração do assoalho marinho (SFD - *SeaFloor Drill*) (RANDOLPH, 2016). A grande vantagem desses sistemas é o acurado posicionamento da amostra recuperada, uma vez que a descida é controlada com posicionamento acústico ativo. É notório também que o número de análises possibilitadas por essas sondas é superior ao das técnicas anteriores. Pode-se por exemplo adquirir a informação da velocidade da onda-S (cisalhante) e realizar vários ensaios de penetração com cones, *t-balls* e outros ensaios geotécnicos.

As amostras do Atlântico Sul presentes nesse trabalho foram adquiridas com a tecnologia PROD da Benthic Geotech. As amostras têm comprimentos recuperados na ordem de dezenas de metros (até 40 m), diferentemente das amostras Antárticas que foram adquiridas com *gravity-corer* e tem recuperação de poucos metros (até 5m), ambos têm continuidade comprometida pois são segmentados. Na amostra coletada na Antártica a segmentação é feita a cada metro e nas amostras de Santos a cada 2m, isso é feito para facilitar o transporte. O tipo de fundo da Bacia de Santos, bastante lamoso, favorece a penetração alta

observada, enquanto o assoalho Antártico devido a presença de clastos carregados por icebergs dificulta a alta recuperação vista em Santos.

## 2.4 MSCL – *Multi-sensor core logger*

O MSCL (*Multi-sensor Core Logger*) é um equipamento fabricado pela empresa inglesa Geotek (GEOTEK, 2016) e pode ser entendido como um sistema que contempla um conjunto de instrumentos através dos quais pode-se realizar diversas medidas físicas na forma de perfil, imagem e raio-x. Dependendo da configuração pode-se ter medidas da velocidade de propagação de ondas P, emissão gamma espontânea, resistividade elétrica, susceptibilidade magnética e densidade. Ele mede densidade através da interação dos raios gamma com o sedimento. O sensor consiste em uma cápsula de Césio 137 de 10 mili-Curie com colimadores de 2,5 – 5 mm de diâmetro e um detector por cintilação. Durante a medição, fótons são emitidos, dispersados e transmitidos através dos sedimentos que estão contidos no *liner* (tubo amostrador retirado do *gravity corer*) que normalmente é plástico. A densidade do material pode ser determinada pela contagem dos fótons que não foram atenuados. Dessa forma a detecção *Gamma* só conta fótons que mantiveram suas energias

A velocidade de propagação da onda compressional P ( $V_p$ ) é medida por dois transdutores ultrassônicos diametralmente dispostos perpendiculares ao eixo do testemunho, os quais trabalham na frequência de 250 kHz. Dessa forma o tempo de trânsito do sinal através do sedimento é medido. Como o diâmetro do tubo é conhecido, a velocidade pode ser calculada uma vez conhecido esse tempo (BEST; GUNN, 1999) .

## **2.5 Modelagem acústica direta**

A modelagem acústica direta é utilizada na construção de traços sísmicos sintéticos a partir de informações de poços perfilados. Esses traços auxiliam na amarração das informações dos poços e em calibrações de modelos geológicos. Eles são muito úteis em interpretações de seções sísmicas em tempo. Traços sintéticos também podem servir como dados para testes e evitar o custo de aquisições pontuais. Algumas técnicas têm sido utilizadas para a modelagem direta (LI, WU, *et al.*, 2019) como o método das diferenças finitas, o método dos elementos finitos e o método do pseudo-espectro.

A modelagem acústica direta, baseia-se nos valores de impedância acústica obtido nos perfis de poços. A Impedância acústica é a resistência a passagem do som por um meio, ela é diretamente proporcional a densidade do meio e a velocidade de propagação da onda acústica no meio.

## **2.6 Inversão acústica**

Através de modelagem direta pode-se predizer um resultado esperado para uma medição, bastando para tal operação um modelo que contenha uma lei para a simulação (SEBAA, FELLAH, *et al.*, 2006) . Por exemplo, no caso do MSCL, a distância entre o emissor e o receptor acústico é conhecida com precisão. Com o cronômetro de precisão do instrumento, o tempo decorrido entre o disparo do pulso e a detecção no receptor é medido. Assim é possível,

diretamente, inferir a velocidade de propagação da onda P na amostra contida no equipamento.

O contrário, por exemplo, saber as velocidades de propagação da onda P em um meio que geram um determinado valor de contraste de impedância acústica em uma sísmica, não é possível através de modelagem direta. Pois diferentes valores de impedâncias acústicas poderiam resultar no mesmo modelo de velocidade. Para tentar solucionar a questão é utilizada a modelagem inversa. Na modelagem inversa diferentemente da modelagem direta, não temos uma resposta única, uma vez que, por exemplo, infinitos arranjos de densidades e velocidades de propagação de onda P podem gerar a mesma resposta medida na sísmica de reflexão.

Dado esse comportamento inerente ao método inverso, a solução frequentemente se dá por uma inferência probabilística usando teorema de Bayes ou Monte Carlo, ou através de otimização numérica iterativa com derivações de métodos da Secante e outros métodos Quasi-Newton, como o algoritmo Broyden-Fletcher-Goldfarb-Shanno (BFGS) ou algoritmos que usam normalização L1 e mínimos quadrados, como a deconvolução *sparse-spike* (CLEARBOUT, MUIR) *apud* (DOSSAL, MALLAT, 2005).

Nos métodos de sísmica de reflexão e refração desde a década de 90 as técnicas de inversão recaem ou na inversão do tempo de trânsito (tomografia) – *tomography travelttime inversion* (DINES, LYTLE) *apud* (ZHANG, SCHUSTER, et al., 2011) ou na inversão da forma de onda completa - *full waveform inversion* (TARANTOLA, 2005).

(BRITTAN, JONES, 2019) fez uma revisão histórica sobre a evolução do FWI (*full waveform inversion* - inversão da forma de onda completa).

Uma outra forma de se dividir as técnicas de inversão sísmica é segundo (RUSSELL, 1988) de acordo com a natureza do dado de entrada da inversão: dado empilhado ou pré-empilhado. Com o dado pré-empilhado, segundo (FILIPPOVA, K; KOZHENKOV, A; ALABUSHIN, 2011) é possível se estimar múltiplos parâmetros elásticos como impedância P e S, razão VP/VS e densidade. Porém com o dado empilhado somente a impedância acústica (Z) pode ser estimada.

A escolha entre algoritmos determinísticos e probabilísticos (geoestatísticos) de acordo com (FRANCIS, 2006) deve se dar seguindo a regra: No estágio inicial do campo, com poucas amostras é utilizada a inversão determinística; em um segundo momento, dispondo de mais dados, a inversão geoestatística mostra melhores resultados pois pode trazer detalhes de escala fina para além da largura de banda da sísmica.

Dada a natureza do dado sísmico de alta resolução (SBP) podemos somente esperar reaver após processo de inversão a impedância acústica. Contudo como define (LATIMER, DAVIDSON, *et al.*, 2002) a Impedância acústica é uma propriedade de camada e não de interface de camadas, como é na sísmica de reflexão. Então um modelo de impedância acústica traz todas as informações que um cubo sísmico ou linha sísmica traz, mas sem as complicações referentes a forma da onda (*wavelet*). Importante notar que o modelo de impedância é o elo natural entre o poço e a sísmica.

As vantagens do dado sísmico de alta resolução no tocante a métodos de inversão sísmica estão:

1. No fato dele possuir uma *wavelet* conhecida e repetida. Essa etapa de determinação da *wavelet* gera várias incertezas quando se trabalha com sísmica convencional com fonte não controlada, como *air-guns* ou dinamites;
2. Seu amplo espectro de frequência;
3. Seu baixo comprimento de onda o que possibilita resoluções sísmicas altas.

As desvantagens do dado sísmico de alta resolução no uso de métodos de inversão sísmica:

1. Não há multiplicidade suficiente para se empilhar o dado, porém o mesmo não pode ser tratado como pré-empilhado porque trata-se de uma aquisição que pode ser assumida como zero-offset, ou seja, sem espaçamento considerável entre fonte e receptor;
2. A sísmica é mono canal. Não existe mais de um par fonte-receptor, logo não se pode ter a separação de offsets curtos e distantes e assim poder falar de AVO (*Angle versus Offset* - ângulo versus afastamento, um domínio onde que pode evidenciar relações interessantes na exploração de hidrocarbonetos),
3. Não há um modelo de velocidade para o marinho raso. Dessa maneira as abordagens recentes de FWI e Tomografia não se aplicam, pois não há modelo inicial para se refinar;
4. As componentes de baixa frequência (menores que 1kHz) não estão presentes, isso pode trazer muito mais dificuldades do que são encontradas com a sísmica convencional multicanal que só não tem frequências menores do que 10Hz, além disso a componente *DC* do sinal não está presente.

Por exclusão, para esse trabalho, dada a natureza do dado SBP apenas técnicas de inversão acústica determinísticas seriam possíveis segundo exposto

por (COOKE, CANT, 2010) para inversões acústicas com a finalidade de interpretações estratigráficas.

## 2.7 Inversão colorida

A técnica chamada inversão colorida (WHITCOMBE, LANCASTER, 2000) é um processo onde é calculado o espectro da Impedância Acústica de uma região que foi sondada por um método sísmico de reflexão e tenha poços perfurados. As curvas de velocidade compressional  $p$  e densidade dos logs de perfilagem desses poços são utilizadas para computar o espectro da IA (Impedância Acústica) e um operador. Esse operador ao ser convolvido com a sísmica traz o espectro da sísmica para os valores estimados de Impedância acústica.

## 2.8 A Transformada de Fourier de curto período

As técnicas para estimar espectro de frequências são baseadas no fato de que as características dos sinais como frequências, amplitudes, covariâncias e densidade espectral não variam no tempo. Além disso, se essas características mudarem suficientemente devagar no tempo, o espectro de frequência dependente do tempo de um sinal pode ser estimado usando versões desses métodos de curto período.

Se compararmos dois sinais que variam no tempo, como por exemplo, um *chirp* linear como o utilizado pelo perfilador de sub-fundo e um impulso, esses sinais podem ter uma estimativa espectral exatamente idênticas. Se tomarmos

a transformada de Fourier dos dois, eles teriam a mesma função descrevendo sua magnitude ( $|Xf|$ ), porém informações de fase distintas. Assim, o espectro, ou periodograma (o quadrado da magnitude da transformada) não nos daria em frequência com clareza a distinção que temos na análise no domínio do tempo.

Em contrapartida, (GABOR, 1946) sugere como solução a representação em tempo frequência, um spectrograma (ou sonograma), o qual por estar suportado em três dimensões é capaz de representar com clareza a evolução temporal e assim elucidar a diferença dos dois sinais.

Para se computar a transformada de Fourier de tempo curto (*STFT - Short time Fourier Transform*), divide-se a sequência de entrada no domínio do tempo em sequências curtas, de modo que elas contemplem um recobrimento. Essa divisão é baseada na escolha de uma janela e um salto (ou deslocamento, "hop").

Computa-se então os espectros ou periodogramas dessas sequências menores. Gerando um espectro de frequência para todas as sub-sequências.

Na prática, a STFT é uma matriz complexa, onde o eixo do tempo e das frequências é arbitrário, porém as implementações mais utilizadas, definem as linhas como *bins* de frequências e as colunas como sequências de tempo.

O número de *bins* está associado ao número de coeficientes utilizados para se computar a transformada de Fourier, na seguinte relação: número de linhas é a metade do número de pontos da transformada de Fourier mais um. Pois a transformada de Fourier quando tomada em múltiplos de  $2^n$  pode ser calculada computacionalmente da maneira rápida (*FFT - fast Fourier transform*) lançando mão de fatorações matriciais, e da simetria de seu conjugado complexo.

O número de sequências de tempo, está associado ao tamanho do salto (ou deslocamento). O número de colunas é dado pela relação entre o número total de amostras do sinal de entrada dividido pelo tamanho do salto mais um.

A escolha da função utilizada como janela nesse sequenciamento é de suma importância, para evitar vazamento espectral. Para uma sequência  $x[n]$  discreta, a equação que computa a transformada discreta de Fourier de tempo curto é:

$$STFT\{x[n]\}(m, \omega) = \sum_{n=mL}^{n=mL-(L-1)} x[n]w[mL - n]e^{-i\omega n} \quad (3)$$

Onde  $w$  é a função janela que desliza ao longo da sequência  $x[n]$  centrada em  $m$ ,  $L$  é um número inteiro que define o salto (ou deslocamento) em tempo que separa dois periodogramas. A exponencial no fim define a transformada de Fourier aplicada no trecho do sinal janelado para cada bin ( $\omega$ ).

A operação inversa a STFT é realizada pelo operador ISTFT ou  $STFT^{-1}$  descrito na equação:

$$\tilde{x}[n] = STFT^{-1}\{X(m, \omega)\} = \sum_m w[mL - n] \sum_{\omega} X(m, \omega)e^{i\omega n} \quad (4)$$

Devido ao limite de Heisenberg-Gabor, não se pode simultaneamente localizar um sinal em ambos domínios do tempo e da frequência. Não é possível atingir ao mesmo tempo uma alta resolução temporal e em frequência. Quando se utiliza uma janela larga para se computar a STFT, a resolução em frequência é grande, porém o resultado em tempo não é bom. E ao contrário, se a janela for

curta em tempo, obtém-se uma boa resolução em tempo, porém o resultado em frequência não é bom.

## 2.9 Algoritmo de Griffin e Lim.

O algoritmo de Griffin-Lim (GRIFFIN, LIM, 1984) é utilizado para inferir a fase de um sinal de modo otimizado a partir da magnitude de um espectrograma.

Griffin e Lim perceberam que a partir de espectrogramas modificados, se algumas constrições fossem observadas, era possível iterativamente reaver o sinal original do espectrograma de entrada, pois havia redundância suficiente na transformada de tempo curto de Fourier (STFT).

As constrições de unicidade da resposta foram posteriormente detalhadas por (NAWAB, QUATIERI, *et al.*, 1983) e versam sobre condições para se obter um espectrograma consistente, além de uma correta amostragem e reconstrução do sinal, na conversão para o espectrograma. Entre elas:

- Deve-se conhecer a função que implementa a janela de amostragem do sinal que será gerado o espectrograma, e a janela de reconstrução do sinal a partir do espectrograma.
- Essas janelas devem ter um comprimento superior a duas amostras
- Não podem ter em si valores nulos, os quais zerariam o trecho do sinal ao se realizar a amostragem com a janela.
- O sinal do qual é computado o espectrograma não pode ter amostras em tempo negativo. Ele precisa ser causal. (*one-sided*)

- O sinal não pode ter entre duas amostras não zeradas, um valor de amostras zeradas superior ao comprimento da janela descontado de duas amostras.
- O passo (ou salto) utilizado no computo do spectrograma precisa ser maior que uma amostra e menor do que metade do comprimento da janela, para que haja o recobrimento mínimo para uma conseguir uma reconstrução perfeita.

O algoritmo de Griffin e Lim admite que a magnitude do spectrograma de entrada é a verdadeira e inicializa a fase. Ele cria uma matriz complexa, onde a magnitude é a parte real e a parte imaginária é inicializada a partir de ruído uniforme. Dessa forma a parte imaginária já tem magnitude, porém a fase ainda não é conhecida. Então ele computa iterativamente, de acordo com o número de iterações passado como parâmetro, a transformada inversa de tempo curto (ISTFT) nessa matriz. Isso resulta em uma série temporal com amplitude, porém ainda sem fase definida. O algoritmo usa a série temporal calculada para computar a transformada de Fourier de tempo curto (STFT) a qual consegue reaver um início de informação de fase, bastante imprecisa ainda, pois foi somente a primeira iteração. O algoritmo então substitui nessa matriz complexa (gerada pela segunda STFT) a parte real pela magnitude original passada. Ao final das iterações ele converge para a fase do sinal.

## 2.10 Aprendizado de máquina (*Machine Learning*)

Após (SAMUEL, 1959) o termo *Machine Learning* (aprendizado de máquina) é usado para representar o campo de estudo que dá aos

computadores a habilidade de aprender sem serem explicitamente programados. Entretanto, os conceitos envolvidos e estudos desse campo remontam ao início do século XIX com Legendre e Gauss e o método dos mínimos quadrados e Fischer com a análise de discriminantes em 1936.

O método dos mínimos quadrados ficou popularmente conhecido como regressão linear. A regressão linear é uma técnica utilizada para prever um valor real específico, quantitativo, como por exemplo quanto valerá um imóvel após um determinado número de anos.

Para prever valores qualitativos, como por exemplo se o valor de uma ação ou moeda vai subir ou cair, ou se um paciente vai sobreviver ou não a um procedimento, utilizam-se métodos para classificação baseados nas técnicas inicialmente desenvolvidas por Fischer.

Todos problemas para os quais se busca o aprendizado de máquina como solução, se encaixam em uma dessas duas naturezas: regressão ou classificação. Em paralelo ao desenvolvimento do aprendizado de máquina, que se deu principalmente no campo de estudos da ciência da computação, aconteceu no campo da engenharia o desenvolvimento do reconhecimento de padrões (*pattern recognition*).

(BISHOP, 2006) diz que o campo de reconhecimento de padrões se preocupa com a descoberta automática de regularidades nos dados através de algoritmos. E com o uso dessas regularidades na tomada de ações, como nos problemas de classificação.

O reconhecimento de padrões é categorizado de acordo com o tipo de procedimento de aprendizado utilizado para gerar as respostas. São quatro

categorias: aprendizado supervisionado, aprendizado não supervisionado, aprendizado semi-supervisionado e aprendizado por reforço.

No aprendizado supervisionado, tem-se o chamado dado anotado. No conjunto de treinamento dos dados, existe para cada entrada uma saída conhecida (um rótulo). Assim os modelos aprendem a gerar a resposta com um gabarito para se corrigirem.

No aprendizado não-supervisionado os dados do conjunto de treinamento não possuem rótulos para saber se estão corretos ou não. Os algoritmos buscam medidas de semelhança para dispor em clusters os dados.

O aprendizado semi-supervisionado é uma combinação dos dois primeiros. Por exemplo, primeiro descobre-se em quantos clusters o problema se divide, depois esses clusters servem de rótulos para o problema de classificação.

No aprendizado por reforço (SUTTON, BARTO, 1998) o algoritmo através de cadeias de estados de Markov, por tentativa e erro descobre a abordagem que leva a maior recompensa no menor tempo. No aprendizado por reforço, assim como no aprendizado não-supervisionado não existem dados rotulados.

## 2.11 Neurônio eletrônico - *Perceptron, MLP e RNAs*

(MCCULLLOCH, PITTS, 1943) apresentam um modelo cognitivo baseado no sistema nervoso e (ROSENBLATT, 1958) apresenta o *Perceptron*. Por analogia ao neurônio humano que tem como entradas os dendritos e saída o axônio, Rosenblatt gerou como neurônio, um classificador linear que mapeia um vetor de entrada real  $x$  em uma saída binária  $f(x)$  segundo a equação:

$$f(x) = \begin{cases} 1, & \text{se } \sum \omega x + b \geq 0 \\ 0, & \text{se } \sum \omega x + b < 0 \end{cases} \quad (5)$$

Onde  $\omega$  é o peso associado ao vetor de entrada  $x$  e  $b$  é (*bias* - viés) associado ao neurônio e não depende da entrada. Dessa forma, o neurônio é capaz de atuar no que é linearmente separável. Da associação de neurônios (conectando a saída de um primeiro neurônio na entrada de um neurônio seguinte) pode se constituir redes neurais artificiais (RNAs).

No que tange a arquiteturas possíveis, as RNAs podem ser compostas de apenas uma camada (camada simples - nenhum neurônio se conecta a outro, apenas as entradas são conectadas a vários neurônios). Ou podem estar dispostas no modelo multicamadas, onde os neurônios de camadas anteriores têm suas saídas conectadas a entradas das camadas posteriores; esse modelo é comumente chamado de MLP (*Multi-layer perceptron*). Quando não há realimentação (conexão de uma saída a uma entrada na rede) diz-se que a rede é *feed-forward* pelo fluxo de informações (direto da entrada para a saída, não há conexões entre neurônios na mesma camada). Se cada neurônio da camada posterior tem suas entradas conectadas a todas as saídas da camada anterior, diz-se que a rede é *FullyConnected*.

Se uma saída é conectada a uma entrada formando um loop, ou conectada ao próprio neurônio, ou a outro de sua camada, diz-se que a rede é recorrente. Essa é uma arquitetura interessante, pois o fluxo de informações percorre a rede em mais de uma direção, e nesse modelo, é possível guardar ocorrências, são redes com memória.

As camadas situadas entre a camada de entrada e a camada de saída são chamadas de camadas ocultas (*hidden layers*), quando existem mais de

duas camadas ocultas a rede já pode ser considerada profunda. Quanto mais camadas tem o modelo, mais profundo ele é. Quanto mais neurônios ele tem por camada, mais capaz ele é. Assim *deep learning* (aprendizado profundo) diz respeito a redes neurais artificiais com muitas camadas.

## 2.12 Funções de ativação

Neurônios artificiais das RNAs são capazes de implementar diferentes funções de ativação (*kernels*), além da função linear anteriormente descrita com a função degrau (equação 5). É possível utilizar como função de ativação a função sinal - equação (6), tangente hiperbólica - equação (7), *ReLU* - equação (8), logística - equação (9), *ELU* - equação (10):

$$f(x) = \begin{cases} 1, & \text{se } \sum \omega x + b \geq 0 \\ -1, & \text{se } \sum \omega x + b < 0 \end{cases} \quad (6)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7)$$

$$f(x) = \begin{cases} x, & \text{se } \sum \omega x + b \geq 0 \\ 0, & \text{se } \sum \omega x + b < 0 \end{cases} \quad (8)$$

$$f(x) = \frac{1}{1+e^{-x}} \quad (9)$$

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha(e^x - 1), & x \leq 0 \end{cases} \quad (10)$$

Convoluçãoes também podem ser implementadas através de *kernels* convolucionais de uma ou duas dimensões.

Assim que a arquitetura e as funções de ativação são definidas um grafo computacional com as operações que a rede implementará é definido. Caminhar por esse grafo partindo da entrada para a saída é o processo de inferência. Percorrer esse grafo computacional no sentido contrário, partindo da saída em direção a entrada através das derivadas parciais das operações utilizadas na

inferência para se atualizar os erros na etapa de aprendizagem, leva o nome de *Backpropagation*.

## 2.13 Backpropagation

A rede neural (comumente chamada modelo) tem dois modos de operação: o modo de treinamento e o modo de utilização (ou de inferências pelo modelo).

Para o correto treinamento e posterior avaliação do modelo, é uma boa prática separar o conjunto de dados iniciais em três subconjuntos: treinamento, validação e teste (KUHN, JOHNSON, 2013). Dessa forma garante-se que a rede não tenha visto os dados do conjunto teste durante o treinamento e assim pode-se computar as métricas para avaliação do desempenho do modelo sem viés.

Na fase de treinamento, objetiva-se a atualização dos pesos associados as conexões neuronais para que o erro entre o valor da predição realizada pela rede e o valor de verdade guardado pelo dado rotulado (no caso do aprendizado supervisionado) seja mínimo. O algoritmo que computa esse erro e o propaga para as arestas do grafo computacional chama-se *backpropagation*. Ele baseia-se na seguinte equação:

$$W^{\text{atual}} = W^{\text{anterior}} + \eta (d^{(k)} - y) x^{(k)}, \quad (11)$$

$W^{\text{atual}}$  é o valor do novo peso da aresta calculado pelo *backpropagation*;  $W^{\text{anterior}}$  é o peso a ser atualizado;  $\eta$  é a taxa de aprendizado (*learning rate*) um hiperparâmetro que permite tornar mais rápido ou suave o aprendizado; E  $d^{(k)}$  é

o valor predito pela rede;  $y$  é o valor esperado para a entrada  $x^{(k)}$ . Buscar o erro mínimo é uma busca pelo gradiente ( $-\nabla W$ ), onde o sinal negativo deve-se ao fato da busca ser pelo mínimo e não pelo máximo.

Otimizadores ajudam a acelerar a tarefa de computar o gradiente. Nem sempre o mínimo global precisa ser encontrado para o resultado ser satisfatório. Mínimos locais podem ser a solução. Esse cálculo pode se dar de uma única vez (contando com todos os elementos em uma única passagem) ou por conjuntos de entradas (*batchs*).

Uma época é a unidade associada a passagem de todas as amostras do conjunto de treinamento (ou validação) pela rede.

## ARTIGOS

Essa tese foi esquematizada em três publicações. A primeira publicação, "*Seismic inversion of an Antarctic sampling using python sbppy and a shallow high resolution seismic*", com coautoria do Prof. Dr. Arthur Ayres Neto e do oceanógrafo Matheus Martins foi realizada no XVI congresso internacional de geofísica da SBGF (Sociedade Brasileira de Geofísica). Ela traz uma modelagem direta entre o perfil de uma amostra geológica, perfilada pelo Matheus com multi-sensor core logger no laboratório de sedimentologia da Universidade Federal Fluminense e um dado de perfilador de sub-fundo. A amostra e o perfil foram coletados na bacia de Bransfield, Antártica, em 2018.

A publicação ainda apresenta a biblioteca SbpPy, escrita por mim, em Python para trabalhar com arquivos gerados por perfiladores de sub-fundo

(SBP). A biblioteca é composta por um conjunto de funções que realizam operações necessárias ao processamento dos dados sísmicos de ultra-alta-resolução, assim como outras operações utilitárias para resolver questões de controle de qualidade de aquisição e auditoria de levantamentos com perfiladores de sub-fundo. São exemplos de procedimentos possíveis a busca da coordenada mais próxima a um tiro, o cálculo da distância entre tiros, efetuar a geometria de aquisição para levantamentos com AUVs, entre outros.

Embora sejam classificados como arquivos `*.segy`, eles não seguem completamente o padrão SEG-Y (NORRIS, FAICHNEY, *et al.*, 2002) pois, por exemplo o número de amostras é superior ao da sísmica convencional, gerando assim um número de amostras superior ao maior inteiro utilizado para representação pelo cabeçalho do padrão. Isso ocorre porque o intervalo de amostragem dos perfiladores de sub-fundo é dado em microssegundos enquanto na sísmica convencional em milissegundos. O número de amostras por traço também não é constante nos dados de perfiladores de sub-fundo. Essas dificuldades geraram a necessidade de se escrever essa *library* para lidar com essas questões. Ela é importante também para disponibilizar no *framework* Python esse tipo de dados, viabilizando as publicações seguintes que usam redes neurais profundas e atributos sísmicos nos dados de perfiladores de sub-fundo.

A primeira publicação apresenta a geração de um traço sintético a partir da amostra geológica perfilada. O objetivo de se realizar essa modelagem direta é viabilizar amarrações furo geológico, ou geotécnico, com a sísmica de ultra-alta-resolução e assim dar lateralidade (através da sísmica) aos parâmetros

geotécnicos provenientes de ensaios pontuais, e as informações geológicas oriundas dos furos de amostragem geológica.

Essa metodologia além de permitir estudos futuros relativos à atenuação do sinal sísmico (fator Q) e automações de procedimentos relativos à interpretação sísmica qualitativa e quantitativa, corrobora com o que queremos provar no tocante ao uso do dado de perfilador de sub-fundo como dado sísmico de ultra-alta-resolução. Satisfazendo o objetivo (3) da tese que diz respeito a integração amostra geológica ou geotécnica com sísmica de ultra-alta-resolução.

A segunda publicação, "*The inverse of envelope operation. Recovering the original seismic waveform only from instantaneous amplitude using deep convolutional networks*", é a maior contribuição desse trabalho. Como os outros dois trabalhos ela tem ineditismo, mas sem ela, por exemplo, a terceira publicação não seria possível. Essa publicação foi submetida para a revista *Geophysics* da *Society of Exploration Geophysicists* e tem como coautores o Prof. Dr. Arthur Ayres Neto e o Ph.D. Climent Nadeu da *Universitat Politècnica de Catalunya*, meus orientadores nessa tese.

O trabalho apresenta o algoritmo *un-envelope* capaz de reaver a onda sísmica original a partir de dados envelopados, isto é, dados que contenham apenas a amplitude instantânea. Reavemos a informação de fase em dados coletados na forma do atributo sísmico de envelope. Conseguimos esse resultado usando a *library* SbpPy, redes convolucionais profundas, máscaras em frequência e o algoritmo de Griffin-Lim.

Inúmeras aquisições foram realizadas utilizando perfiladores de sub-fundo e os dados finais foram armazenados como atributo sísmico de envelope. Agora

com essa metodologia, todo esse passivo pode ser reinterpretado, uma vez que os refletores podem ser corretamente posicionados, e diversos outros estudos são possíveis, o mesmo tipo de estudo possível com dados sísmicos, incluindo correlações com os diversos furos geológicos e geotécnicos e uso de atributos sísmicos.

Os resultados, reconstrução com pelo menos 90% de correlação, são definitivos. Essa publicação atende o primeiro objetivo da tese.

A terceira e última publicação, "*Ultrahigh-resolution seismic enhancement. The use of colored inversion and seismic attributes on sub-bottom profiler data*", submetida para *Journal of Applied Geophysics* tem como coautor o Prof. Dr. Arthur Ayres. Uma vez que conseguimos reaver a forma de onda sísmica completa do dado de perfilador de sub-fundo na segunda publicação, pôde-se aplicar técnicas consagradas na sísmica de reflexão em dados de SBP para ratificar que eles são dados sísmicos de ultra-alta-resolução. Realizamos pela primeira vez uma inversão colorida em dados SBP, provando a integração furo geológico com a sísmica de ultra-alta-resolução que é o objetivo (3) da tese. A inversão colorida teve uma performance superior ao atual *benchmark* da indústria que era o atributo de envelope, pois ela resulta em um sinal com mais resolução (e forma de onda completa) e amplitudes superiores ao dado bruto.

Nessa publicação também provamos ser possível computar os atributos sísmicos tradicionais utilizando a biblioteca SbpPy. Dessa forma atendemos o objetivo (2) da tese. O atributo de fase instantânea teve um resultado excelente trazendo grande continuidade aos refletores mergulhantes. Nesse tipo de dado é possível se automatizar o mapeamento de refletores, o que pode trazer grandes economia com carga horária de trabalho para a indústria. Computamos

os atributos sísmicos: envelope, fase instantânea, frequência instantânea, cosseno da fase, RMS (*root mean square*), e TecVA (tecnologia de volumes de amplitude) do (BULHÕES, DE AMORIM, 2005).

A seguir as três publicações.

# **Seismic inversion of an Antarctic Sampling using python sbppy and a shallow high resolution seismic**

Cunha, J. B.<sup>1</sup>, Ayres Neto, A.<sup>1</sup>, Martins, M. S<sup>1</sup>

<sup>1</sup> Universidade Federal Fluminense, General Milton Tavares de Souza Avenue, Campus da Praia Vermelha, Niterói, RJ, Brazil

## **ABSTRACT**

We want to present a python library called sbppy which deals with sub-bottom profile data. In this work, we use it to invert an Antarctic sample acquired in Operantar 34 (AM10) and a High-resolution seismic survey acquired in Operantar 33. This contribution creates a synthetic trace to compare with the one obtained on Bransfield basin. The library sbppy may help users who need to use sub-bottom profile data in research and enable high-resolution shallow seismic data to the data science frameworks.

**Author Note:** This expanded abstract was complemented by a Poster in this event where more data were added, including a better geological sample profiled also with Geotek and a sub-bottom profiler data related. Both allowed for publication by Petrobras. The correlation was higher in this new data than in this one.

## INTRODUCTION

This contribution wants to present a new python library called SbpPy, which deals with sub-bottom profiling data also known as high-resolution seismic. This sub-bottom profiling data covers the upper part of the seafloor and is very common in subsea engineering, often used to determine the oil and gas pipeline routes. The high-resolution seismic can be seen as a single channel, and zero offset seismic since source and receiver are the same transducer. Its penetration capacity depends on the subsea material and the power of its source (LURTON, 2010). It reaches depths around 80 meters below the seafloor in muddy sediments with nowadays sensors (KONGSBERG, 2019). The resolution depends on the velocity of the vehicle, which is acquiring the data (AUV or vessel) due to its ping rate. Also, the bandwidth used - it often operates with kHz frequency with sampling interval of a few microseconds of resulting in a large number of samples per trace, and a large number of traces pretty close to one another. These particularities bring a hard time to commercial softwares used to interpret and process conventional multichannel seismic.

To solve the issues regarding these particularities of this kind of data, a library SbpPy was develop at LAGEMAR (marine geology laboratory) of Universidade Federal Fluminense. It opens high-resolution seismic file and enables the users to access the desired fields in traces headers and binary headers. It is object-oriented and this way the access is simple and straight since each trace is a callable object. Using this library, the user can write specific python routines using SBP data. It is possible to feed a neuronal network system wrote in Pythorch or Tensorflow directly, or plotting using libraries like Matplotlib

(HUNTER, 2007) or even create probes with python-geoprobe (KINGTON, 2012) to use with Mayavi (RAMACHANDRAN, VAROQUAUX, 2011).

To exemplify the use of this library, we propose a preliminary inversion of a sediment core (AM10) acquired during Operantar 34 in Bransfield basin (Figure 2), using a gravity-corer. The core was logged for VP and density with a Geotek multi-sensor core logger on March 7th of 2018. With P-wave velocity and density curves, we generated the impedance and reflectivity profile. After that a synthetic trace was created to compare with the high-resolution seismic trace #85037 from the SBP line P2-3Sisiters11.seg.

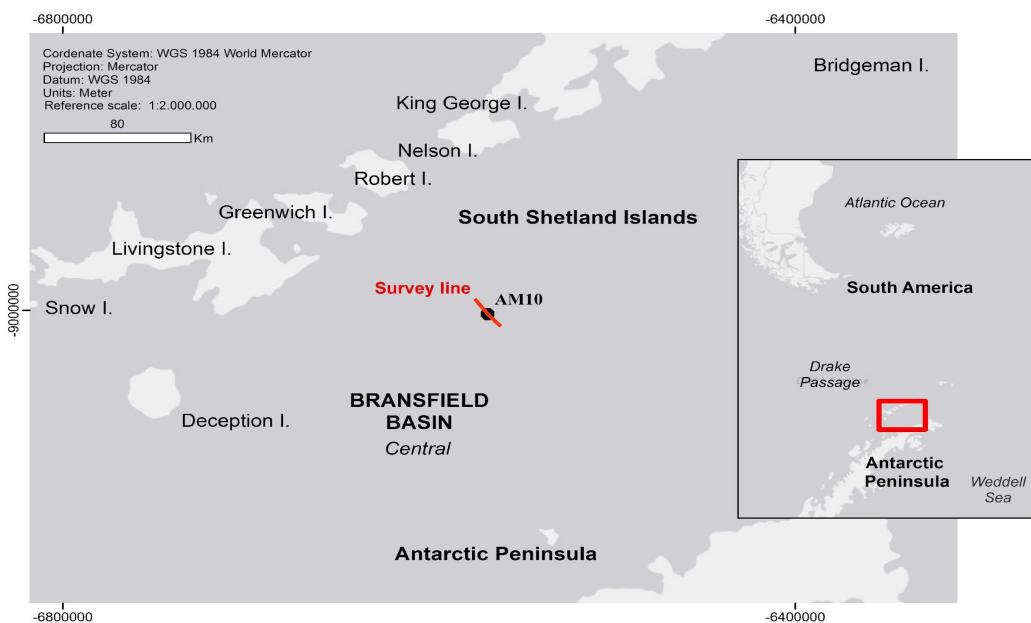
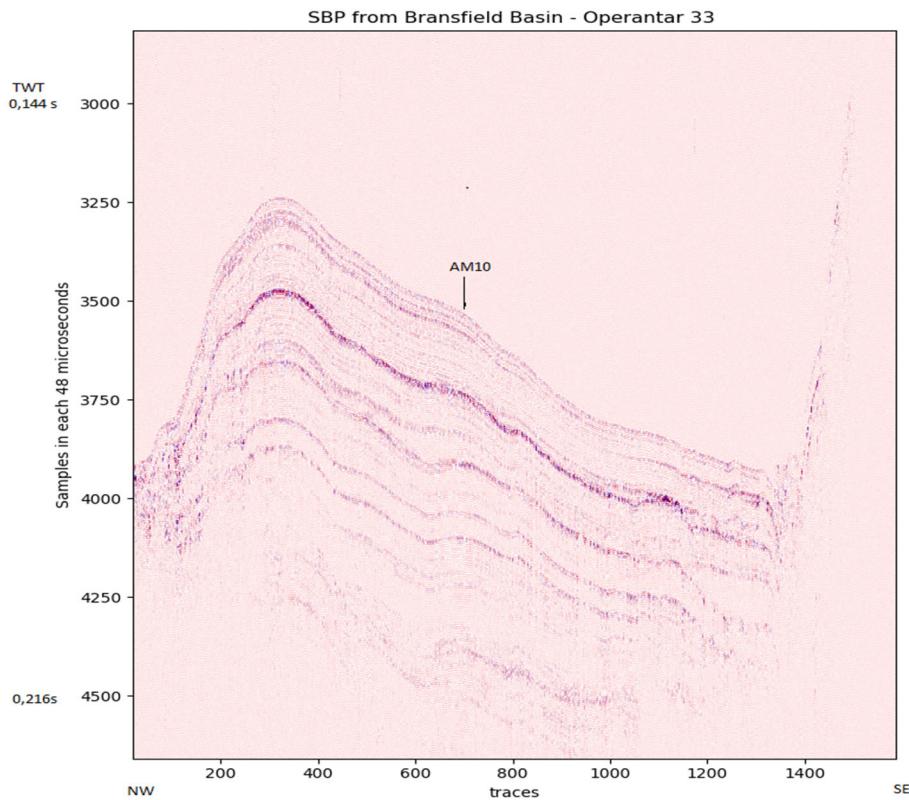


Figure 2 - Study Area in Bransfield Basin, with SBP line and AM10 sample.

## METHODOLOGY

The seismic data was acquired during Operantar 33 on board of the Brazilian Navy Almirante Maximiano with a hull mount system Kongsberg SP120

at the Bransfield basin as shown in Figure 2. Figure 3 shows a zoom into the profile plotted using the SbpPy and matplotlib libraries. This window is a matrix where the columns are traces from SBP file and lines are samples (sample interval is 48 microseconds).



*Figure 3 - Sub-bottom Profile plotted using sbppy and matplotlib, number of samples in vertical axis and traces on horizontal axis.*

One year later in Operantar 34, we acquire a geological core (AM10) with a gravity corer. Figure 2 shows the coordinates of this geological sampling.

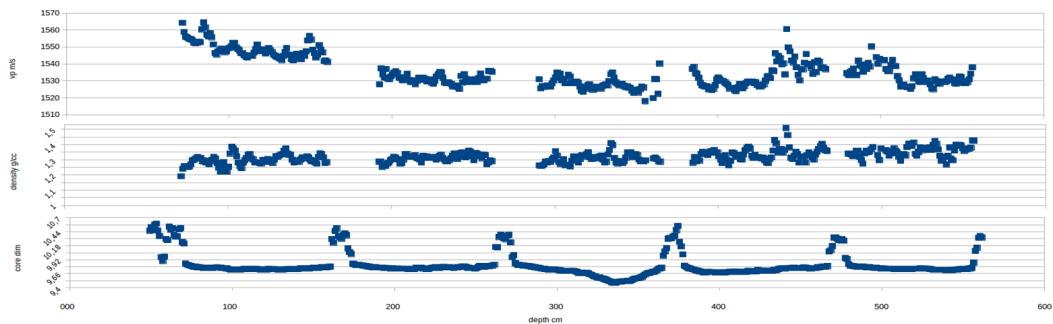
The core was logged using the multi-sensor core logger (MSCL), produced by Geotek Ltd. The MSCL makes high quality measures with high resolution (1 cm) along the core. For this work, we only used the data of compressional wave velocity and gamma density.

The MSCL measures density through the interaction of gamma rays with the sediment. The sensor consists of a ten milli-Curie 137 Cesium capsule with

collimators of 2.5 to 5mm in diameter and a scintillation detector. During the measurement, it emits, disperse and transmit photons through the sediments. It determines the density of the material by counting not attenuated photons. Thus, the gamma detection system only counts the photons that have maintained the same primary source energy (GEOTEK, 2019).

Two diametrically opposed ultrasound transducers measure the P-wave velocity at the frequency of 250 kHz positioned perpendicular to the axis of the core. It measures the elapsed time between the transmission and detection of a sound wave after being attenuated. It calculates the velocity by dividing the tube diameter by the signal's transit time (GEOTEK, 2019).

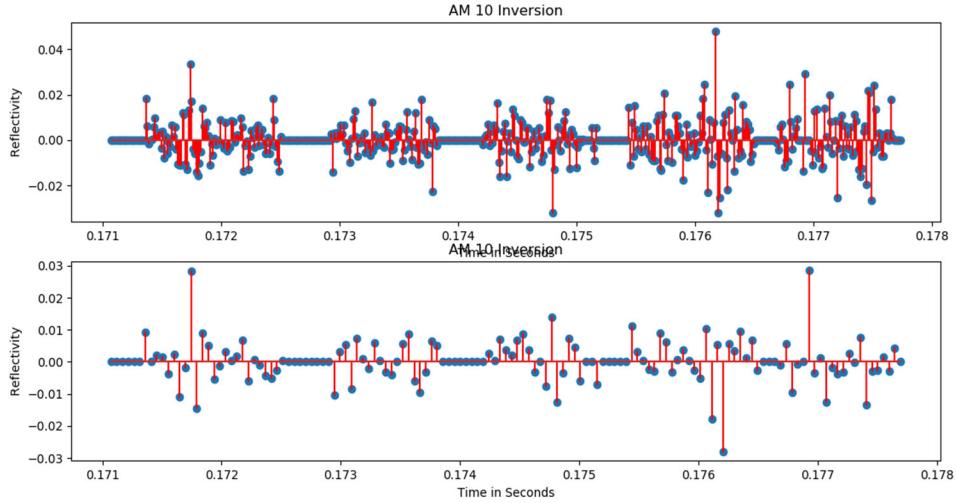
Due to logistic issues, the core was split into five subsections each one with 1 m long. This operation uses a plastic cap to seal the core, which leads to wrong measures at the top and base of each section. Figure 4 shows the VP, density and Core Length profiles after the deletion process.



*Figure 4 - P-wave velocity profile, density profile and core length profile.*

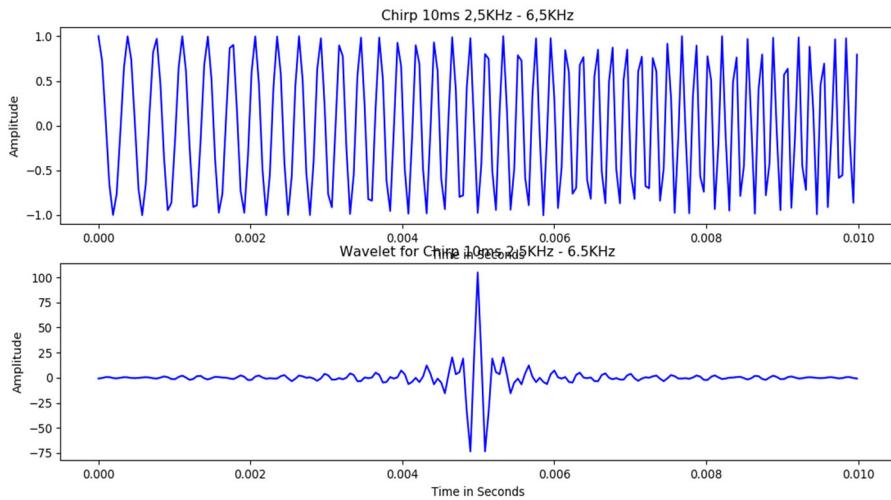
The product of these two profiles (VP and density) generates an impedance measure, which we use to create a reflectivity function. This function models the elastic Impulse response expect from Earth. Since we are trying to use it with Sub-bottom profile data it is good to put them both in the same time domain. At this point it is essential to notice that the SBP has a higher sample

interval (four times) than the reflectivity interval which is critical to avoid artifacts or have some alias effect. Figure 5 shows the resultant reflectivity and the reflectivity resampled to the sample interval of the SBP data (48 microseconds).



*Figure 5 - Reflectivity and Reflectivity resampled. It is possible to note the gap between data due to corers' edges.*

To generate a synthetic trace to compare with the one from the SBP data, we convolve the reflectivity function calculated from MSCL profiles with the wavelet generated by convolution between the chirp-signal with itself (YLMAZ, DOHERTY, 1987). The chirp signal has a 10 milliseconds pulse length and a linear form starting at frequency 2500 Hz and end frequency of 6500 Hz. Figure 6 shows the chirp signal in time, and its wavelet generated.



*Figure 6 - Chirp in time and its wavelet.*

To compare the two traces, we used SbpPy to load the traces from survey seg file to a SbpPy data structure. The method `readtraces` returns a NumPy matrix where it is possible to access the data traces from SBP file. Once this data is in a NumPy array, the user can print using any plotter library like matplotlib for example. Using the SbpPy library, we plotted the Figure 3.

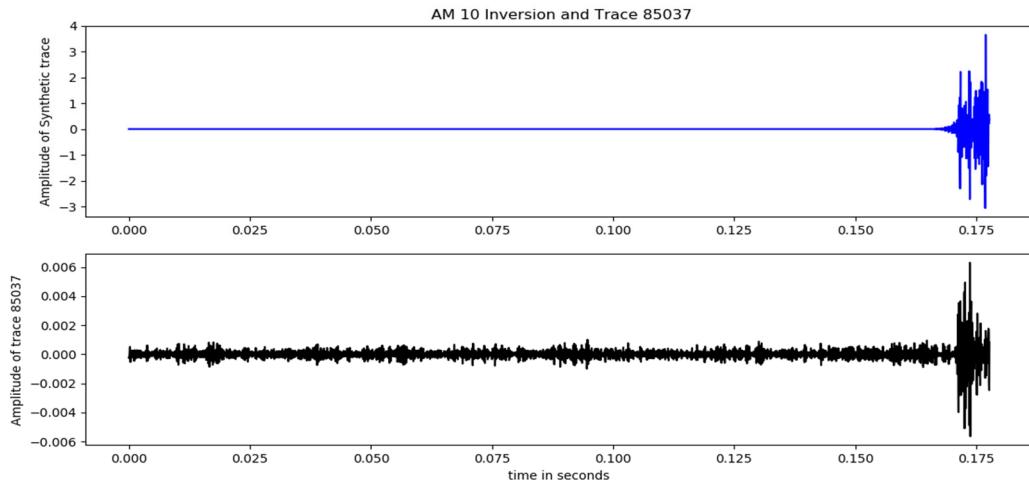
It is easy to get useful information from the SBP file like the minimum and maximum coordinates using the methods `getMinMaxCoords()`. We used methods to read the trace header to check which trace is the closest one to core AM10. We choose the trace #85037 to compare with the synthetic trace.

## RESULTS

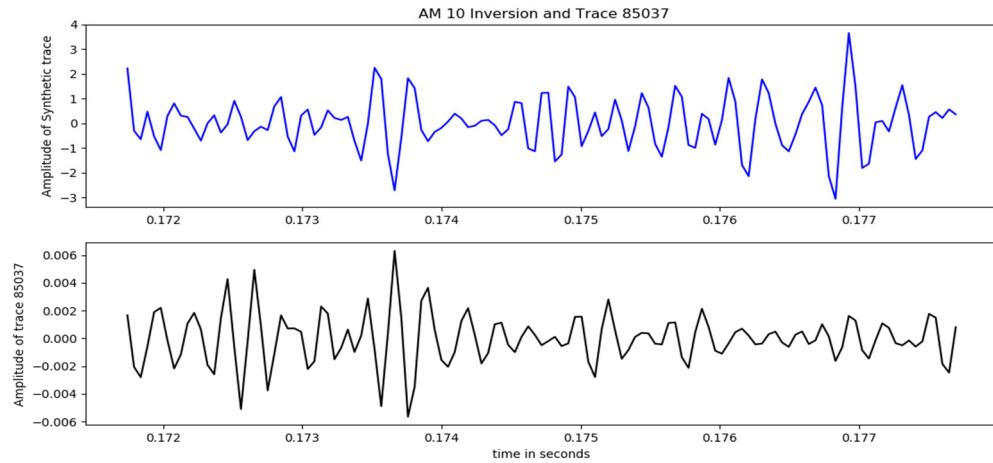
After retrieving the trace #85037 information using SbpPy, it is ready to compare with the synthetic trace generated. No USBL system was used to control the exact position of the corer device at the seafloor; Thus, the coordinate used is referenced to the ship's GPS system. Due to lack of data at the top and bottom of each sub-section the synthetic trace was not a perfect match. We have a lot of expected attenuation, which we want to measure in future works to know if it is

possible to have an indication of the sediments type. In fact, the lack of data makes an impact in continuity of the trace, some Gibbs effects caused by it.

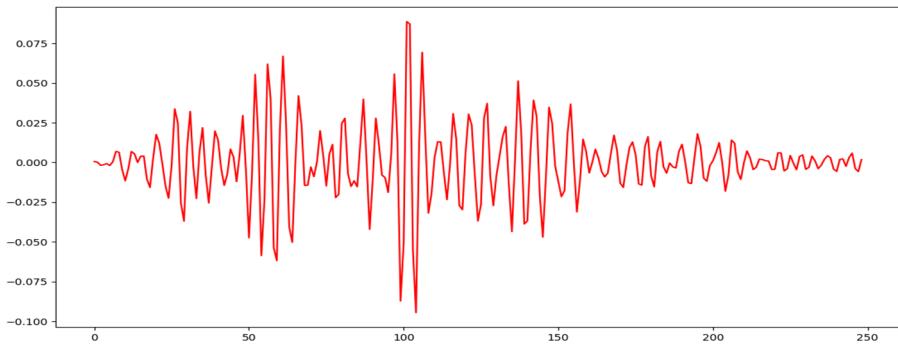
Figure 7 shows them both the synthetic and the original field trace. Figure 8 is a zoom in. Figure 9 is a cross-correlation between the two signals where it is possible to confirm a misfit.



*Figure 7 - The Synthetic trace on top and Acquired on Bottom.*



*Figure 8 - A zoom in the beginning of both traces to compare phase and amplitudes.*



*Figure 9 - A cross-correlation between the synthetic trace, and the original trace, the misplacing is shown.*

## CONCLUSIONS

We conclude that SbpPy library enables users to access the information in SBP files and to afford it in a structured way. It will help in future studies regarding spreading punctual information like geotechnical sampling or geological sampling into SBP files which has 2D behavior or even 3D. The library will help to push high-resolution seismic to data science frameworks. The quality of a synthetic trace depends on the continuity of the profile, and perhaps with more extended profiles, we may reach better results.

## ACKNOWLEDGEMENTS

This work was conducted during a scholarship supported by the International Cooperation Program CAPES. Financed by CAPES – Brazilian Federal Agency for Support and Evaluation of Graduate Education within the Ministry of Education of Brazil.

We would like to thank the support from Natacha Rocha from CGG, Elionardo Pintas and Matheus Sobreira from Petrobras.

# **The inverse of envelope operation. Recovering the original seismic waveform only from instantaneous amplitude using deep convolutional networks**

Cunha, J. B.<sup>1</sup>, Ayres Neto, A.<sup>1</sup>, Nadeu, C.<sup>2</sup>

<sup>1</sup> Universidade Federal Fluminense, General Milton Tavares de Souza Avenue, Campus da Praia Vermelha, Niterói, RJ, Brazil

<sup>2</sup> Universitat Politècnica de Catalunya, Campus Nord, Jordi Girona 1-3 Barcelona, Spain

## **ABSTRACT**

When exploring or producing a marine oilfield, before installing new producer wells or submarine infrastructures in the seafloor, companies perform a high-resolution and ultra-high-resolution acoustic surveys. These surveys collect centimetric information of the first hundred meters of sediments and rocks to detail the risks a well-trajectory will face through drilling operation or compute safety factors for slopes and the risks in a route of a pipeline. Ultra-high-resolution seismic acquisitions performed in the past with sub-bottom profilers were stored only as seismic envelope (instantaneous amplitude) instead of the full seismic waveform, leading to a massive amount of legacy data without phase information. To retrieve the seismic waveform from an envelope, we introduce the un-envelope algorithm based on two deep convolutional neural networks. It was tested in real data from Bransfield basin, Antarctic, and achieved a reconstruction with at least 90% of matching. The main objective of retrieving the full seismic waveform from an envelope data is the use of seismic attributes on it. The data can also be used in numerical modeling on geotechnical studies, providing vertical precision and accuracy in seismic interpretations. The risk for the installation of oil and gas production facilities also can be mitigated using phase attributes in the ultra-high-resolution seismic in the detection of a shallow influx of water or gas.

**Keywords:** data reconstruction, high-resolution, machine learning, near surface, seismic attributes.

## INTRODUCTION

At the beginning of the exploration of a marine oilfield or when new producer wells and submarine infrastructures like manifolds and pipelines must be installed in the seafloor, companies perform a high-resolution acoustic survey regarding the first one hundred meters of sediments to provide centimetric information about the geology to their subsea engineers. The information about seabed's morphology comes from echosounders and side-scan sonars. In contrast, details about the sub-seafloor geology come from sub-bottom profilers, S-UHRS (sparker ultra-high-resolution seismic), and geological sampling. The subsea engineers and geologists use this information to detail the risks a well-trajectory will face in the drilling operation, to compute safety factors for geohazards studies and the risks in a route of a pipeline. Reservoir and exploration personnel also use this information as initial parameters for their geological models. Despite being on different scales, it is possible to share faults continuities, stratigraphic sequences, geometry and type of material in each sediment-layer.

Unfortunately, the acoustical data collected with sub-bottom profilers were not treated as high-resolution seismic data for years. Thus, acquisitions performed in the past covering the shallow marine environment were stored only as instantaneous amplitude (envelope) data instead of the seismic waveform, leading to a massive amount of legacy data without the phase information.

The importance of the signal phase in seismic interpretations is undeniable. (TANER, KOEHLER, *et al.*, 1979) introduced the instantaneous phase attribute, which is also a physical attribute to aid in geological interpretations, and since then, seismic attributes became ubiquitous. The

instantaneous phase attribute can be used as a discriminator for geometrical shape classification and is the best indicator of lateral continuity and sequence boundaries since it provides a detailed visualization of bedding configuration. It is useful for tracking reflection continuity across a low amplitude area because it is independent of amplitude information. (KOVESI, 1996) designed a phase congruency attribute to detect corners and edges and successfully associated it with karst collapsed structures. (YIN, 2003) used phase inversion in high-resolution seismic profiles to indicate mounds in the East China Sea, which were formed by gas or fluid escaped. (NING, 2009) also identified gas hydrates – a significant risk factor for geohazards - on mud diapirs through impedance inversion. (PARTYKA, 2005) showed phase attributes could be used to map subtle faults, (DAVOGUSTTO, DE MATOS, *et al.*, 2013) mapped discontinuities in spectral-phase components and correlated to unconformities in the base of channels.

The problem of retrieving phase information from the one-dimension envelope is ill-posed. It does not have a unique solution since every phase is an answer without other information and constrictions (HAYES, 1982), (BATES, 1978) and (BRUCK, SODIN, 1979).

We developed an end to end system of deep neural networks that solves the problem of recovering the seismic waveform of a high-resolution seismic trace using only its seismic envelope attribute (instantaneous amplitude).

The system is based on two deep convolutional networks trained in a supervised learning way on real sub-bottom profiler data from acquisitions on the Antarctic continent in 2018. The first network learned how to classify any envelope trace in one of many classes that represent pairs of possible window

lengths and hop sizes; the second one learned how to compute the spectrogram of a frequency Wiener mask based on envelope trace, and window-hop parameters inferred by the first one. The spectrogram of this mask multiplied by the spectrogram of the envelope give us the spectrogram of the desired waveform signal. And through the Griffin Lim algorithm, (GRIFFIN, LIM, 1984), it is possible to recover the waveform signal from its magnitude spectrogram.

Different from (RU-SHAN, 2014), this contribution does not bring an inversion of the seismic attribute envelope to recover low frequencies on conventional seismic data to aid in the full waveform inversion problem. Instead, we are un-enveloping the seismic data, i.e., we are, trace-to-trace, performing the inverse operation of the envelope to recover the original seismic waveform, bringing the powerful seismic attributes possibilities to shallow seismic interpretation.

## METHODOLOGY

According to (GABOR, 1946), the complex signal in rectangular coordinates is defined by:

$$z(t) = s(t) + i \text{Hi}\{s(t)\} \quad (12)$$

Where  $z(t)$  is the complex signal;  $s(t)$  is the real component of the signal, in this case, the pressure variation along time that we measure with sub-bottom profilers transducers in the field along Nadir direction;  $i$  stands for the imaginary unit ( $i = \sqrt{-1}$ ); and  $\text{Hi}\{s(t)\}$  is the Hilbert transform of  $s(t)$ . Equation (12) is also known as the analytic form of signal  $s(t)$ .

The Hilbert transform is omnipresent in communications and signal processing; among other possibilities, it can generate an analytic signal from a time series. The Hilbert transform in a convolutional way is defined by:

$$H\{s(t)\} = h(t) * s(t) \quad (13)$$

Where  $h(t)$  is the Hilbert kernel (or Hilbert impulse response,  $h(t) = \frac{1}{pi.t}$ ), and  $s(t)$  is the time series to convert to analytic signal. The analytic form of the signal can also be written in polar coordinates following Euler's formula:

$$z(t) = A(t)e^{-i\varphi(t)} \quad (14)$$

Where  $A(t)$  is the instantaneous amplitude of the signal, also known as the envelope, and  $e$  is the base of the natural logarithm,  $i$  is the imaginary unit, and  $\varphi(t)$  the instantaneous phase of the signal. The instantaneous amplitude and the instantaneous phase can be calculated by:

$$A(t) = \sqrt{s(t)^2 + H\{s(t)\}^2} \quad (15) \quad \varphi(t) = \tan^{-1}\left(\frac{H\{s(t)\}}{s(t)}\right) \quad (16)$$

(TANER, KOEHLER, et al., 1979) introduced the envelope seismic attribute. The envelope operation calculates the instantaneous amplitude  $A(t)$  from its seismic waveform  $s(t)$ . This work developed a way to retrieve the seismic waveform  $s(t)$ , knowing only the instantaneous amplitude  $A(t)$ . For this contribution, only high-resolution envelopes acquired with sub-bottom profilers were used, but, with adaptations, this methodology may be expanded to other scenarios.

## The sub-bottom profiler data

Sub-bottom profilers are marine acoustical devices used to create a 2D seismic (or 3D depending on assembly) to survey the upper marine environment below the seafloor. They are constituted by ceramic transducers capable of convert electrical energy to mechanical energy (sound) and thus act in the transmission of controlled sound pulses and also in the reception converting sound to electrical energy to register the effect of the pulse interference with the probed medium. Sub-bottom profilers can be hull-mounted, be towed by a vessel or installed on AUVs (Autonomous Underwater Vehicles) or ROVs (Remote Observation Vehicles).

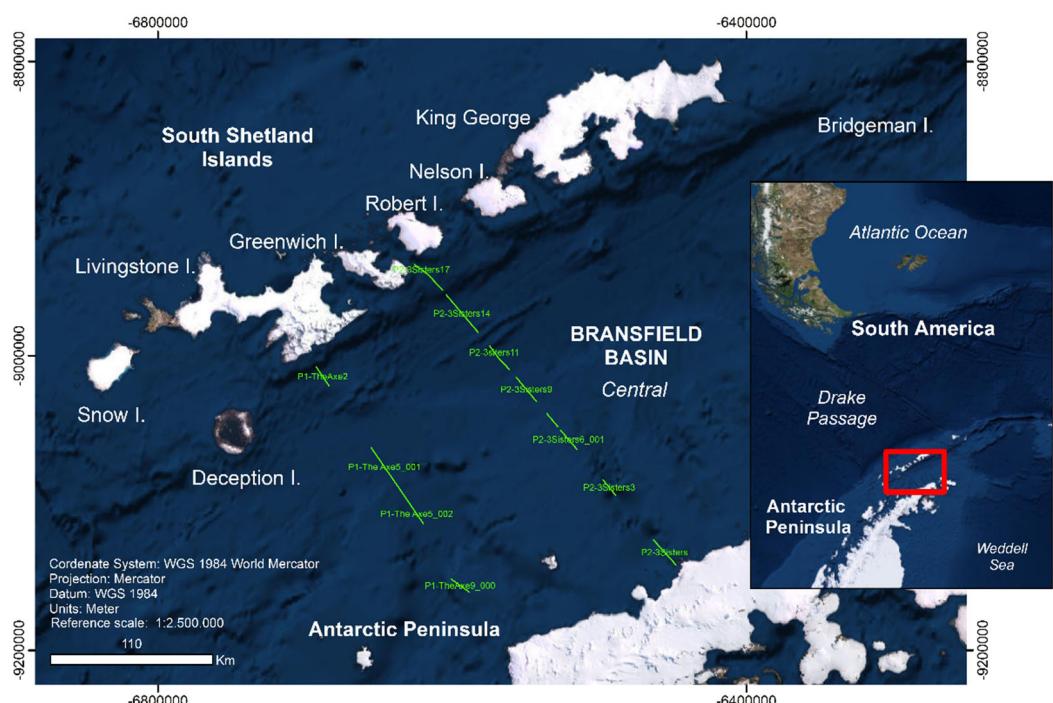
The operation principles of the sub-bottom profilers are different from side-scan sonars once they are based on specular reflection (the signal falls vertically downwards). Like in the marine conventional reflection seismic acquisitions, sub-bottom profilers register the contrast of acoustic impedance between the sedimentary layers of the seabed. For (THEUILLON, STÉPHAN, *et al.*, 2008), surveys with sub-bottom profilers may also make inference about the reflectivity, and absorption coefficients of the layers. The diameter of the ceramic disks that physically implements the transducers limit the operating frequency range of the method, as they need to oscillate at the selected operating frequency, but they work in kHz range, and it has a plentiful spectral bandwidth. Sub-bottom profilers use CHIRP pulses, and its seismic processing is equivalent to land Sweep acquisitions, due to its known source signature, (CECILIO, A. B., CUNHA, J. B., AYRES NETO, 2019).

The profiler emits pulses while sailing, the number of shots per time is constant (ping rate). However, the shots per distance is variable and depends on

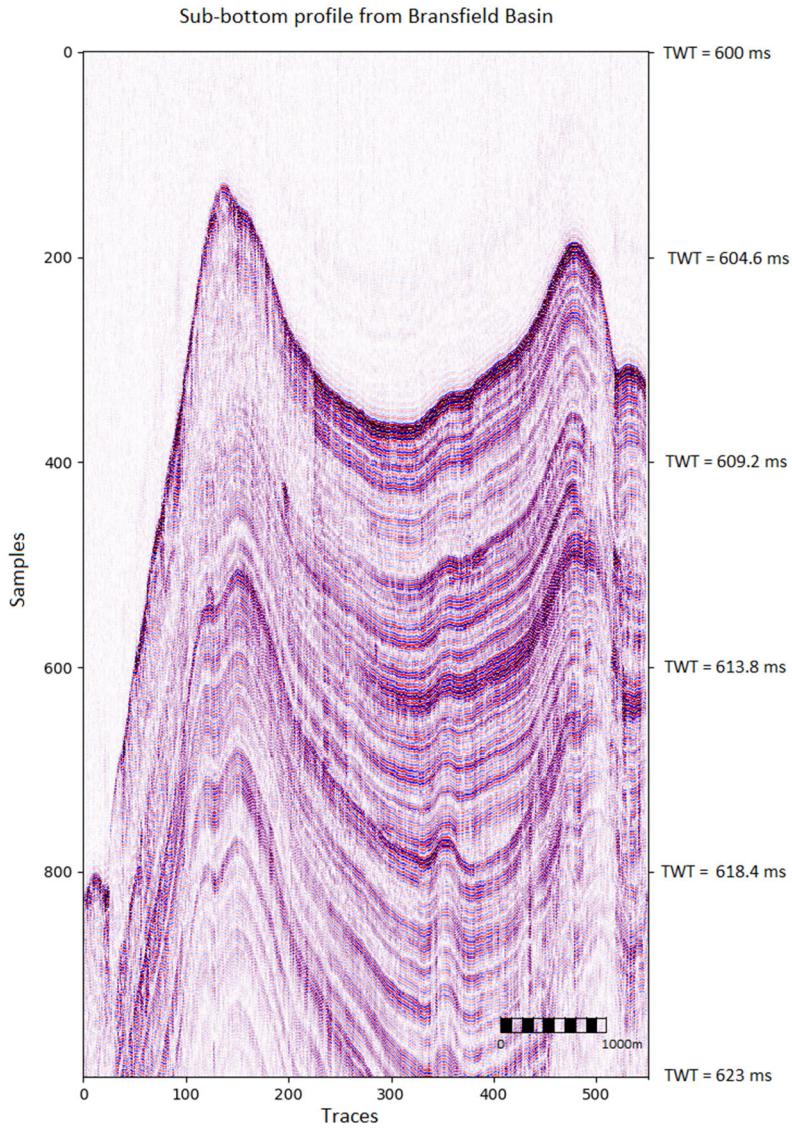
navigation speed and depth. The signal penetration is directly proportional to the power of the generating source and inversely proportional to the frequency used. It depends strongly on the type of sediment that it faces. In coarse sediments, the penetration is low, while in mud, it can penetrate up to 80 meters.

The sub-bottom profiler data can be treated as a single channel zero-offset seismic because it receives the reflected pulse very close to the position it was emitted. It has ultra-high-resolution since its high-frequency operation provides centimetric wavelengths.

For this work, we used high-resolution seismic data acquired in the Bransfield basin - Antarctica in 2018 with a hull-mounted Kongsberg SBP 300 system installed on the Brazilian navy oceanographic research vessel Maximiano. The water depth of the acquisition varied, but the average was about 500m. The CHIRP configuration was linear, with a frequency range from 2.5 kHz to 6.5 kHz and pulse length of 2 milliseconds. The sampling interval was 23 microseconds, the trace length was 240 milliseconds (10445 samples for trace), and the files were saved during acquisition in the full waveform. Figure 10 shows the localization of the survey, and Figure 11 shows one of the sub-bottom profiler seismic files used.



*Figure 10 - Localization of the eleven lines acquired with sub-bottom profiler in Bransfield Basin, Antarctic 2018.*

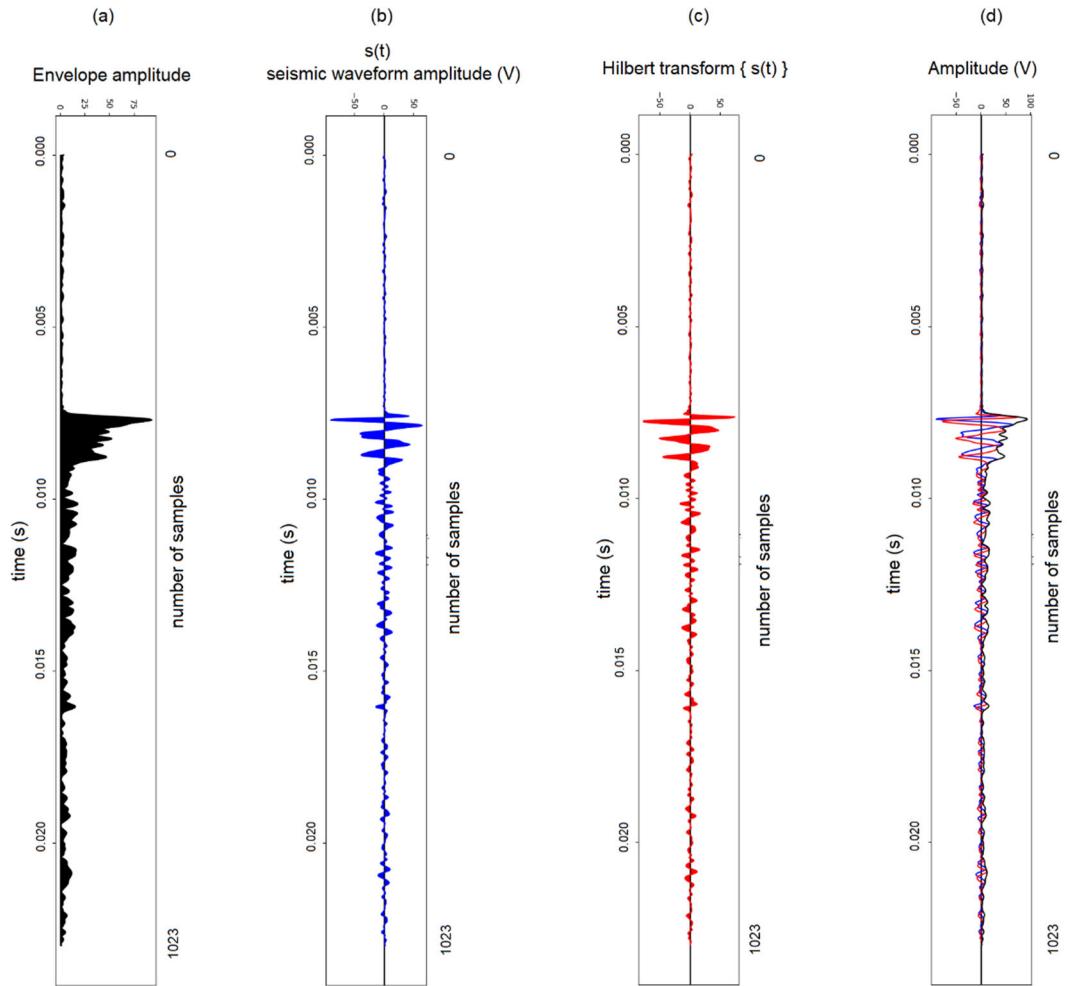


*Figure 11 - One example of acquired file. All acquired traces vertically side by side generates a seismic section, in this example 550 traces with 1000 samples each. The seafloor is the stronger reflection and it is possible to see in this section about 35 meters below the seabed. Each trace is about 9 meters from each other, so the length of this section is 4950 meters.*

## Dataset creation and pre-processing

Initially we checked the useful traces in lines, and the depth (in milliseconds) of the traces that have meaningful information. Then we generate a dataset with 20000 traces, randomly made from traces from different geological environments and different start times with 1024 samples for each trace,

removing any bias it could have. To open a sub-bottom profiler file and convert the traces to arrays, we used a python library called SbpPy, (CUNHA, AYRES NETO, 2019). This dataset with 20000 full-waveform traces was the ground truth for our regression task, it is, the target dataset or labeled data. Then we generate an input dataset from this target dataset using Hilbert transform and equation (15). Figure 12 shows a comparison between one of the input files and the associated target file. The input dataset also has 20000 files with 1024 samples each.



*Figure 12 - The comparison between one input envelope trace in (a) and the seismic waveform in (b) which is the target trace. In (c) the Hilbert transform of (b). The envelope (a) is compound by the squared root of the squared sum of (b) and (c). (d) shows this relation among them, where the envelope is in black, the real part of the analytic signal in blue, and the imaginary part of the analytic signal in red. All signals have dimension of 1024 samples.*

## Time-frequency representations and frequency masks

We tried to use a simple fully connected neural network to perform the regression task to bring the input directly to the target. Still, since it is too complicated to train in raw audio forms, it had a poor performance, even testing a different number of layers, activation functions, capacities (number of neurons), and other hyperparameters. Moreover, we ran a PCA analysis using Scikit-learn (version 0.22.2) PCA decomposition, where we could verify the random character of both datasets.

Time-frequency representations verifying constrictions have enough redundancy and can reconstruct signals from consistent spectrograms, (GRIFFIN, LIM, 1984). We choose the STFT (short-time Fourier transform) as our time-frequency representation because it is ubiquitous and easy to implement. The discrete STFT is defined for the discrete input sequence  $x[n]$  by equation (3).

$$STFT\{x[n]\}(m, \omega) = \sum_{n=mL}^{n=mL-(L-1)} x[n]w[mL - n]e^{-i\omega n} \quad (3)$$

Where  $w$  denotes the window  $w[n]$  in our case we only used the Hanning window;  $L$  is an integer that denotes the separation in time between adjacent short-time sections, also known as hop size. The  $x[n]$  is the input sequence,  $w[mL - n]$  the sliding window, and the last term is the Fourier transform operator. The time-frequency representation STFT is a square matrix, where we assume each row is a bin of frequencies and each column a windowed (chunk) part of the signal. The input sequence is framed with an overlap (to provide redundancy), each frame is Fourier transformed, and the complex result is added to the matrix.

The matrix stores the magnitude and phase for each point in time and frequency. The number of lines of this matrix is defined only by the number of coefficients of the Fourier transform. The number of columns is given by the length of the provided time series as input and the hop size. Optimizing these three parameters (the number of Fourier coefficients, the length of time series, and the hop size), it is possible to obtain a spectrogram that represents the input time series. The magnitude squared of the STFT yields the spectrogram representation.

(NAWAB, QUATIERI, *et al.*, 1983) introduced the unicity conditions to guarantee a unique correspondence between the signal and its STFT magnitude, among them, to the window: to know the window function, this window must have a length larger than two samples ( $N_w > 2$ ), and cannot have zero values (No zeros within  $N_w$ ). Regarding the input sequence, it must be one-sided and have at most  $N_w - 2$  consecutive zero samples between any two non-zero samples. Regarding the hop size, it must be higher than one sample and smaller or equal than half of the window size ( $1 < L \leq [N_w/2]$ ), i.e., the window must overlap at least 50%. (ROUX, ONO, *et al.*, 2008) introduced the constrain of consistency of the spectrogram, and (STURMEL, DAUDET, 2011) resumes state of the art about signal reconstructions from STFT magnitude. The inversion of an STFT is achieved by a synthesis operator STFT-1 defined in equation (4):

$$\tilde{x}[n] = STFT^{-1}\{X(m, \omega)\} = \sum_m w[mL - n] \sum_{\omega} X(m, \omega) e^{i\omega n} \quad (4)$$

The  $\tilde{x}[n]$  represents the reconstructed sequence. The constraining (17) can check the consistency of  $X(m, \omega)$ :

$$X(m, \omega) - STFT [STFT^{-1} [X(m, \omega)]] = 0 \quad (17)$$

Due to the Heisenberg-Gabor limit, one cannot simultaneously localize a signal in both the time domain and the frequency domain. It is not possible to achieve a high temporal resolution and high-frequency resolution at the same time. Using a wide window length to compute an STFT, it is possible to achieve a good frequency resolution but a fair resolution in time. On the opposite, if the window length is narrow, we have a fair frequency resolution and a good resolution in time. Even if we could set only one window length and a specific hop size to generate good spectrograms from all our input and target signals, we still have to train a network to learn how to generate the desired output spectrogram from the inputted one. This task not always converges to an answer, and the training is difficult as the previous one.

Inspired in works of noise removal in audio speech, acoustic data enhancement, and source separation, that solves non-linear inversions using spectrograms like in (XU, DU, *et al.*, 2015), (TAKAHASHI, AGRAWAL, *et al.*, 2018), (BENDORY, EDIDIN, *et al.*, 2019), (WILLIAMSON, WANG, *et al.*, 2016), (LEE, Yuan-shan, WANG, *et al.*, 2017), we propose to treat the high-resolution seismic envelope signal as a composition of two signals, like the analogous signal plus noise. One of the signals is the desired seismic waveform, and the other signal is its imaginary part, and any residual, like suggested in equation (15). (JEN-TZUNG CHIEN, 2019) states that speech separation or data enhancement problems can be seen as a regression problem and can be tackled using supervised learning. That is the reason we choose this approach. (MACK, HABETS, 2020) and (KAVALEROV, WISDOM, *et al.*, 2019) propose to use a frequency mask to deep filtering noise in signals, using (WIENER, 1949) filtering

concepts. We decided to create a mask, adapted from a generalized Wiener frequency mask:

$$M(m, \omega) = |X_d(m, \omega)|^2 / |X_e(m, \omega)|^2 \quad (18)$$

Where  $M(m, \omega)$  is the computed mask,  $X_d(m, \omega)$  is the STFT of the desired output, and  $X_e(m, \omega)$  is the STFT of the enveloped input. This mask, when multiplied by the magnitude spectrogram of the envelope, returns the magnitude spectrogram of the desired seismic waveform. Since each pair of input envelope and desired signal returns a different mask, we decide to train a network to learn how to retrieve the respective mask given the envelope.

### Auxiliary dataset for mask training

From the previous datasets, we selected randomly 2000 files from the enveloped inputs and their matches from the target dataset generating an auxiliary dataset. We fixed the number of Fourier coefficients to 128 based on observation of the size of the features in the frequency domain and the Nyquist frequency. Once the sampling interval of the data is 23 microseconds, the Nyquist frequency is 21.739 kHz. The number of lines in STFT is 65 for 128 Fourier coefficients, and each bin has a 169.83 Hz of resolution. Fixing this number of Fourier coefficients also lead us to the maximum value to the window length, which is 128 samples. And according to Nawab constrictions, the maximum hop size is 64 samples, to allow an overlap and add in the reconstruction. For each file of the auxiliary dataset, we looped through all possible window lengths and all possible hop sizes computing the STFT of the envelope input and the STFT of the real target. And while in this loop, from both STFT, we calculated the magnitude spectrogram and applied equation (18) to obtain the frequency mask

to that pair of signals. Figure 13 shows an example of three spectrograms of input, output, and mask.

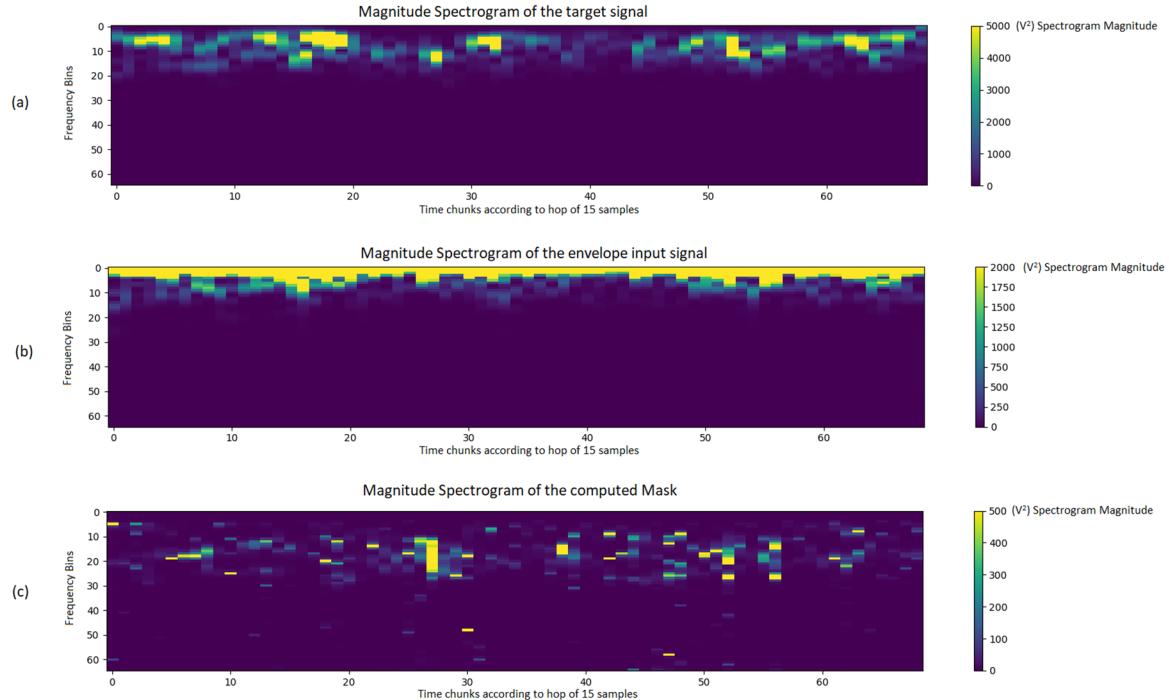
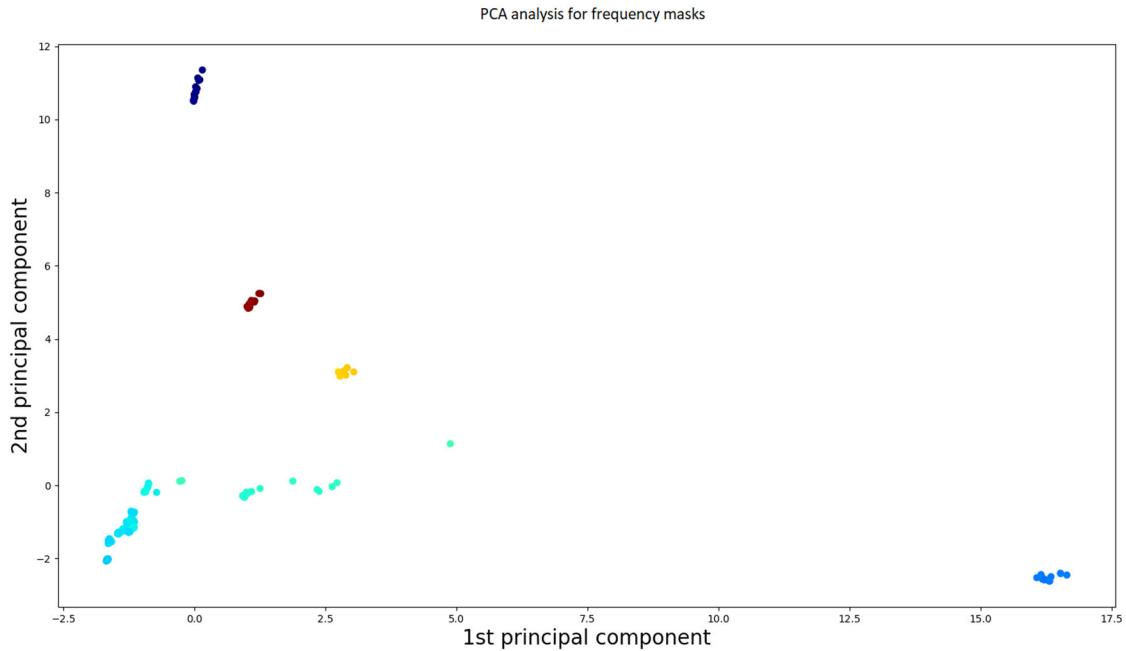


Figure 13 - Three spectrograms of input, output, and mask. In (a) on top the magnitude spectrogram of the target signal (square modulus of STFT(seismic waveform)), in (b) the magnitude spectrogram of the envelope signal, and in (c) the magnitude of the spectrogram of the computed mask for this pair.

We compute using Griffin Lim Algorithm the reconstructed signal from the magnitude spectrogram generated by the product of the spectrogram of the envelope input and the spectrogram of the calculated mask. The Griffin Lim Algorithm has as input parameters the magnitude spectrogram from which it will recover the original signal, the number of iterations to converge, which we set to 500, the window type (Hanning), and window length / hop size that changed at every loop step. Then the reconstructed signal is compared to the target signal using the Pearson Correlation Coefficient. We used Dynamic time warping (GIORGINO, 2009) to illustrate the synchrony of the signals in results section.

We save all the window length, and the hop size pairs, which led to a Pearson's correlation coefficient higher than 0.90 (at least 90% of matching) to binary matrices where the lines are the different hop sizes and the columns are the different window length. We used 1 to represent a valid pair and 0 for an invalid pair of window length and hop size. We also save all the computed masks according to the criterion above for each envelope input file. More than one pair of window length and hop size can achieve the same result of reconstruction for the same envelope file. We save all of them to have a data augmentation to help in the training phase, 87637 records of valid masks were generated in this process, 2000 files with windows-hop matrices, and we also saved the 87637 magnitude spectrograms for each envelope according to their masks. Since the hops have different sizes, we zero-padded the mask to the worst case, which is the hop size equals to six samples. This way, all masks consist of a matrix of 65x171.

We perform a PCA analysis using all the computed masks to check if they could be clustered, and yes, they can be grouped in a few classes. Figure 14 shows this result for 262 masks.



*Figure 14 - Principal Component Analysis using 262 randomly computed masks where it is possible to see some clusters they could group. It shows they have similarity and could be learned from a network.*

Another impressive result is the ratio between the hop size and window length. We plotted and verified the minimum and maximum values to the ratio, and it is between 0.26 and 0.34, i.e., the minimum overlapping of 66% and the maximum overlap of 74%.

### The 1st deep convolutional network – classification task

Since we know for 2000 different envelope files which pairs of windows size and hops size works, it is possible to train a network to classify an envelope input into one of the possible pairs. Indeed, more than one is an answer to each input, so it is a multi-label classification problem, where we must retrieve at least one valid result. Inspired by the idea of automatic tagging music used by (LEE, Jongpil, PARK, *et al.*, 2019), we used Pytorch (PASZKE, GROSS, *et al.*, 2019) to design a deep convolutional neural network to multi-label classify the raw audio

input. The raw audio input has dimension of 1024. We called this model "WinHopClassifier" and it has six convolutional blocks and a fully connected layer at the end. Each convolutional block has a 1-D convolution layer, followed by a 1-D batch normalization layer, a 1-D max pooling layer, and a ReLU (rectified linear unit) activation function. The number of kernels, kernel sizes, and strides are shown in figure 15.

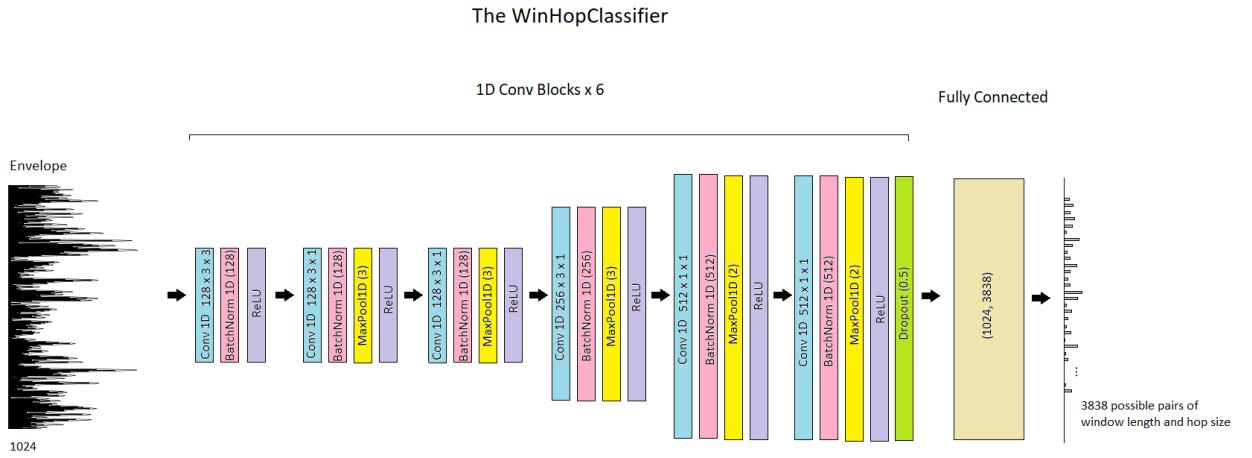


Figure 15 - The WinHopClassifier model design.

The fully connected layer has 3838 output neurons, to fit all window-hop pair possibilities, i.e., window lengths from 28 to 127 samples, and hop sizes from 6 to 44 samples, after the previous analysis. The loss function used was binary cross-entropy with logits, the optimizer was a stochastic gradient descent with Nesterov, with a fixed learning rate of 0.01, momentum=0.9. We split the auxiliary dataset into training (90%) and validation (10%), regularized the input using Scikit-learn min-max scaler, flattened the output matrix, which contains the classes (window length-hop size pairs) and trained it for sixty epochs. The binary cross-entropy with logit function returns the level of confidence in each of the multiple

classes at the end, thus choosing the higher score leads to a pair of a window length and hop size that solves the reconstruction with at least 90% of matching.

## The 2nd deep convolutional network – regression task

Inspired in the speech spectrogram regression from intracranial records, (ANGRICK, HERFF, *et al.*, 2019), we designed a deep convolutional neural network to implement a regression from a magnitude spectrogram of an envelope input to a magnitude spectrogram of the desired mask. We called this model "MaskNet" and it has four convolutional blocks and one fully connected layer at the end. Each convolutional block has a 2-D convolution layer, followed by a 2-D batch normalization layer, an ELU (exponential linear unit) activation function, a 2-D max pooling layer, and 50% of dropout. The number of kernels, kernel sizes, strides, and padding are shown in figure 16.

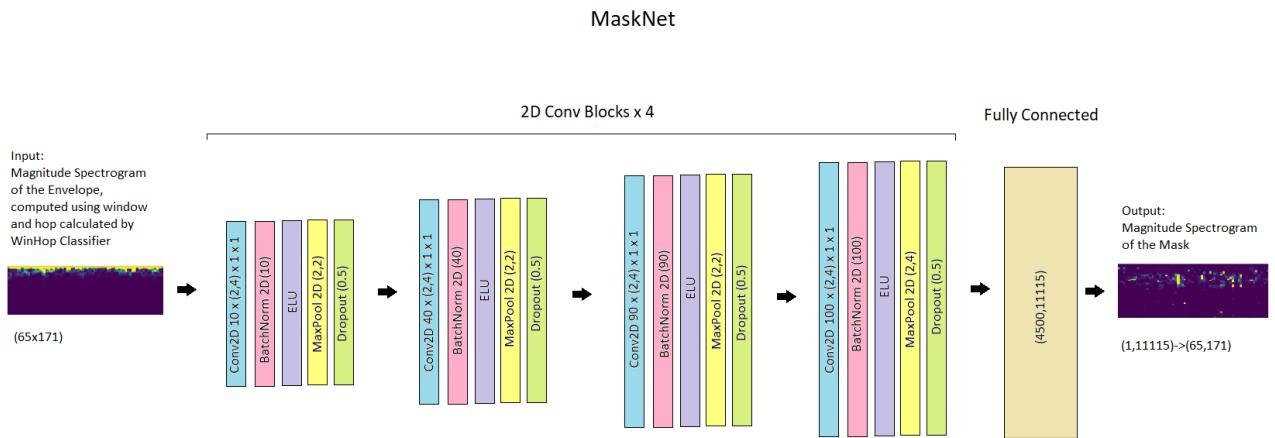
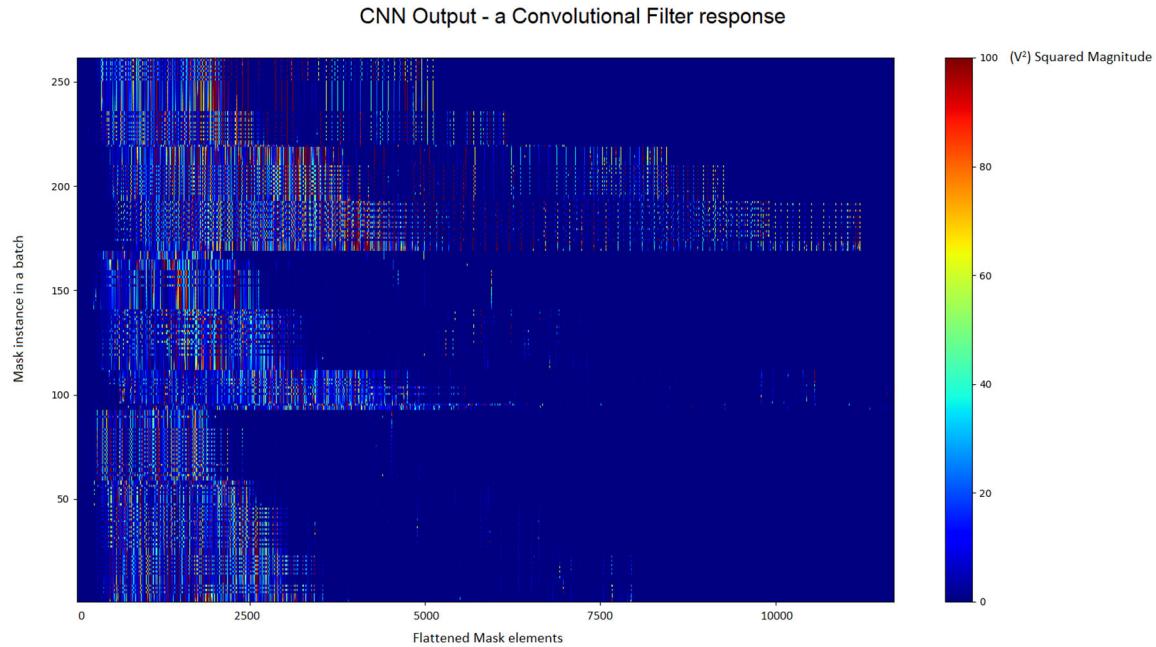


Figure 16 - The MaskNet model design

We used ELU to deal with the non-linearity issue. The fully connected output layer has 11115 neurons to fit the flattened masks ( $65 \times 171 = 11115$ ). The loss function was mean squared error, with Adam optimizer, with a learning rate of 0.01, and batch size of 256. We used only 65536 files from the 87637, to fit in (216). We split it into the train (90%) and validation (10%) datasets. We

regularized the input magnitude spectrograms for the envelopes, and the output flattened magnitude spectrograms of the masks with Scikit-learn min-max scaler. We also trained for fifty epochs. An example of output batch from the last convolutional layer before it enters the fully connected layer showing the pattern of flattened learned masks is shown in Figure 17.



*Figure 17-CNN Output - A convolutional filter response for a batch of 256 flattened masks.*

If this pattern could be expressed in a formula, this formula will be the equivalent of the inverse of equation (15) in frequency domain. Since it still not possible to be expressed in a formula, we solved the problem using the un-envelope algorithm.

### The Un-envelope algorithm

Finally, the use of these networks follows the un-envelope algorithm explicit in Figure 18.

---

**Algorithm 1** Un-envelope

---

```
1: initialization w, h, A{1,3838};  
2: NFFT ← 128;  
3: WHC ← load WinHopClassifierModel;  
4: MaskNet ← load MaskNetModel;  
5: Data: envelope{1,1024};  
6: WHC.eval( );  
7: MaskNet.eval( );  
8: A = WHC(envelope);  
9 : w, h ← max(A);  
10: envSTFT = STFT(envelope, w, h, NFFT);  
11: envSpec = |envSTFT |2;  
12: envSpec ← zeropadding(envSpec, (65,171));  
13 : maskSpec = MaskNet(envSpec);  
14: targetSpec = envSpec x maskSpec #element-wise Multiply;  
15: target = GLA(targetSpec, w, h, NFFT, iter=500);  
16: return target;  
17: end
```

---

Figure 18 - The un-envelope algorithm

## RESULTS

We used Scikit-learn metrics AUC (area under the curve) to compute the accuracy of our classifier, and it is 0.9022. We also calculated the number of hits to compute a true positive rate TPR =0.9201 and a final accuracy of 86%. These values are below state of the art (LEE, Jongpil, PARK, *et al.*, 2019) in audio classification 0.913 and accuracy = 89%, but it worked satisfactorily, and our input

data is not an audio raw. Instead, it is an envelope, and this comparison may be unfair.

The loss per epoch curve of the training and validation of the MaskNet is shown in Figure 19.

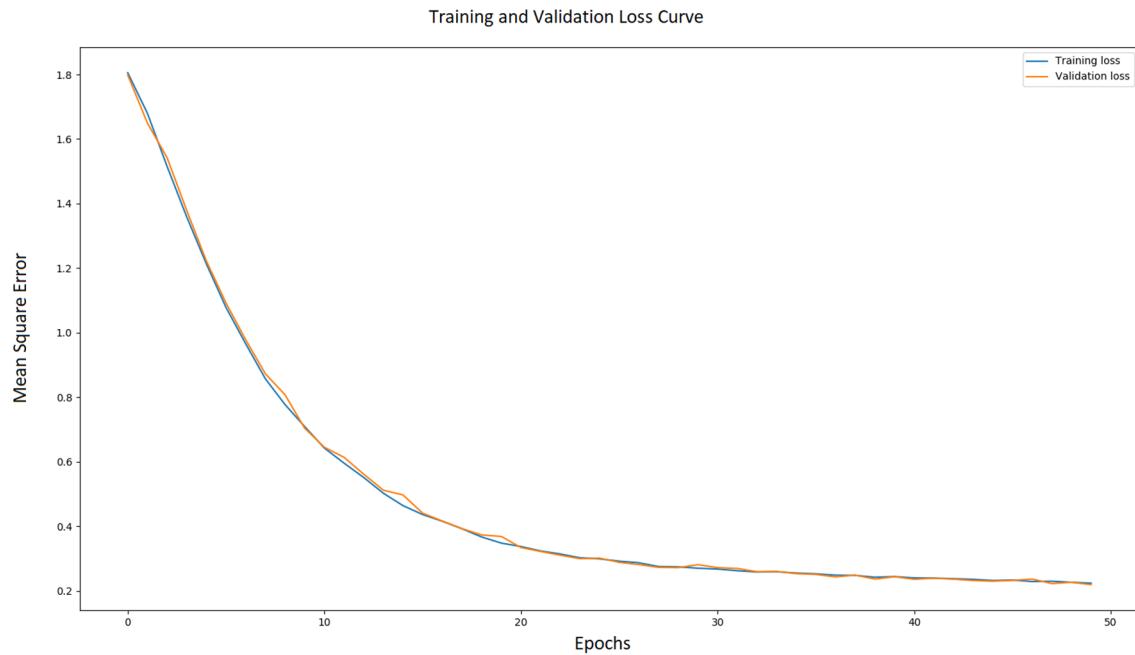
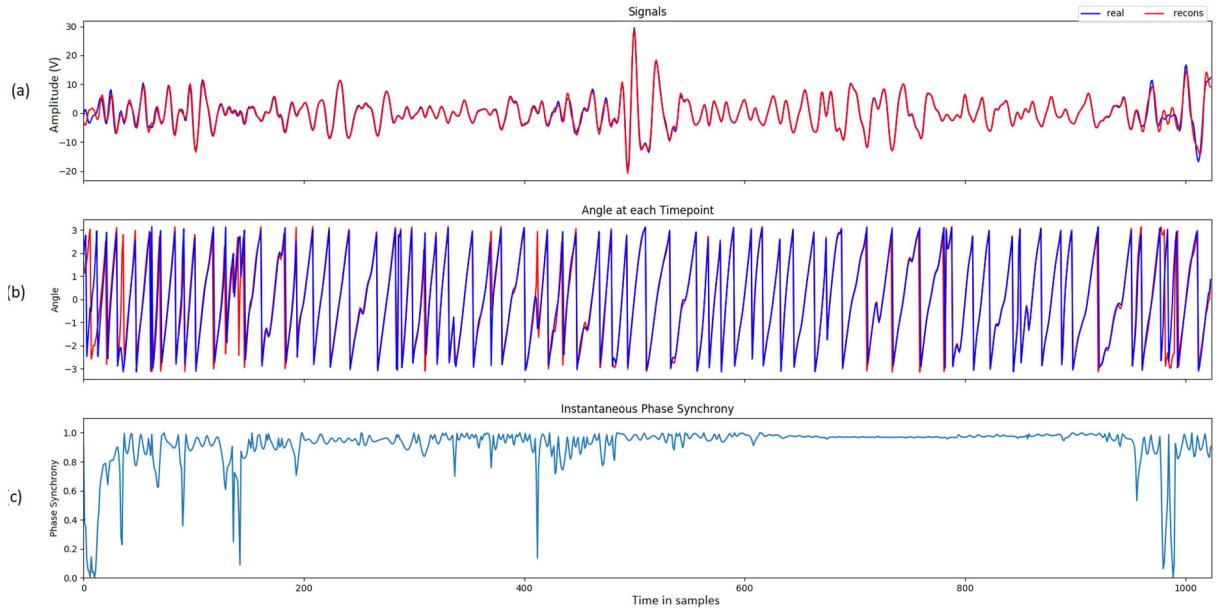


Figure 19 - The Loss per epoch curve of the training and validation of the MaskNet. The values of Mean Squared error to each epoch with training set is in blue, and to validation set is in orange. We used early stop in the 50th epoch with MSE=0.21

There is a lack of baselines, since we don't have a spectrogram regression result from other work to compare. We didn't want to compare with sound files because the range of frequencies and the nature of the signals are too different. It took 48 hours to train the regression and 36 hours to train the classification using CPU (Intel i7) instead of GPU. Still, this result ( $MSE = 0.21$ ) could retrieve waveform signals with at least 90% of matching, which is enough to solve the actual absence of information. Figure 20 shows an example of the result.

Example of Reconstruction by Un-Envelope algorithm



DTW Minimum Path with minimum distance: 491.54

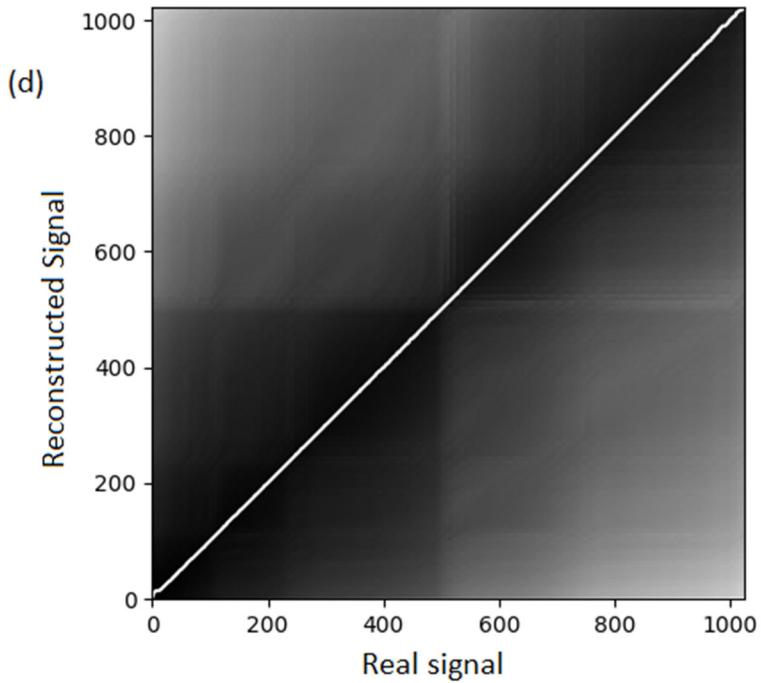


Figure 20 - One reconstruction example using window size =89 and hop size=24. This sample has a Pearson's  $r$  value of 0.9823. In (a) the two waveforms, the reconstructed in red to be compared with the target in blue, it is possible to see small border effects in the very beginning and end. In (b) the wrapped phase between  $-\pi$  and  $\pi$  to each sample. And in (c) the synchrony between the two signals, values close to one show better synchrony. The DTW was applied in this example just to illustrate the synchrony of both signals, it is shown by the 45° line in detail (d) and it was used only as a visual metric.

Once the networks are trained the evaluation time is instantaneous, i.e., take seconds to compute the pair of window length and hop size from an envelope trace and to perform the regression from one spectrogram to the mask spectrogram. It is not necessary to train it again, it can be loaded and used. To run the Griffin Lim algorithm also take seconds when it is set to 500 iterations.

This methodology could be expanded to conventional reflection seismic acquisitions, changing the number of Fourier coefficients to fit in a different Nyquist limit. On conventional seismic acquisitions, the sampling rate is 2 milliseconds which has Nyquist frequency on 250 Hz, the size of the features is expected to be different.

We found an issue regarding the border effect in the reconstruction, but if the signal is windowed before the use into the algorithm, this can be mitigated. Another issue is the phase inversion even to high Pearson's correlation coefficients; the point where the phase is inverted is preserved attending the requisites to instantaneous phase attribute. However, the phase is the opposite (rotated 180 degrees) of the expected. More studies on this question are necessary. As a partial solution it is enough to analyze the context of that flipped trace, the traces immediately before and after show the correct phase value.

We used the un-envelope algorithm trained in Bransfield basin data into Santos basin sub-bottom profiler data to test the results. This test data was also acquired as full seismic waveform with the same sampling rate. We computed the seismic attribute of envelope in few traces and tested the algorithm. The algorithm performance was the same as the obtained in validation data and it completed the task of un-envelope successfully.

## CONCLUSION

This contribution introduced a way to recover the seismic waveform from seismic envelopes, using the new developed un-envelope algorithm. The reconstructed signal with at least 90% of matching is achieved at least 86% of the time for high-resolution seismic data collected with sub-bottom profilers.

The ratio between the hop size and the window length chose to perform an STFT for signal reconstruction is also a significant result. The minimum ratio is 0.26 and the maximum 0.34. This considerably decreases the amount of calculations to be computed.

Reconstructing signals from envelopes will bring phase information to legacy data, which will become able to be explored again using seismic attributes. This will allow the data to be used for numerical modeling in geotechnical studies, providing much more vertical precision and accuracy in seismic interpretations. The risk for installation of facilities also can be mitigated with the use of phase attributes in the high-resolution seismic since they can be used for evidence, for example, the presence of a shallow influx of water or gas.

# **Ultrahigh-resolution seismic enhancement. The use of colored inversion and seismic attributes on sub-bottom profiler data**

Cunha, J. B.<sup>1</sup>, Ayres Neto, A.<sup>1</sup>

<sup>1</sup> Universidade Federal Fluminense, General Milton Tavares de Souza Avenue, Campus da Praia Vermelha, Niterói, RJ, Brazil

## **ABSTRACT**

Companies perform acoustic surveys before installing any submarine infrastructures in the seafloor, like new wells, pipelines, manifolds, cables, or wind farms. These surveys provide high-detailed geological information about the seabed and the first one hundred meters underneath the seafloor to subsea engineers and geologists. The prime use of this information by marine geologists is in geohazards analysis. The industry always used the sub-bottom profiler data in a fast-track way, not using its latent excellence. This contribution wants to magnify the potential of the sub-bottom profiler and define it as an ultrahigh-resolution seismic method. Sub-bottom profiler data assists numerical geotechnical analysis, and despite the scaling difference, can be the initial values when modeling velocity, sedimentary layers, and faults continuities. To support it, we present some established procedures from multichannel seismic, like classical seismic attributes applied to sub-bottom data. We computed envelope, instantaneous phase, instantaneous frequency, the cosine of phase, RMS, and TecVA on it. We used for the first time the colored inversion to broadband the spectrum of the ultrahigh-resolution seismic, using one seismic line acquired in South Atlantic with a sub-bottom profiler and one sample profiled with a multi-sensor core logger. The new seismic spectrum enhances geology features providing a result better than obtained with the conventional seismic envelope attribute format provided by most sub-bottom systems. It has vertical resolution like the seismic waveform and intensity like the envelope attribute.

**Keywords:** colored inversion; near-surface; seismic attributes; sub-bottom profiler; ultrahigh-resolution.

## INTRODUCTION

When it is necessary to install any submarine infrastructures in the seafloor, like pipelines, manifolds, cables, wind farms, or new producer wells, companies need to perform an acoustic survey to provide detailed information about the relief of the seabed and the first tens of meters of the geology under the seafloor to support the project's subsea engineers and geologists.

The information about the seabed relief comes from multibeam echosounders, which operate in a frequency band from 10 kHz to 460 kHz; the information about the sediment type of the seabed comes from side-scan sonars which work in a frequency range from 75 kHz to 1600 kHz; Ultrahigh-resolution seismic methods and sampling reveal the first one hundred meters of the geology underneath the seabed. They operate in a frequency range from 1 kHz to 10 kHz.

The term ultrahigh-resolution seismic is new and should be used to refer to acoustical acquisitions recorded in a sampling rate of microseconds, in contrast with the conventional seismic methods, which have sampling rates of milliseconds. Sub-bottom profilers and sparker using ultrahigh-resolution streamer (S-UHRS) are examples of these methods.

For years, the industry treated sub-bottom profilers as "echosounders" and not as seismic. This contribution wants to change the classification of sub-bottom profilers to an ultra-high-resolution seismic method and, to support this proposal, we present some established procedures from multichannel seismic, like classical seismic attributes introduced by (TANER, KOEHLER, *et al.*, 1979), applied into sub-bottom data.

Inspired in the results obtained in (RU-SHAN, 2014) and based on colored inversion (WHITCOMBE, LANCASTER, 2000) we tested a variation of this technique to broadband the spectrum of the ultra-high-resolution seismic, using one seismic line acquired in South Atlantic with a sub-bottom profiler and one geological core profiled with an MSCL (multi-sensor core logger) to determine the P-wave velocity, density and acoustic impedance of the sediments.

The new seismic spectrum enhances geological features providing an image better than obtained with seismic envelope attribute, preferentially used by most sub-bottom systems.

## THEORY

### **The ultrahigh-resolution seismic data from sub-bottom profilers**

Sub-bottom profilers are marine acoustical devices used to investigate the upper geological layers of the seafloor. Ceramic transducers, a seismic register, and a control unit implement them. The transducers convert electrical energy into sound and act in the transmission of controlled chirp sound pulses, and in the reception, converting the sound into electrical energy. This received signal has the effect of the pulse interference with the probed medium (seabed) regarding the changing in acoustic impedance along the nadir direction caused by sedimentary layers. Similar data is recorded by each 1-C (one component) hydrophone in streamers from conventional surveys. (THEUILLOU, STÉPHAN, *et al.*, 2008) states sub-bottom profilers can also make inference about reflectivity and absorption coefficients of the surveyed layers.

Sub-bottom profilers may be hull mounted, towed by research vessels or installed on AUVs (autonomous underwater vehicles) and ROVs (remote observation vehicles). It is also possible to arrange the transducers to create a 3D seismic.

The profiler emits chirp pulses (pings) while sailing in a constant ping rate. The distance between pings is variable and depend mostly on the water depth. The second factor affecting this distance is the ship's velocity, which varies depending on the environmental conditions during the survey. The signal penetration depends on many factors, like the source power, frequency, the type of sediments it travels through, and the distance traveled. The medium rapidly attenuates the high frequencies, and the signal strength decays with the square of the distance traveled. Regarding the type of sediments, in coarse grained sediments, the penetration is low, while in mud, the pulse penetration can reach up to 80 meters.

Once the sub-bottom profiler receives the reflected pulse very close to the position where it was transmitted, we can assume the raw data as zero-offset seismic. Often it is in a single channel, and the seismic profile generated looks like a stacked profile with irregular CDP spacing.

### **The seismic processing on sub-bottom profiler data**

The data from sub-bottom profilers are no longer processed using the sonar equation:

$$Rx = SL - 20 \log(2H + 2H_s) - 2\alpha H - 2\alpha_s + 20 \log(W_{ws} W_{sw}) + 20 \log V - NL + DI + PG \quad (2)$$

Where  $Rx$  is the signal returned,  $SL$  is the intensity of the transmitted pulse,  $H$  is the water depth (the distance traveled in the water column),  $H_s$  the distance traveled in the sedimentary layer (the depth penetration in the sediment),  $\alpha$  is the water absorption coefficient,  $\alpha_s$  is the absorption coefficient in the sediment,  $W_{ws}$ , and  $W_{sw}$  the two-way transmission coefficient in dB,  $V$  is the reflection coefficient,  $NL$  the noisy level,  $DI$  the beam directivity, and  $PG$  a gain in processing.

Instead, the data is processed as seismic data. (QUINN, BULL, *et al.*, 1998) proposed a seismic processing flow, and (BARADELLO, 2014) modified it based on seismic processing for land acquisitions using sweep trucks (BAETEN, ZIOLKOWSKI, 1990). It is a pre-requisite to have a minimum phase wavelet to use the Yilmaz deconvolution, so (ROBINSON, SAGGAF, 2001) introduced a way to transform the chirp zero-phase wavelet into its minimum phase wavelet. The seismic processing flow has these seven steps:

1. Generate the zero-phase wavelet (Klauder) from the chirp pulse through autocorrelation.
2. Create a Wiener Filter to transform the wavelet into the minimum phase.
3. Apply this filter in the raw sub-bottom data generating a de-chirped signal.
4. Apply spherical divergence correction.
5. Apply a predictive deconvolution.
6. Apply F-X Decon.
7. Migrate using Stolt constant velocity migration.

It is crucial to perform a geometry stage before dealing with signal form. When the sub-bottom profiler is hull-mounted, the data is processed in the sea level datum, but when the sensor is in a vehicle like an AUV, the source and the

receiver depth need to be correctly positioned by procedures similar to static correction.

## The seismic attributes

A seismic attribute is a quantity extracted or derived from seismic data to aid in geological or geophysical interpretations. Seismic attributes reinforce, resolve, and enhance features that seismic images are not able to distinguish.

Taner, Koehler, and Sheriff introduced in 1979 the first seismic attributes derived from complex trace analysis. From this analysis they obtain the envelope attribute, the instantaneous phase and instantaneous frequency. After them, many other attributes emerged in the oil industry to discriminate bright spots and direct hydrocarbon indicators. (MARFURT, 2018) compile them according to their use in the oil industry stage. Commonly used seismic attributes are the coherency, curvature, AVO (angle versus offset), spectral decomposition, azimuth, and dip.

The seismic attributes can be calculated in post-stack or pre-stacked data, in time or frequency domain, and using a single trace, a gather, or a sliding window. They can be applied to specific regions, like between two seismic horizons, or in the full volume or seismic profile.

Subsea engineering can also use seismic attributes to enhance the base of channels, discontinuities, unconformities, and faults. The most used seismic attribute in this scope is the envelope because it generates a clearer image of the seismic section. Sub-bottom profilers can implement the envelope attribute directly in acquisition using Hilbert transform.

## **Sampling profiling for geotechnical and geological studies**

The recovery of geological samples for laboratory analysis date from the 1940s, and according to (TUCHOLKE, SHIRLEY, 1979) it is essential for determining subsurface properties .

The advancement of robotics led to the production of test and sampling systems based on drilling on the seafloor. Companies like Benthic Geotech and the Fugro group operate with these systems, which have considerably improved the recovery rate and quality of the samples. Benthic Geotech launched in 1997 (NGUYEN, LUNNE, *et al.*, 2013) the portable remotely operated drilling rig (PROD - portable remotely operated drill) while Fugro launched the marine floor drilling rig (SFD - Seafloor drill) (RANDOLPH, 2016). The great advantage of these systems is the accurate positioning of the recovered sample since active acoustic positioning systems can provide the exact coordinate of the equipment on the seafloor. It is also clear that the number of information made possible by these probes is higher than that of the conventional approaches. For example, you can acquire S-wave information (shear) and perform various penetration tests with cones, t-balls, and other geotechnical tests.

The MSCL (Multi-sensor core logger) is a system manufactured by Geotek, that includes a set of instruments through which it is possible to carry out various physical measurements in the form of profile image and x-ray. Depending on the configuration, it is possible to measure P velocity propagation, spontaneous Gamma emission, electrical resistivity, magnetic susceptibility, and bulk density. It measures density through the interaction of gamma rays with the sediment. The sensor consists of a ten milli-Curie Cesium 137 capsule with

collimators of 2.5 - 5 mm in diameter and a scintillation detector. During the measurement, photons are emitted, dispersed, and transmitted through the sediments that are inside the liner (the corer sample tube). By counting the photons not attenuated, we can determine the material density. Thus, Gamma detection only counts photons that kept their energies.

Two ultrasonic transducers diametrically arranged perpendicular to the core, working at the frequency of 250 kHz, measures the transit time through the sediment. Since the diameter of the tube is known, the velocity can be inferred once the travel time is known (BEST, GUNN, 1999).

### **The broadband seismic spectrum**

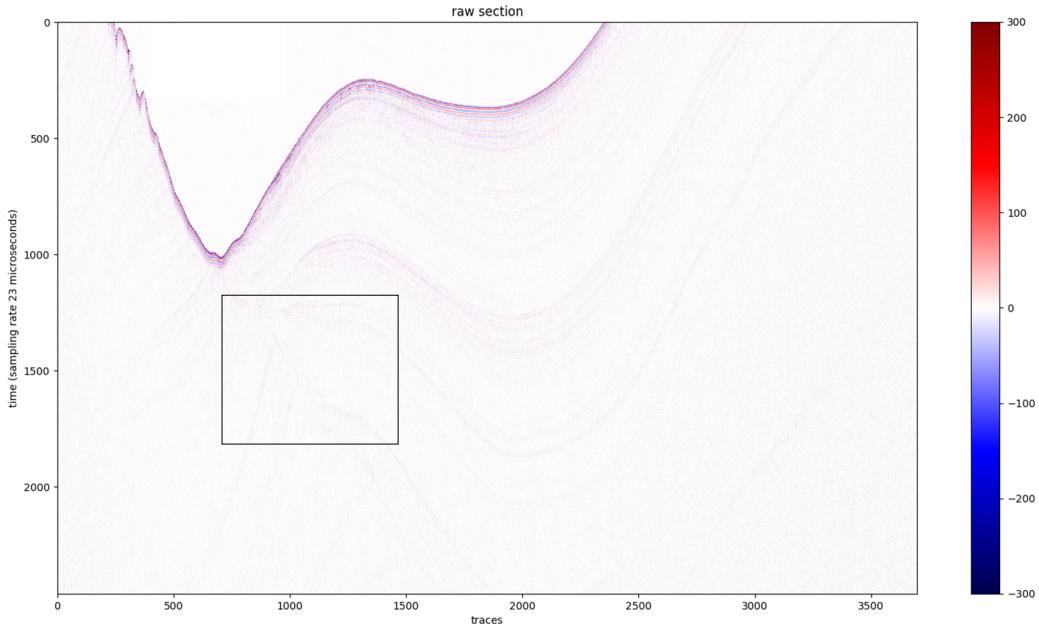
(WALDEN, HOSKEN, 1985) introduced a way to approximate spectrum shape using a model with two parameters, based on empirical observations of reflection coefficients series that after a cut frequency falls obeying a power law  $f^\beta$ , where  $\beta$  is between 0.5 and 1.5. Lancaster and Whitcombe in 2000 propose a fast-track algorithm called colored inversion, to compute a single convolutional operator. An inversion of the seismic data performed with this operator aims the same trend in acoustic impedance logs for wells in the area of the seismic data. They observed that the gross spectral form of acoustic impedance logs in wells was reasonably constant. Thus, they can compute the operator.

If the seismic spectrum becomes wider, it led to a more detailed seismic in time. This way, the feature becomes sharp, and the resolution may be enhanced.

## METHODOLOGY

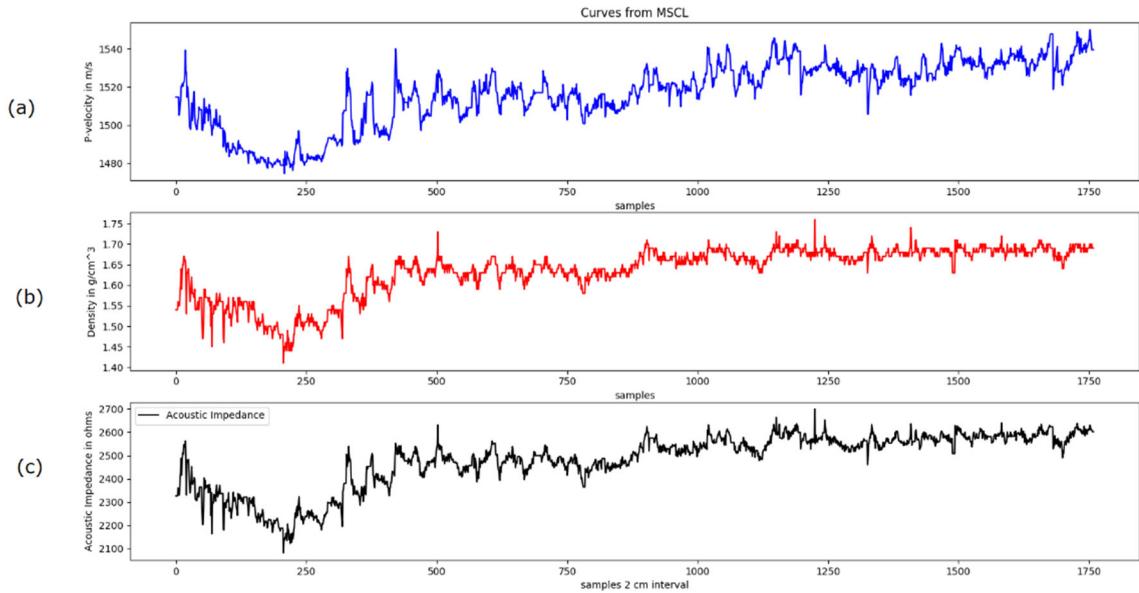
We used an ultrahigh-resolution seismic file surveyed with a sub-bottom profiler onboard of an AUV in South Atlantic (Santos Basin). The sensor of the

profiler was a DW-106 operating in a range of frequencies from 1 kHz to 10 kHz. The chirp length was 10 milliseconds, and the frequency variation was linear. The file was acquired on the real seismic waveform with a sampling rate of 23 microseconds. Figure 21 shows a section of this file.



*Figure 21 - Ultrahigh-resolution seismic file acquired in South Atlantic with a sub-bottom profiler. The vertical axis is in time samples, and the sampling rate is 23 microseconds. The traces are side by side. The maximum distance between them calculated with SbpPy (CUNHA, AYRES NETO, 2019) is 1 meter. The black square is a zoom for further comparison. The strongest reflection is the seabed.*

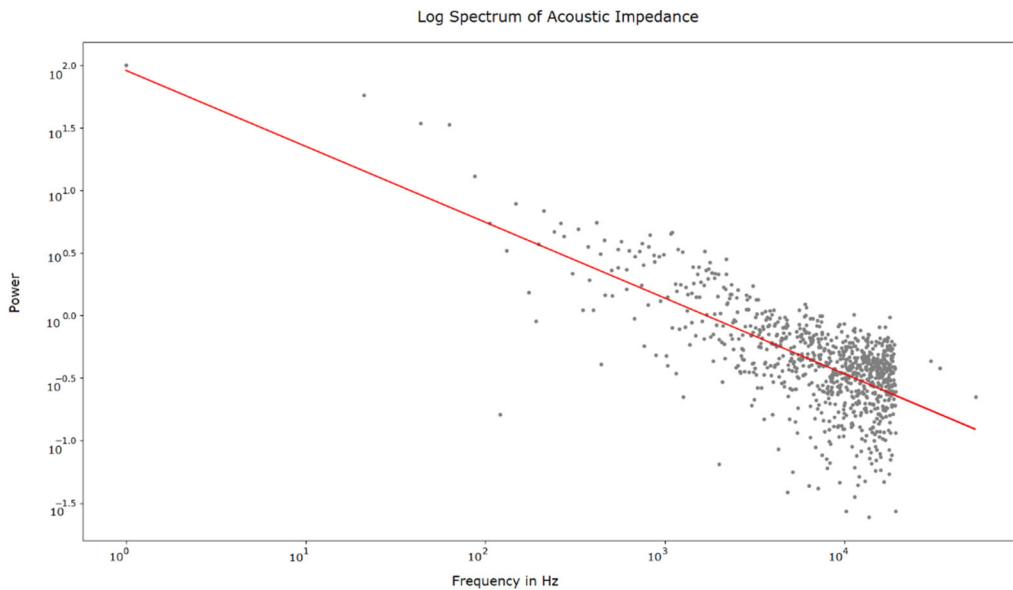
We also used one 35 meters long sediment core acquired over this same seismic line with the PROD system. The core was profiled with a MSCL every 2 cm, for gamma-ray density, P-velocity (VP), Phi porosity, magnetic susceptibility, and electric resistivity. We used the curve of VP and density to generate an acoustic impedance curve ( $AI = VP \times Density$ ) (Figure 22).



*Figure 22 - Three curves profiled in MSCL. On top (a) the P-velocity profile in m/s. in the middle (b), the density measured with gamma-ray in g/cc3. And on the bottom (c), the acoustic impedance computed by the product between the two curves above.*

To open and process the ultrahigh-resolution seismic file, we used a Python library SbpPy (CUNHA, AYRES NETO, 2019) because it can work with the sampling rate of the data, bringing these data to a python framework where we can use Numpy, and Scipy (OLIPHANT, 2006), and Matplotlib (HUNTER, 2007). SbpPy was used to retrieve the nearest seismic trace from a specific coordinate (of a geological sample).

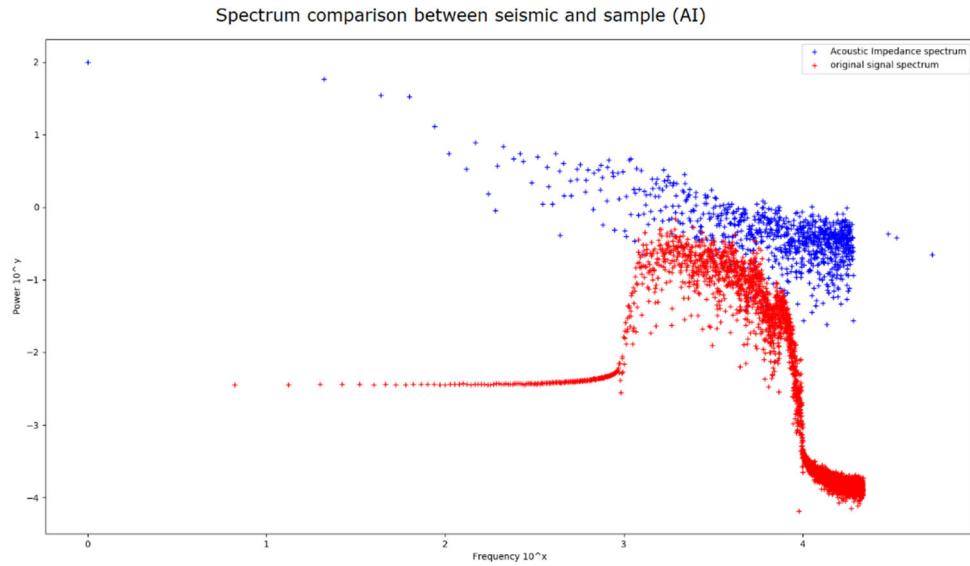
We started following the processing sequence presented by Robinson and Sagaaf in 2001 until step four. The last processing step applied to the data was the spherical divergence because the colored inversion does not need the deconvolution stage. Then we went through the (Lancaster & Whitcombe) colored inversion algorithm bringing the acoustic impedance measures from depth domain to time domain. Then we compute its log spectrum, shown in Figure 23.



*Figure 23 - Acoustic impedance plotted according to its log10 power and frequency. In red, the function computed through linear regression, which represents the scattered data. The difference between the spectrum of the seismic and the spectrum of the Acoustic Impedance profiled sample.*

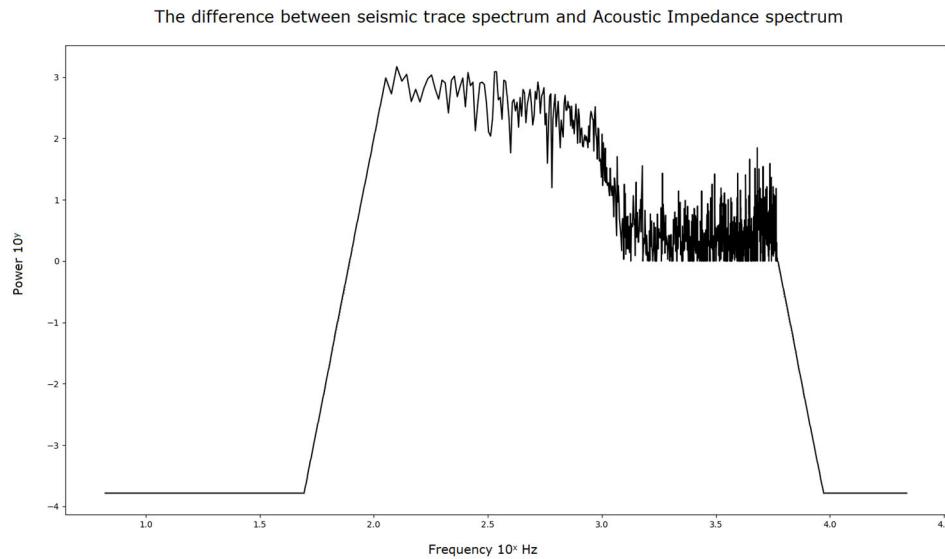
We performed a linear regression (least-squares) in our acoustic impedance values, leading to a simplification of the acoustic impedance spectrum. The red line in Figure 23 is the regression that will represent the acoustic impedance spectrum from now on.

To compute the operator responsible for the colored inversion, we picked the nearest seismic trace to the sediment core and computed its spectrum (Figure 24).



*Figure 24 - Spectral comparison between seismic (in red) and acoustic impedance (in blue), frequency, and power are in log10.*

We computed the difference between the two spectrums and bandpass its result (40 - 100 Hz and 9980 - 10 kHz), as shown in Figure 25.



*Figure 25 - The difference between the spectrum of the seismic and the spectrum of the acoustic impedance profiled sample. All frequencies from 100 Hz and 1000 Hz were added to the spectrum.*

Finally, to derive the colored inversion operator, we moved this computed spectrum to the time domain using an inverse fast Fourier transform. We shifted the zero-lag to the center of the window because we have a zero-phase wavelet

and applied a quadrature filter on it. Figure 26 shows the Colored Inversion operator.

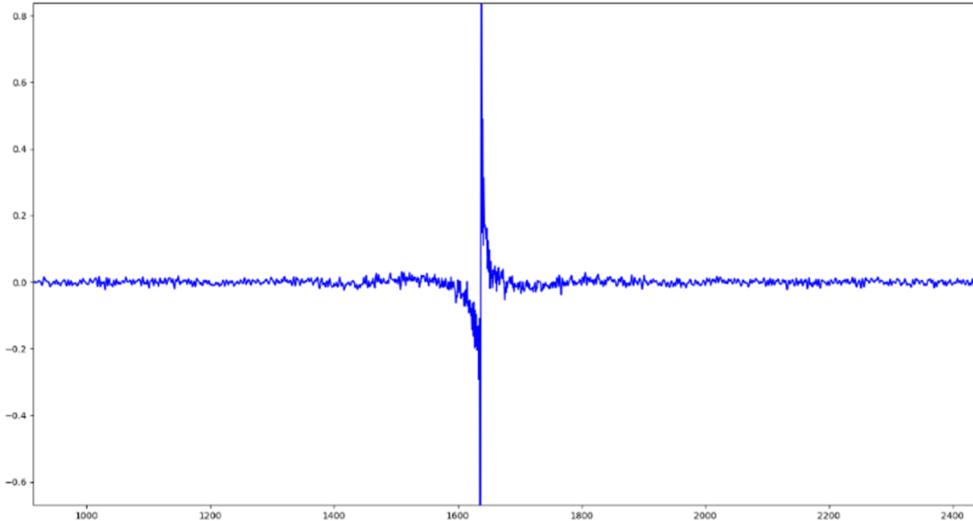


Figure 26 - The colored inversion operator in time, the vertical axis is the amplitude in Volts (V), the horizontal axis is in samples.

In sequence, we convolved our computed operator with the seismic profile trace-by-trace, using NumPy and the SbpPy libraries. We checked the results in the time domain, analyzing the colored inverted section, and in the frequency domain, by comparing the resultant spectrums. Figure 27 shows the comparison of the seismic data spectrum and the colored inverted.

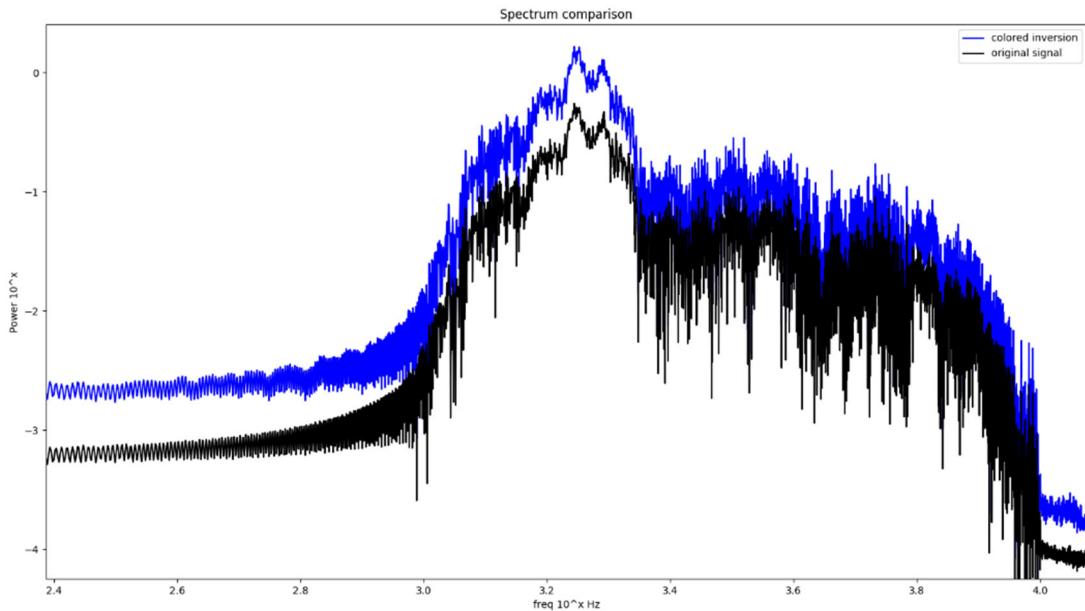


Figure 27 - The comparison of the seismic data spectrum (in black) and the colored inverted (in blue) where it is possible to see the gain between 103Hz and 103.4Hz.

As a second activity, we computed six seismic attributes for this profile using SbpPy and NumPy. We started from the attributes derived from complex trace analysis. Using Scipy Hilbert, the first computed attribute was the envelope. We simply calculate the instantaneous amplitude according to (GABOR, 1946) equation (15):

$$A(t) = \sqrt{s(t)^2 + H\{s(t)\}^2} \quad (15)$$

We computed in a straightforward way, the instantaneous phase, using the equation (16):

$$\varphi(t) = \tan^{-1} \left( \frac{H\{s(t)\}}{s(t)} \right) \quad (16)$$

Then the Cosine of the phase. Equation (19):

$$COS = \cos \varphi(t) \quad (19)$$

We unwrapped the phase and differentiated it to obtain the instantaneous frequency attribute, equation (20):

$$InstFreq = \frac{d\varphi(t)}{dt} \quad (20)$$

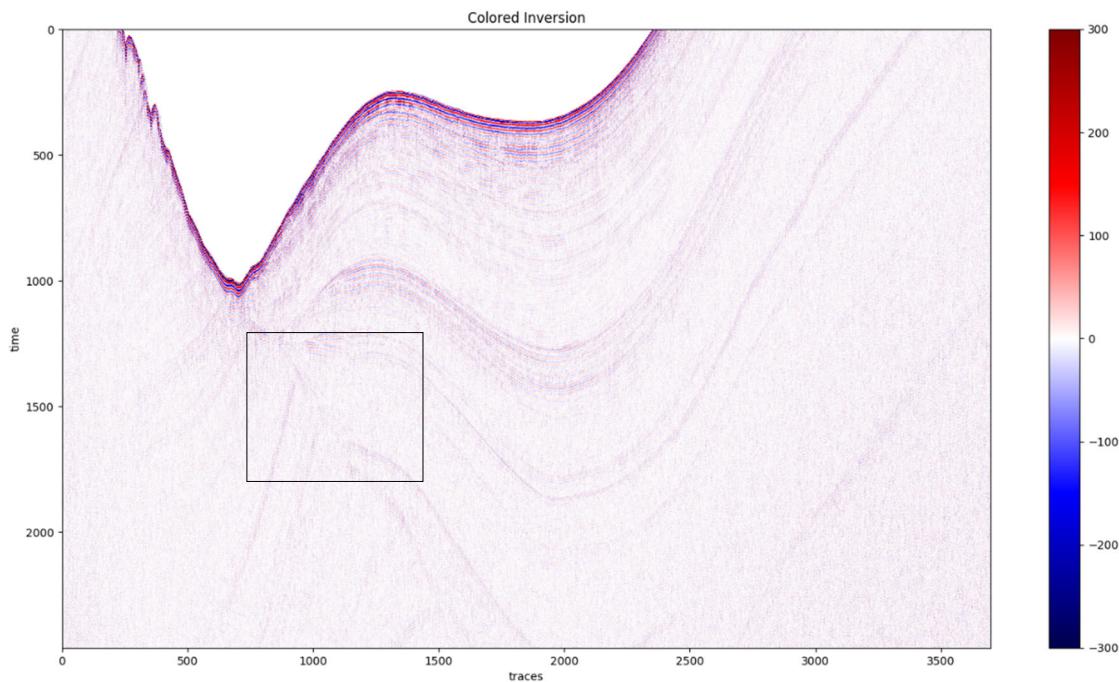
We also computed the RMS (root mean squared) seismic attribute using equation (21):

$$RMS_i = \frac{1}{w\_length} \sqrt{\sum_{w=1}^{w\_length} x^2} \quad (21)$$

Where  $i$  is an index for the sliding window of length  $w$ . And we computed the TecVA attribute rotating by 90° the RMS.

## RESULTS AND DISCUSSION

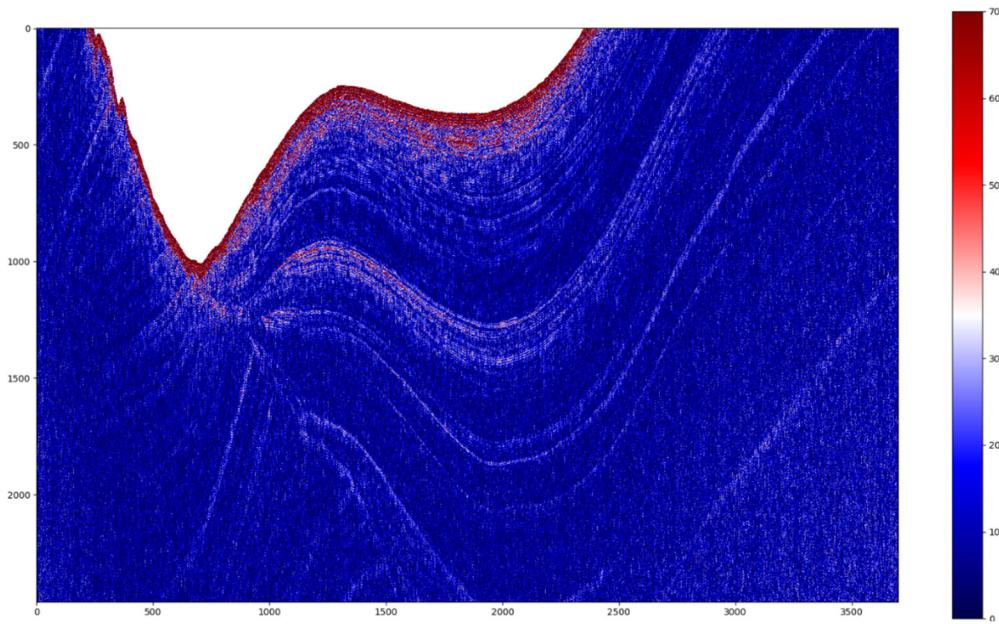
The main objective for people who performs a colored inversion is to quickly invert the seismic data to an impedance domain. Sometimes it enhances detailed structures that might be more subtle in the conventional seismic image. To correctly predict the dominant frequencies in the data is also a target. Nevertheless, in sub-bottom profiler's data, the result is a bit different, because it enhanced the geology (the low-frequency information). Thus, we could have higher amplitudes in the deeper part of the section, Figure 28 shows the colored inversion results. The noise came with this low-frequency information, but, maybe, a better filtering in the operator creation could mitigate it.



*Figure 28 - The result of colored inversion. A comparison using the same color bar limit values to the amplitude of the raw seismic profile (in Figure 21) is possible. The amplitude of deep reflectors is bigger in colored inversion; the resolution of shallow reflectors was also improved.*

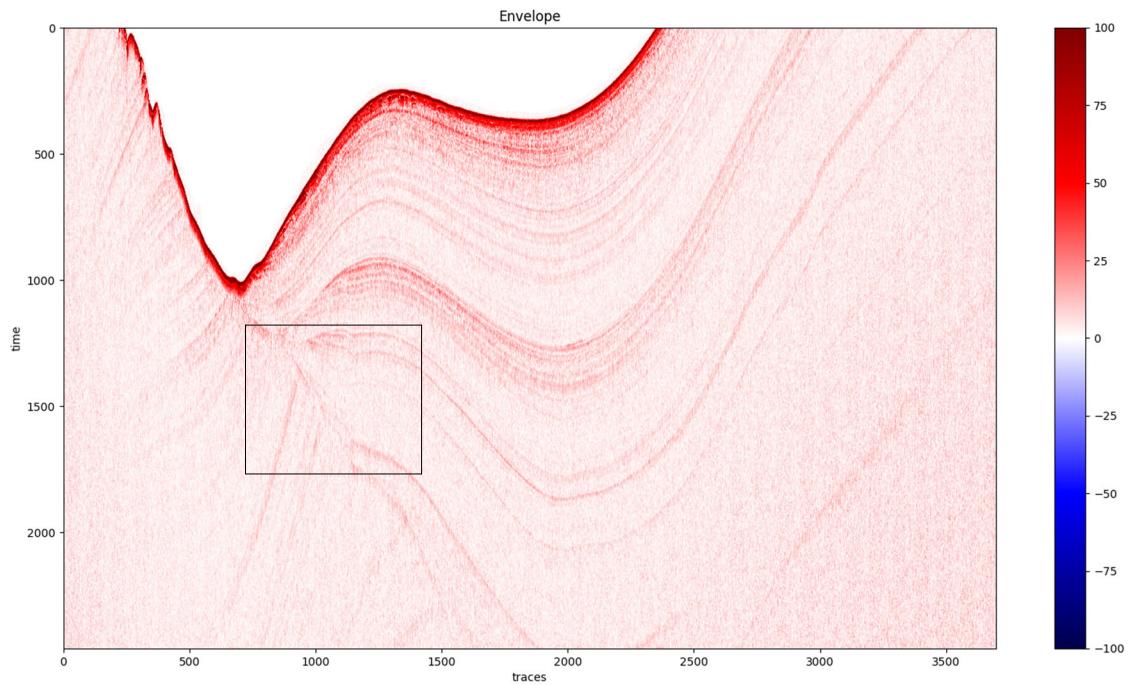
Unfortunately, this sediment section consists only of mud. But even though it is possible to see unconformities regarding the different time of depositions. This older, deeper mud layers should offer more resistance, like backstops, to be drilled.

Figure 29 brings a difference between the raw seismic and the colored inversion. It was used to demonstrate and enhance the differences between the two datasets.



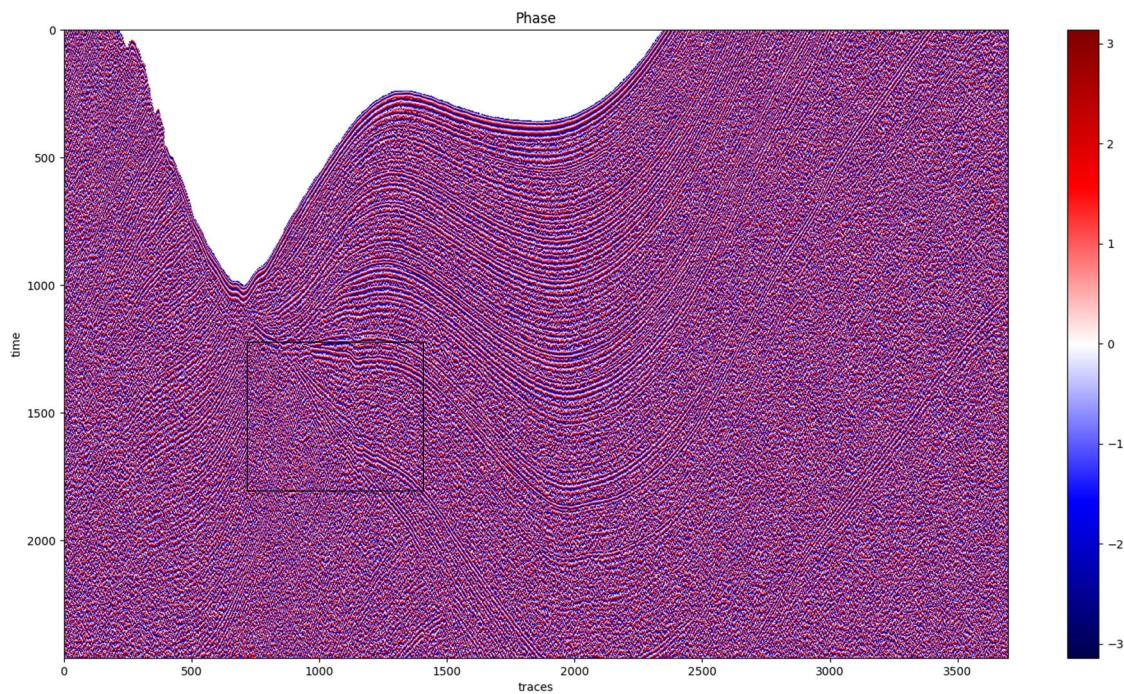
*Figure 29 - The difference between raw seismic and the colored inverted. One minus the other, thus, it is possible to check the amplitude difference in deep numerically.*

Regarding the use of seismic attributes, it is possible to see a balanced image on the envelope, but the colored inversion lit up more details, since it has a better vertical resolution. Of course, we are not suggesting replacing one by the other. The envelope is calculated in a straightforward way, and we not always have a sediment core in the area to perform a colored inversion. Figure 30 shows the envelope attribute result and the reflection strength it reveals from the data.

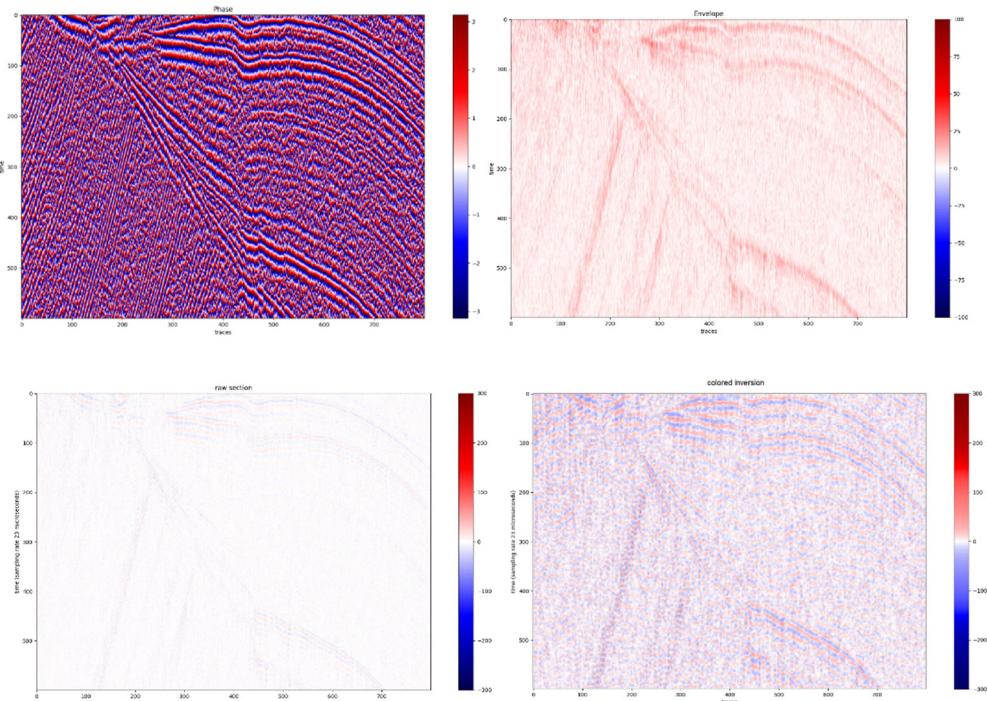


*Figure 30 - The envelope seismic attribute. Zoom in the detail square will be used for comparison.*

The instantaneous phase is the best attribute to track folded seismic reflectors, faults, pinch outs, and angularities. According to Tanner and Sheriff et al. 1979, it makes coherent events clearer since it does not depend on amplitude. Figure 31 shows the results of instantaneous phase attributes. And Figure 32 the comparison between envelope and instantaneous phase attributes in detail, and the detail of raw section and colored inversion.

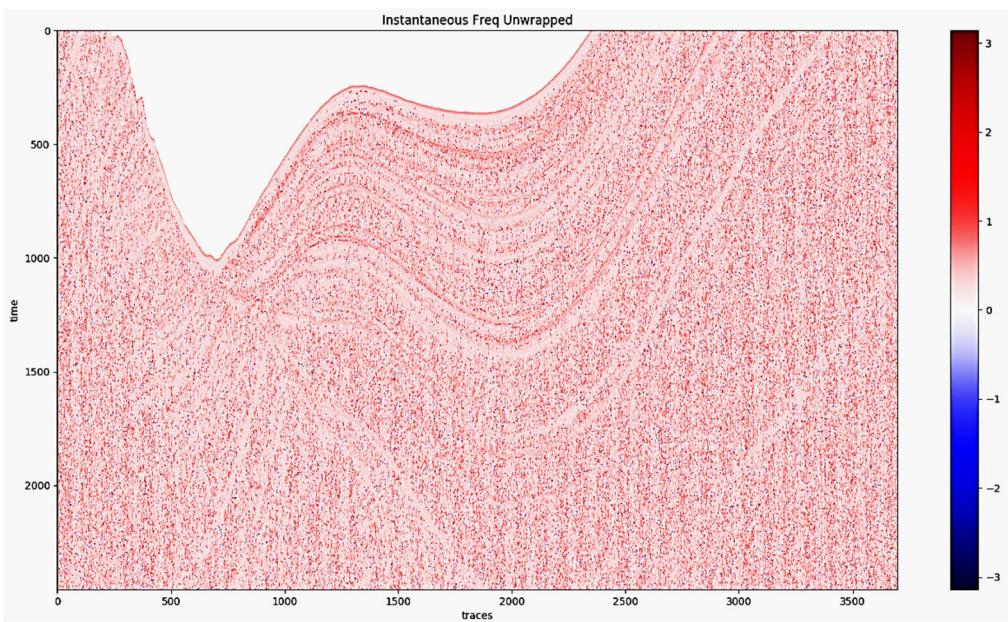


*Figure 31 - The instantaneous phase attribute is enhancing the continuity in angularities, high-angle faults, and folds.*



*Figure 32 - A detailed comparison between the instantaneous phase attribute (up left) and the envelope attribute (up right). It is easier to map a reflector in the up left because it has more continuity. The position of the reflector is clear in phase change (white) in the instantaneous phase attribute, while it is not so precise in the envelope attribute. The bottom left is the raw seismic where the mapping reflector task is performed nowadays, and the bottom right is the colored inversion result. In the colored inversion, the amplitude of the reflector is higher than the raw data, and the resolution of reflectors is better than in the envelope.*

The Instantaneous frequency did not respond well to this data. Perhaps if there were higher contrast lens partially filled with gas or water within the sedimentary sequence, they would be more visible. Since they are not present, and the geology is monotonous the attribute did not perform well. The color palette choosing, and the range of frequencies also contributed to the fair result. Figure 33 shows the result of the Instantaneous frequency attribute. Usually, this attribute is plotted in a composite, choosing colors for a band of frequencies. Thus, it enhances levy channels and abandoned meanders.



*Figure 33 - The instantaneous frequency attribute computed from an unwrapped phase.*

The cosine of the phase (Figure 34) acts like an AVG in the instantaneous phase attribute showing good results when analyzed on a more detailed scale (Figure 35).

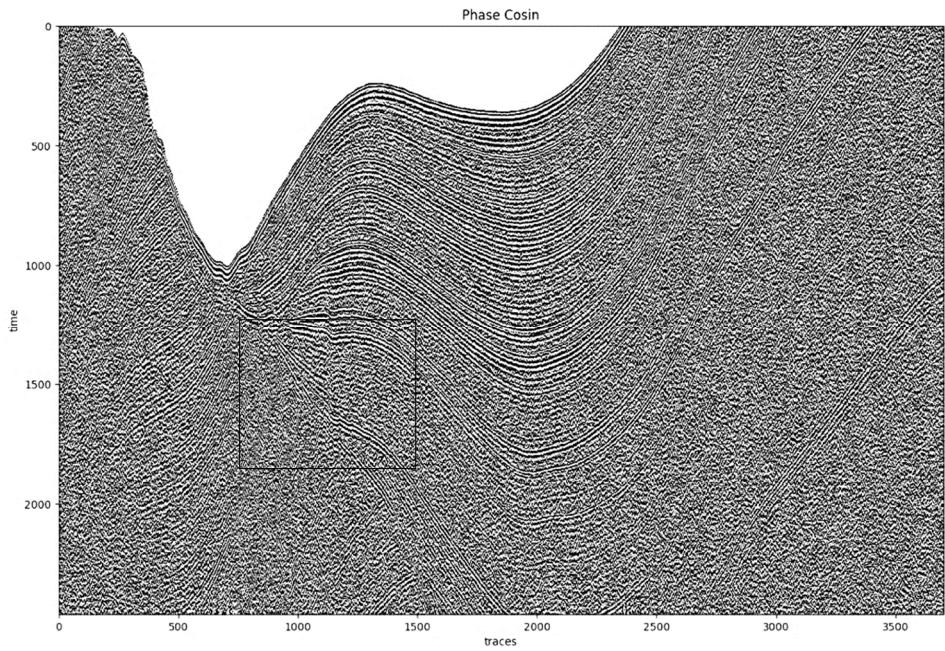


Figure 34 -The cosine of the phase attribute varying from -1 (white) to 1 (black).

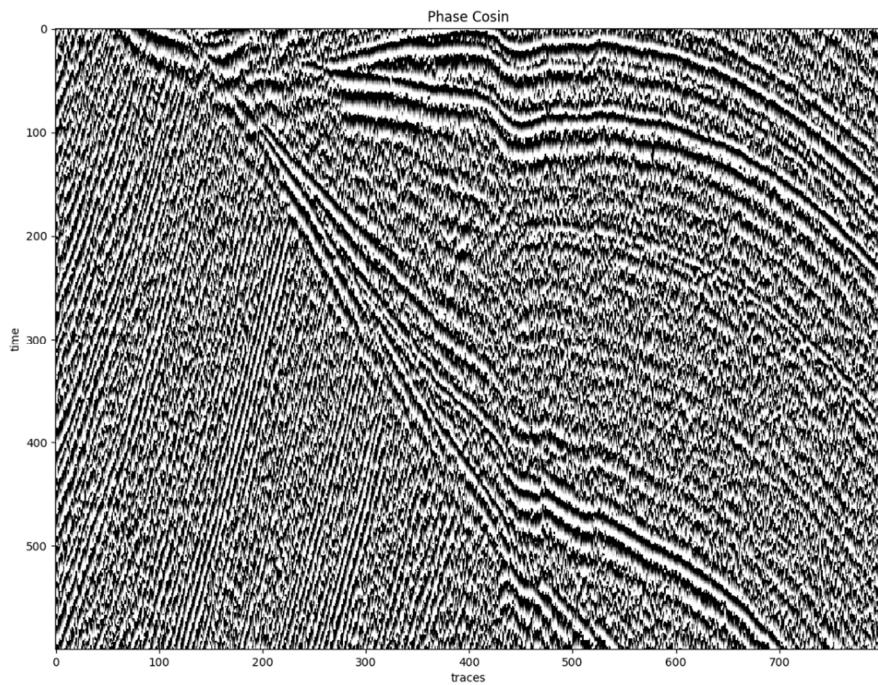
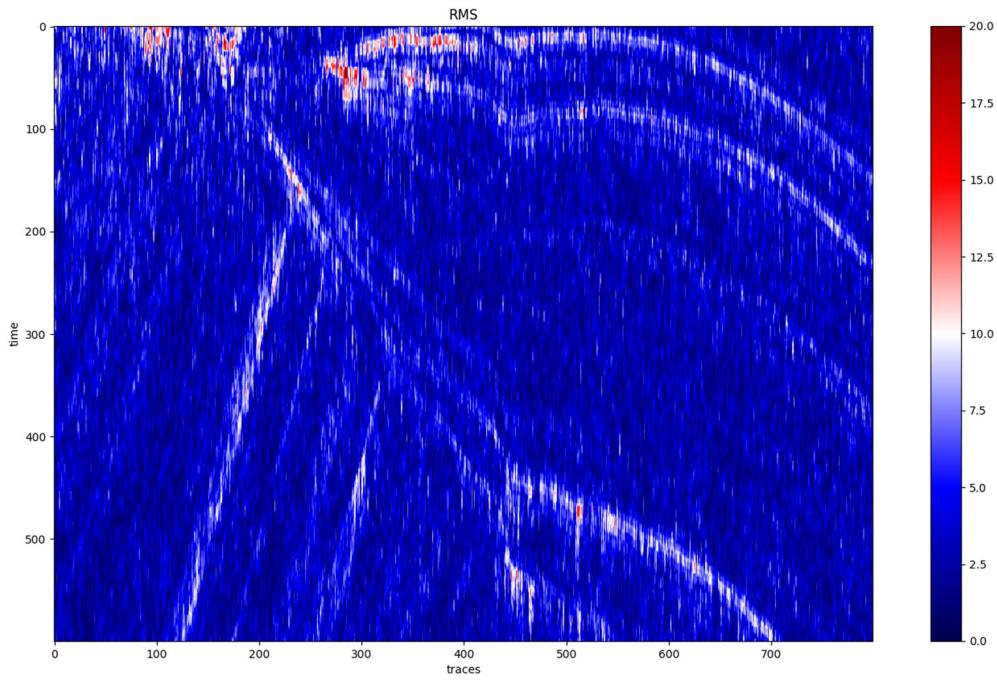


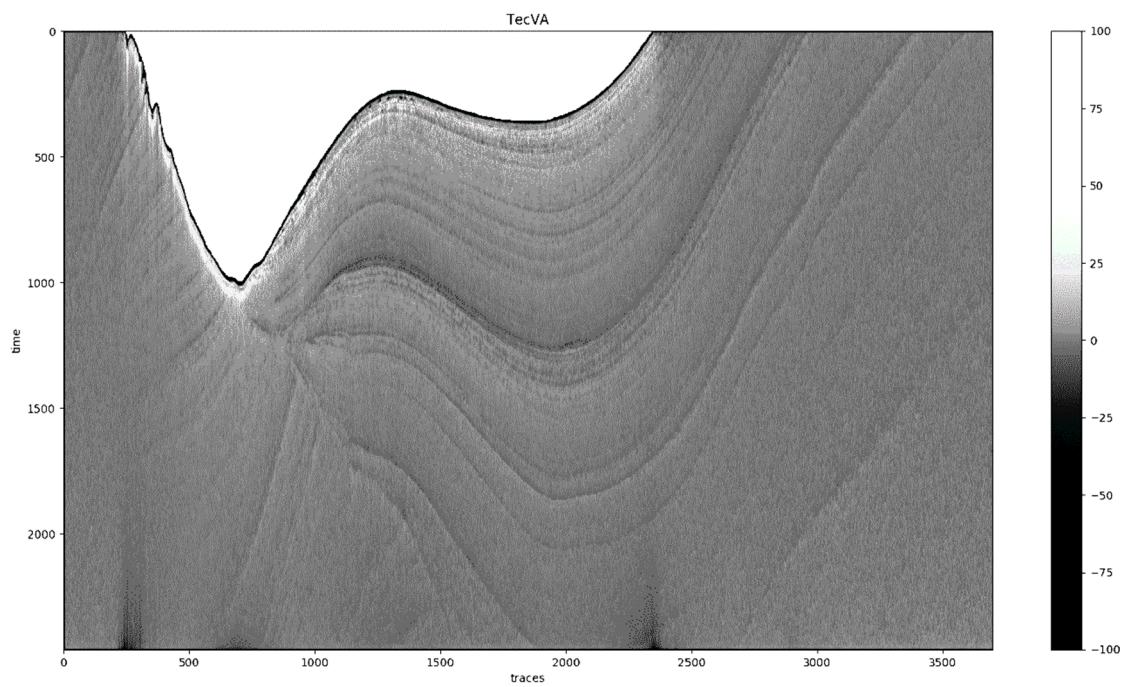
Figure 35 - The cosine of the phase in detail varying from -1 (white) to 1 (black).

The RMS attribute did not perform satisfactorily. Perhaps because of the monotonous geology, or the chose in the window size, we need to run more tests. The Figure 36 shows in detail the result of RMS attribute.



*Figure 36 - The result of the RMS attribute showing the unconformities.*

Finally, the TecVA (Volume Amplitudes Technique) attribute (BULHÕES, DE AMORIM, 2005) emphasized the change in the sediment properties according to its unconformities. This attribute when applied to a seismic data with different geological features should perform interestingly. Figure 37 shows the result of TecVA.



*Figure 37 - The TecVA attribute emphasized the change in sediment properties; in this case, we believe it regards the resistance to penetration of the sedimentary layer.*

## CONCLUSION

We showed that sub-bottom profilers' data could be treated as ultra-high-resolution seismic data. We successfully computed seismic attributes from the data, and we know other attributes or combinations of those, that can also be used. Moreover, new attributes could be created in order to help in specific problems regarding subsea engineering problems

We performed a colored inversion on this data, also with good results. This technique is exciting to geotechnical studies, where punctual information regarding safety factors, shear resistance and undrained strength of the soil could be laterally spread along a specific reflector. Colored inversion and seismic attributes can help in the automatization of tasks, like unsupervised mapping of reflectors, because it enhances their continuity.

## ACKNOWLEDGMENTS

This work was conducted during a scholarship supported by the International Cooperation Program CAPES. Financed by CAPES – Brazilian Federal Agency for Support and Evaluation of Graduate Education within the Ministry of Education of Brazil.

## CONCLUSÃO

Conforme demonstramos nas publicações, os dados de perfiladores de subfundo podem ser tratados como dados sísmicos de ultra-alta-resolução. É possível processá-los para corretamente posicioná-los em profundidade, e assim ter uma boa correlação com amostras geológicas e geotécnicas. Através da modelagem direta, com a geração de traços sintéticos, a amarração pode ficar acurada o suficiente para extrapolar a informação pontual geotécnica como as medidas de resistência ao cisalhamento não drenado e resistência a perfuração, além da extração das medidas geológicas e geofísicas ao longo dos refletores sísmicos. Assim, por exemplo, modelos de velocidade com ultra-alta-resolução podem ser confeccionados.

Além disso, provamos ser possível realizar uma inversão colorida, a qual agrupa riqueza espectral ao dado, evidenciando eventos geológicos em profundidade com a mesma capacidade do atributo sísmico de envelope, porém não perdendo sua informação de fase. Além disso a inversão colorida proporciona um realce na sísmica ao que é geológico, pois o espectro final fica alinhado com a impedância acústica evidenciada em testemunho geológico ou perfil.

Provamos ser possível e útil computar atributos sísmicos nos dados do perfilador de subfundo. O atributo de fase, por exemplo, teve uma excelente resposta em continuidade em refletores de alto ângulo e isso agrupa valor nas interpretações geológicas.

E principalmente, conseguimos um resultado fantástico reavendo fase de dados puramente envelopados. Dando vida a um passivo de aquisições que agora poderão trazer novas informações a partir dos mesmos dados antigos. É como se uma nova aquisição fosse feita no local. Atributos sísmicos podem ser utilizados. E essas informações podem fomentar modelos de bacias, e servir como input inicial em modelos geomecânicos de reservatórios e modelos de velocidade.

Esperamos com essa contribuição, aumentar o ferramental da indústria de engenharia submarina, tornando a atividade de análise de riscos geológicos submarinos mais embasada e criteriosa. E se possível revelar riscos antes não vistos, para que os mesmos possam ser mitigados ainda na fase de projeto de instalações submarinas.

## REFERÊNCIAS

- ANGRICK, M., HERFF, C., JOHNSON, G., et al. "Interpretation of convolutional neural networks for speech spectrogram regression from intracranial recordings", **Neurocomputing**, v. 342, p. 145–151, 2019. DOI: 10.1016/j.neucom.2018.10.080. Disponível em: <https://doi.org/10.1016/j.neucom.2018.10.080>.
- ASTM D4318-17E1. "Standard Test Methods for Liquid Limit, Plastic Limit, and Plasticity Index of Soils", **ASTM International**, 2017. DOI: 10.1520/D4318-17E01..
- BAETEN, G., ZIOLKOWSKI, A. **Advances in Exploration Geophysics (Book 3)**. [S.I.], Elsevier Science, 1990.
- BARADELLO, L. "An improved processing sequence for uncorrelated Chirp sonar data", **Marine Geophysical Research**, v. 35, n. 4, p. 337–344, 2014. DOI: 10.1007/s11001-014-9220-1..
- BATES, R. H. T. "On the phase problem II", **Optik**, v. 51, n. 3, p. 223–234, 1978. .
- BENDORY, T., EDIDIN, D., ELDAR, Y. C. "Blind Phaseless Short-Time Fourier Transform Recovery", **IEEE Transactions on Information Theory**, p. 1–1, 2019. DOI: 10.1109/tit.2019.2947056. .
- BEST, A. I., GUNN, D. E. "Calibration of marine sediment core loggers for quantitative acoustic impedance studies belonging to Southampton Oceanography Centre", **Marine Geology**, v. 160, p. 137–146, 1999. .

BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.I.], Springer Berlin Heidelberg, 2006. Disponível em:  
[http://cds.cern.ch/record/998831/files/9780387310732\\_TOC.pdf](http://cds.cern.ch/record/998831/files/9780387310732_TOC.pdf).

BRITTAN, J., JONES, I. "FWI evolution — From a monolith to a toolkit", n. March, p. 179–184, 2019. DOI: 10.1190/tle38030179.1. .

BRUCK, Y. M., SODIN, L. G. "On the ambiguity of the image reconstruction problem", **Optics Communications**, v. 30, n. 3, p. 304–308, 1979. DOI: 10.1016/0030-4018(79)90358-4. .

BULHÕES, E. M., DE AMORIM, W. N. "Princípio da SismoCamada Elementar e sua aplicação à Técnica Volume de Amplitudes (tecVA)", v. d, p. 1382–1387, 2005. DOI: 10.1190/sbgf2005-275. .

CECILIO, A. B., CUNHA, J. B., AYRES NETO, A. **Processamento sísmico e análise de atributos em dados monocanal de alta resolução na bacia de Bransfield, Antártica**. . Porto Alegre, II Simpósio Brasileiro de Geologia e Geofísica Marinha. , 2019

COOKE, D., CANT, J. "Model-based Seismic Inversion : Comparing deterministic and probabilistic approaches", **CSEG Recorder**, n. April, p. 28–39, 2010. .

CUNHA, J. B., AYRES NETO, A. "MAPIRA-A support decision tool for marine pipeline risk assessment". 2015. **Anais** [...] Rio de J, [s.n.], 2015. DOI: 10.1109/RIOAcoustics.2015.7473605.

CUNHA, J. B., AYRES NETO, A. "Seismic inversion of an Antarctic Sampling using python sbppy and a shallow high resolution seismic". 2019. **Anais** [...] Rio

de Janeiro, [s.n.], 2019. p. 1–4. DOI: 10.22564/16cisbgf2019.108.

DAVOGUSTTO, O., DE MATOS, M. C., CABARCAS, C., *et al.* "Resolving subtle stratigraphic features using spectral ridges and phase residues", **Interpretation**, v. 1, n. 1, p. SA93–SA108, 2013. DOI: 10.1190/INT-2013-0015.1..

DOSSAL, C., MALLAT, S. "Sparse spike deconvolution with minimum scale", In **Proceedings of Signal Processing with Adaptive Sparse Structured Representations**, n. 4, p. 4–7, 2005. Disponível em:

<http://www.cmap.polytechnique.fr/~mallat/papiers/SparseSpike.pdf>.

EDGETECH. **2200-S SURVEY QUALITY SONARS FOR SMALL AUVs**. . West Wareham, [s.n.]. Disponível em: [www.edgetech.com](http://www.edgetech.com)., 2005

EMERY, K. O., DIETZ, R. S. "Gravity coring instrument and mechanics of sediment coring", **Bulletin of the Geological Society of America**, v. 52, n. 10, p. 1685–1714, 1941. DOI: 10.1130/GSAB-52-1685. .

FILIPPOVA, K; KOZHENKOV, A; ALABUSHIN, A. "Seismic inversion techniques: choice and benefits", **First Break**, v. 29, n. 5, p. 103–114, 2011..

FRANCIS, A. "Understanding Stochastic Inversion: Part 1", **First Break**, v. 24, n. 11, p. 66–67, 2006. .

GABOR, D. **Theory of Communication part I**. [S.l: s.n.], 1946.

GEOTEK. **Mscl-S : Multi-Sensor Core Logger Automated & Flexible Core Logging & Scanning**. . [S.l: s.n.], 2019

GEOTEK. **Multi-Sensor Core Logger**. 1. ed. UK, [s.n.], 2016.

GIORGINO, T. "Computing and visualizing dynamic time warping alignments in R: The dtw package", **Journal of Statistical Software**, v. 31, n. 7, p. 1–24, 2009. DOI: 10.18637/jss.v031.i07. .

GRIFFIN, D. W., LIM, J. S. "Signal Estimation from Modified Short-Time Fourier Transform", **IEEE Transactions on acoustics speech and signal processing**, v. 32, n. 2, p. 236–242, 1984. .

GUNN, D., BEST, A. "A new automated nondestructive system for high resolution multi-sensor core logging of open sediment cores", **Geo-Marine Letters**, v. 18, n. 1, p. 70–77, 1998. DOI:

<https://doi.org/10.1007/s003670050054>. .

GUO, N. **The vibration characteristics of piezoelectric discs**. 1989. 239 f. Imperial College of Science, 1989.

HAMILTON, E. L., BACHMAN, R. T., BERGER, W. H., *et al.* "Acoustic and related properties of calcareous deep-sea sediments", **Journal of Sedimentary Research**, v. 52, n. 3, p. 733–753, 1982. .

HAYES, M. H. "The reconstruction of a multidimensional sequence from the phase or magnitude of its Fourier transform", **IEEE Trans. Acoustic. Speech Signal Processing ASSP**, v. 30, p. 140–154, 1982. .

HUNTER, J. D. "Matplotlib: A 2D graphics environment", **Computing in Science and Engineering**, v. 9, n. 3, p. 99–104, 2007. DOI: 10.1109/MCSE.2007.55. .

JEN-TZUNG CHIEN. **Source Separation and Machine Learning**. 1. ed. [S.I.], Academic press, 2019.

KAVALEROV, I., WISDOM, S., ERDOGAN, H., *et al.* "Universal Sound Separation", 2019. Disponível em: <http://arxiv.org/abs/1905.03330>.

KINGTON, J. **Python Geoprobe**. . [S.l: s.n.]. Disponível em:  
<https://github.com/joferkington/python-geoprobe>. , 2012

**KONGSBERG. Kongsberg SBP 29 Sub-bottom Profiler Product Description**. , A., nº 447542. Norway, [s.n.], 2019. Disponível em:  
<http://www.km.kongsberg.com>.

**KOVESI, P. D. Invariant Measures of image Features from Phase information**. 1996. University of Western Australia, 1996.

KUHN, M., JOHNSON, K. **Applied predictive Modeling**. 1. ed. [S.I.], Springer, 2013.

LATIMER, R. B., DAVIDSON, R., VAN RIEL, P. "An interpreter's guide to understanding and working with seismic-derived acoustic impedance data", **The Leading Edge**, v. 19, n. 3, p. 242–256, 2002. DOI: 10.1190/1.1438580. .

LEE, J., PARK, J., KIM, K. L., *et al.* "Sample-level deep convolutional neural networks for music auto-tagging using raw waveforms", **Proceedings of the 14th Sound and Music Computing Conference 2017, SMC 2017**, p. 220–226, 2019. .

LEE, Y., WANG, C., WANG, S., *et al.* "Fully Complex Deep Neural Network for Phase-Incorporating", **IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP) 2017**, p. 281–285, 2017. .

LI, Q., WU, G., WU, J., *et al.* "Finite difference seismic forward modeling method for fluid-solid coupled media with irregular seabed interface", **Journal**

**of Geophysics and Engineering**, v. 16, n. 1, p. 198–214, 2019. DOI: 10.1093/jge/gxy017. .

**LIPPSETT, L. Lamont-Doherty Earth Observatory : twelve perspectives on the first fifty years, 1949-1999.** Palisades NY, [s.n.], 1999.

**LURTON, X. An Introduction to Underwater Acoustics.** 1. ed. Berlin, Heidelberg, Springer Berlin Heidelberg, 2010. Disponível em:  
<http://link.springer.com/10.1007/978-3-642-13835-5>.

**MACK, W., HABETS, E. A. P.** "Deep Filtering: Signal Extraction and Reconstruction Using Complex Time-Frequency Filters", **IEEE Signal Processing Letters**, v. 27, p. 61–65, 2020. DOI: 10.1109/LSP.2019.2955818. .

**MARFURT, K. J. 2018 Distinguished Instructor Short Course Seismic Attributes as the Framework for Data Integration Throughout the Oilfield Life Cycle presented by Society of Exploration Geophysicists Seismic Attributes as the Framework for Data Integration Throughout th.** [S.l: s.n.], 2018.

**MCCULLOCH, W., PITTS, W.** "A logical calculus of the ideas immanent in nervous activities", **Bulletin of Mathematical Biophysics**, v. 5, p. 115–133, 1943. .

**NAWAB, S. H., QUATIERI, T. F., LIM, J. S.** "Signal Reconstruction from Short-Time Fourier Transform Magnitude", **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 31, n. 4, p. 986–998, 1983. DOI: 10.1109/TASSP.1983.1164162. .

**NGUYEN, H. Q., LUNNE, T., KELLEHER, P., et al.** "Offshore Site

Characterization of Small Strain Shear Modulus Using a Seabed Based Drilling System", 2013. DOI: 10.4043/24124-ms. .

NING, X. et al. "Gas hydrate associated with mud diapirs in southern Okinawa Trough", **Marine and Petroleum Geology**, v. 26, n. 8, p. 1413–1418, 2009. DOI: 10.1016/j.marpetgeo.2008.10.001. Disponível em:  
<http://dx.doi.org/10.1016/j.marpetgeo.2008.10.001>.

NORRIS, E. M. W., FAICHNEY, A. K., SEG, Y. "Seg-y format", n. May, 2002. .

OLIPHANT, T. E. **A guide to Numpy**. 1. ed. USA, Trelgol Publishing, 2006.

PARTYKA, G. et al. **Spectral Inversion, SEG Distinguished Lecture**. . [S.l.: s.n.], 2005

PASZKE, A., GROSS, S., MASSA, F., et al. "PyTorch: An Imperative Style, High-Performance Deep Learning Library", n. NeurIPS, 2019. Disponível em:  
<http://arxiv.org/abs/1912.01703>.

QUINN, R., BULL, J. M., DIX, J. K. "Optimal processing of marine high-resolution seismic reflection (chirp) data", **Marine Geophysical Research**, v. 20, n. 1, p. 13–20, 1998. DOI: 10.1023/A:1004349805280. .

RAMACHANDRAN, P., VAROQUAUX, G. "Mayavi: 3D Visualization of Scientific Data", **IEEE Computing in Science & Engineering**, v. 13, n. 2, p. 44–51, 2011. .

RANDOLPH, M. F. "New tools and directions in offshore site investigation", **Australian Geomechanics Journal**, v. 51, n. 4, p. 81–92, 2016. .

ROBINSON, E. A., SAGGAF, M. "Klauder wavelet removal before vibroseis deconvolution", **Geophysical Prospecting**, v. 49, n. 3, p. 335–340, 2001. DOI:

10.1046/j.1365-2478.2001.00260.x. .

ROSENBLATT, F. "The perceptron: A probabilistic model for information storage and organization in the brain", **Psychological Review**, v. 65, n. 6, p. 386–408, 1958. DOI: 10.1037/h0042519. .

ROUX, J. Le, ONO, N., SAGAYAMA, S. "Explicit consistency constraints for STFT spectrograms and their application to phase reconstruction", **Proc. SAPA**, n. Sapa, p. 23–28, 2008. .

RU-SHAN, W. et al. "Seismic envelope inversion and modulation signal model", **Geophysics**, v. 79, n. 3, p. WA13-23, 2014. .

RUSSELL, B. H. **Introduction to Seismic Inversion Methods**. [S.l: s.n.], 1988. Disponível em: <https://library.seg.org/doi/book/10.1190/1.9781560802303>.

SAMUEL, A. L. "Some studies in machine learning using the game of checkers", **IBM Journal of research and development**, v. 3, n. 3, p. 210–229, 1959. .

SEBAA, N., FELLAH, Z. E. a, FELLAH, M., et al. **Inverse Problem Theory**. [S.l: s.n.], 2006. v. 120. Disponível em:  
<http://www.ncbi.nlm.nih.gov/pubmed/17069280>.

STURMEL, N., DAUDET, L. "Signal reconstruction from STFT magnitude: A state of the art", **Proceedings of the 14th International Conference on Digital Audio Effects, DAFX 2011**, p. 375–386, 2011. .

SUTTON, R. S., BARTO, A. G. **Introduction to Reinforcement Learning**. Cambridge, MIT Press, 1998.

TAKAHASHI, N., AGRAWAL, P., GOSWAMI, N., et al. "PhaseNet: Discretized

phase modeling with deep neural networks for audio source separation", **Proceedings of the Annual Conference of the International Speech Communication Association, INTERSPEECH**, v. 2018-Septe, n. September, p. 2713–2717, 2018. DOI: 10.21437/Interspeech.2018-1773. .

TANER, M. T., KOEHLER, F., SHERIFF, R. E. "Complex Seismic Trace Analysis.", **Geophysics**, v. 44, n. 6, p. 1041–1063, 1979. DOI: 10.1190/1.1440994. .

TARANTOLA, E. **Inverse Problem Theory and Methods for model parameters estimation**. USA, Society for Industrial and Applied Mathematics, 2005.

THEUILLON, G., STÉPHAN, Y., PACAULT, A. "High-resolution geoacoustic characterization of the seafloor using a subbottom profiler in the Gulf of Lion", **IEEE Journal of Oceanic Engineering**, v. 33, n. 3, p. 240–254, 2008. DOI: 10.1109/JOE.2008.926958. .

TUCHOLKE, B. E., SHIRLEY, D. J. "Comparison of Laboratory and In situ Compressional Wave Velocity Measurements on Sediment Cores from the Western North Atlantic", **Journal of Geophys**, v. 84, p. 687–695, 1979. .

WALDEN, A. T., HOSKEN, J. W. J. "an Investigation of the Spectral Properties of Primary Reflection Coefficients", **Geophysical Prospecting**, v. 33, n. 3, p. 400–435, 1985. DOI: 10.1111/j.1365-2478.1985.tb00443.x. .

WHITCOMBE, D., LANCASTER, S. "Fast-track ' coloured ' inversion", **SEG Expanded abstracts**, p. 3–6, 2000. .

WIENER, N. **Extrapolation, Interpolation and Smoothing of Stationary Time**

**Series with Engineering Applications.** New York, Wiley, 1949.

WILLIAMSON, D. S., WANG, Y., WANG, D. L. "Complex ratio masking for monaural speech separation", **IEEE/ACM Transactions on Audio Speech and Language Processing**, v. 24, n. 3, p. 483–492, 2016. DOI: 10.1109/TASLP.2015.2512042. .

XU, Y., DU, J., DAI, L. R., *et al.* "A regression approach to speech enhancement based on deep neural networks", **IEEE/ACM Transactions on Audio Speech and Language Processing**, v. 23, n. 1, p. 7–19, 2015. DOI: 10.1109/TASLP.2014.2364452. .

YIN, P. et al. "Mud volcanoes at the shelf margin of the East China Sea", **Marine Geology**, v. 194, n. 3–4, p. 135–149, 2003. DOI: 10.1016/S0025-3227(02)00678-3. .

YLMAZ, O., DOHERTY, S. **Seismic Data Analysis: Processing, Inversion, and Interpretation of seismic data.** vol I ed. [S.I.], SEG, 1987.

ZHANG, S., SCHUSTER, G., LUO, Y. "Wave-equation reflection traveltime inversion", v. 56, n. 5, p. 2705–2710, 2011. DOI: 10.1190/1.3627756. .