



3-D Pre-Stack Depth Migration to Enhance Reservoir Imaging in Deep Water A Pilot Project Applied to Reservoir Characterization in Campos Basin

Elen Delone and Ernesto Lemos, PGS
Carlos Eduardo B. S. Abreu and Paulo Johann, Petrobras

Abstract

Usually, 3-D pre-stack depth migration (PSDM) of seismic data is applied in a structural complex settings (thrust belts, salt deformation, extremely faulted environment, etc) for exploration purpose.

In the last years there has been a significant evolution in imaging the subsurface by pre-stack depth migration methods. Many oil and services companies, universities and research centers worked hard to introduce this new methods. Increasing computer power and the better results are enabling to apply more complex algorithms of PSDM and to open the application of this seismic processing to enhance reservoir imaging and to support drilling decisions.

This paper is focalized over a pilot project applied to reservoir characterization in Campos Basin where the results of PSDM enhanced reservoir imaging in Campos basin. After 3-D PSDM same important suitable faults related to the reservoir with a important impact in the drainage plan were better imaged.

Introduction

Recently, Roden and Fagin (TLE, May 2001) made an interesting introduction of pre-stack migration section. This introduction list same issues that PSDM is confronted: (1) poor data, (2) incorrect geologic models and associated velocity fields, (3) inaccurate processing algorithms, (4) anisotropy, (5) near surface, (6) topographic effects, (7) lack of a true amplitude solution, (8) limited computer power, (9) overall cost.

The second point is related to the working relationship between the interpreter and processor to collaborate closely and determine the parameters necessary to truly image subsurface. We believe that this issue is the most important phase to improve the results of PSDM, particularly to enhance

reservoir imaging and influence drilling decisions.

Grech, Chedale and Lawton (TLE, May 2001) show that the benefit of imaging using PSDM is derived from accurately computing the behavior of the wavefield as it propagates through a velocity model representative of the subsurface geology. This model integrate borehole information and surface seismic for velocity anisotropy analysis and depth imaging.

Processing Methodology and Strategies.

The whole depth imaging processing consisted of a time domain pre-processing step and the 3-D Pre-Stack Depth Migration itself. The time domain processing key task was to suppress the strong multiples interfering about the target depth. The approach used was the parabolic Radon transform, subtracting from the original data the events matching the parabolas assigned for the multiples pattern. The attenuation resulted very effective after a second pass of the Radon transform (the first one made part of the onboard sequence). Due to the very good quality of the data, this procedure didn't degrade the primary events, preserving the resolution.

The depth imaging sequence consisted basically on the classic approach of updating vertical velocity functions through a 3-D velocity analysis performed on depth migrated gathers, following a sequence of iterations (Figure 1). Before the final migration there were five velocity iterations and one iteration exclusively to migrate with a new operator. Due to the particular purpose of the project, aiming at providing an enhanced mapping of the producing oilfield, careful impulse response tests were done. In order to obtain the maximum resolution it was tried to push the anti-alias filter farther than usual. The strategy was to start with an

open filter and hi-cut down to a satisfactory result. This new operator achieved a subtle enhancement in resolution, resulting a crisper image. Also on behalf of the resolution, the final product consisted of a volume with full range of offsets (4500m) and a second one with the offset limited to 2400m. Due to eventual poor velocity analysis on the low coverage areas, longer offsets could in some cases interfere on the imaging quality of the relatively shallow target depths (2200 to 3200m).

The procedure KDMIG of the Cube Manager from PGS was the depth migration routine. It is a Kirchhoff based depth migration algorithm. Each velocity iteration is computational intense. An initial velocity model is generated through the model builder program MODEL.M. The first iteration from the rms velocities picked in time. It is raytraced to produce travel time tables to migrate. The pre-stack data was migrated for gathers on a grid of 500x500 meters and for QC sections on a grid of 500x25 meters. From the depth migrated gathers semblance panels were created to enable the picking for the velocity update. From the updated velocity functions a new velocity model is generated to reiterate. The final cube was migrated on a grid of 25x25 meters.

Application in Campos basin

The pilot study of 3-D PSDM applied to enhance reservoir imaging and to support drilling decisions was carried out in a oil field in Campos basin (Figs. 2 and 3). This oil field reservoirs are Oligocene/Miocene and Paleocene/Eocene turbidites. Individual Oligocene/Miocene reservoirs comprise lenticular and NW-elongated sandbodies; their amalgamation form up to 30m-thick sand-rich successions. Eocene/Paleocene reservoirs are confined to a NW-oriented, fault-bounded through, reaching maximum net sand thickness of 100m. The most important challenge in the field development is the positioning of horizontal water injection wells, since they are placed near the reservoir margins, and their 700m to 1300m-long trajectory crosses sandstones thinner than 10m.

The pilot project was carried out over an area of 200 km² oriented NW-SE. The water depth from 600m to 1000m. Target reservoir from 2800m to 3000m. Cable length of 4500m. Fold coverage of 120.

The Figures 2 and 3 shows the images after PSDM processing over offshore Brazil reservoirs. The Paleocene and Oligocene and Miocene reservoir with some faults control were enhanced after PSDM application.

Conclusion

We believe that in the near future most of seismic data will be in depth. Seismic imaging in depth for D&P propose is the better way to G&G integration and to support drilling decisions. The dynamically integration of G&G model into the flow simulation will replace the concept of "statical model". The 3-D PSDM will help us to improve G&G and reservoir engineering integration and to optimize the D&P process.

In this paper we show in a pilot project over a oil field in Campos basin how the 3-D PSDM oriented to reservoir propose can improve the reservoir imaging, particularly to enhance suitable faults.

Acknowledgements

We thank Petrobras for permission to publish this paper.

References

- Grech, M. G. K., Cheadle, S. and Lawton, Integrating borehole information and surface seismic for velocity anisotropy analysis and depth imaging, TLE, May 2001.
- Roden, R. and Fagin, S., An introduction to pre-stack depth migration, TLE, May 2001.

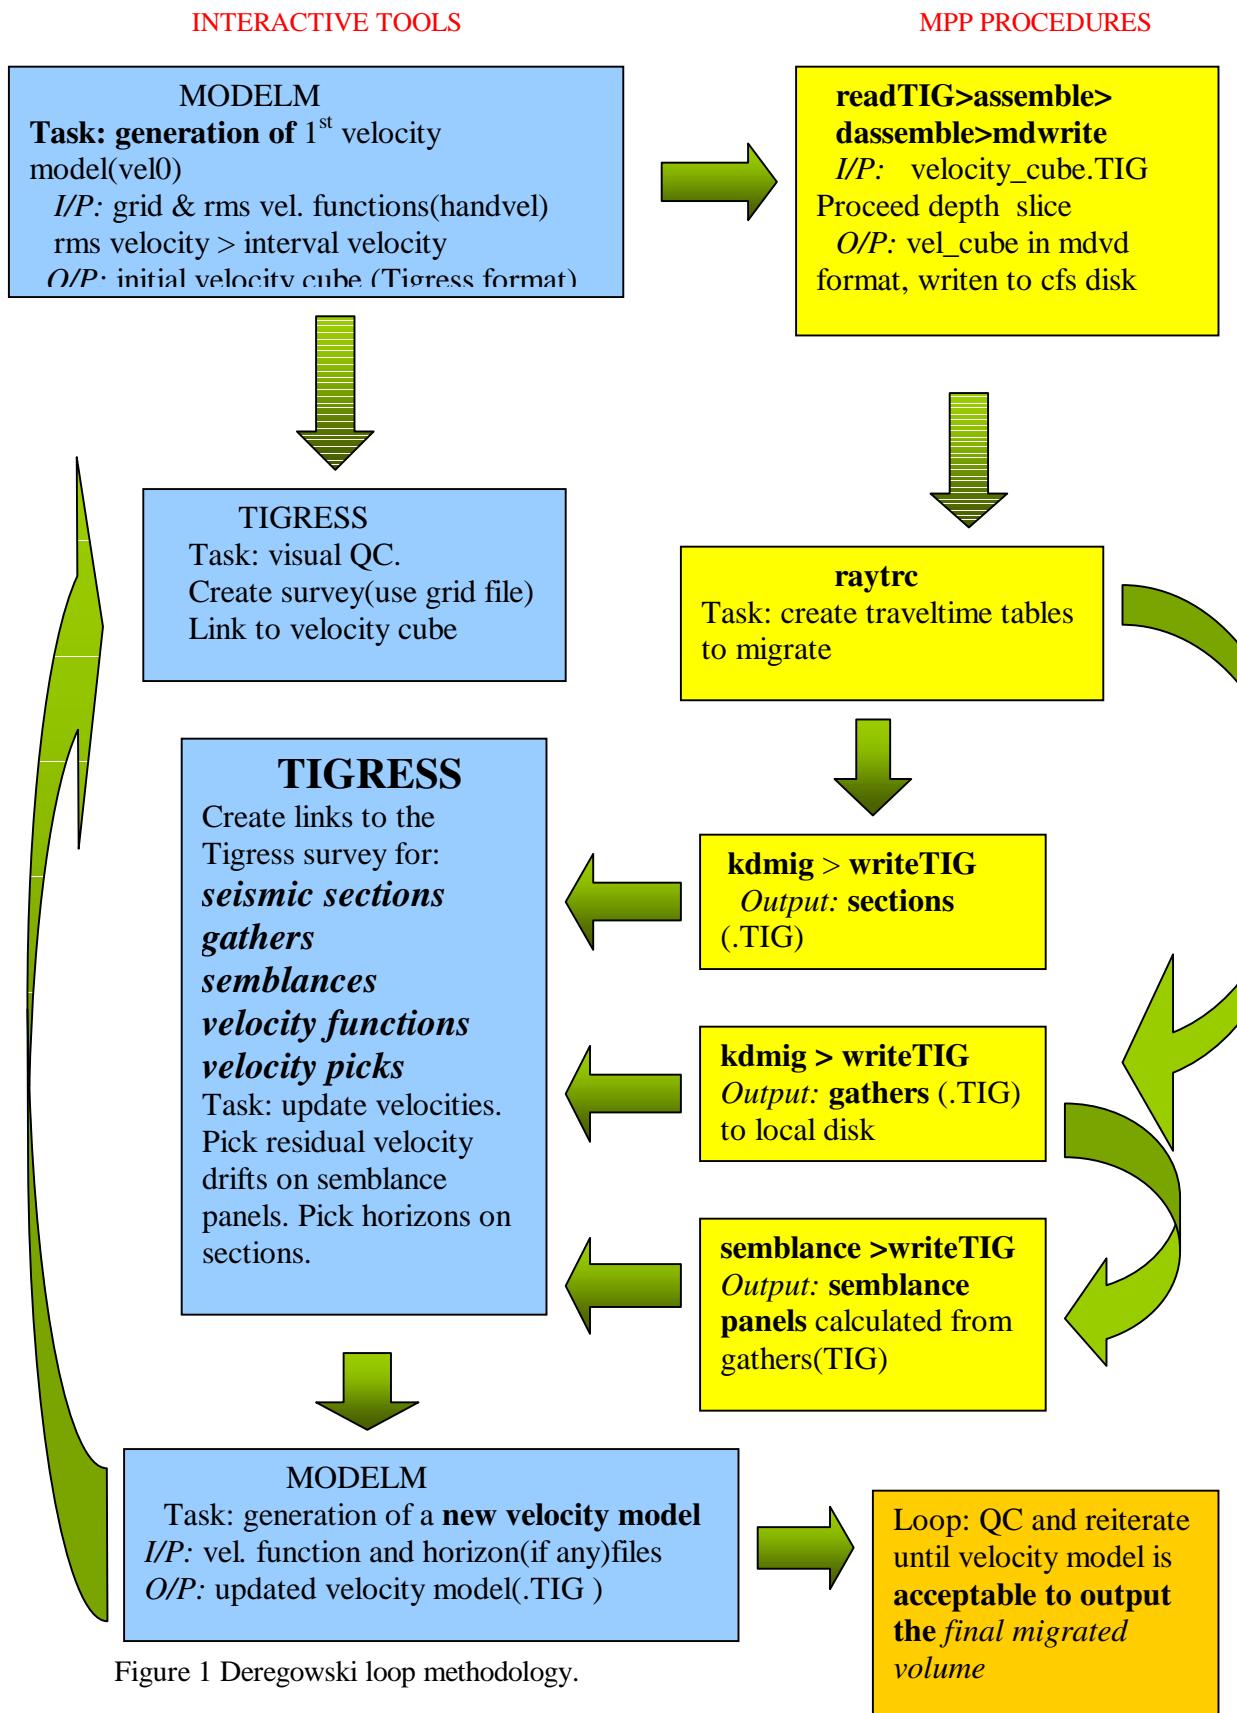


Figure 1 Deregowski loop methodology.

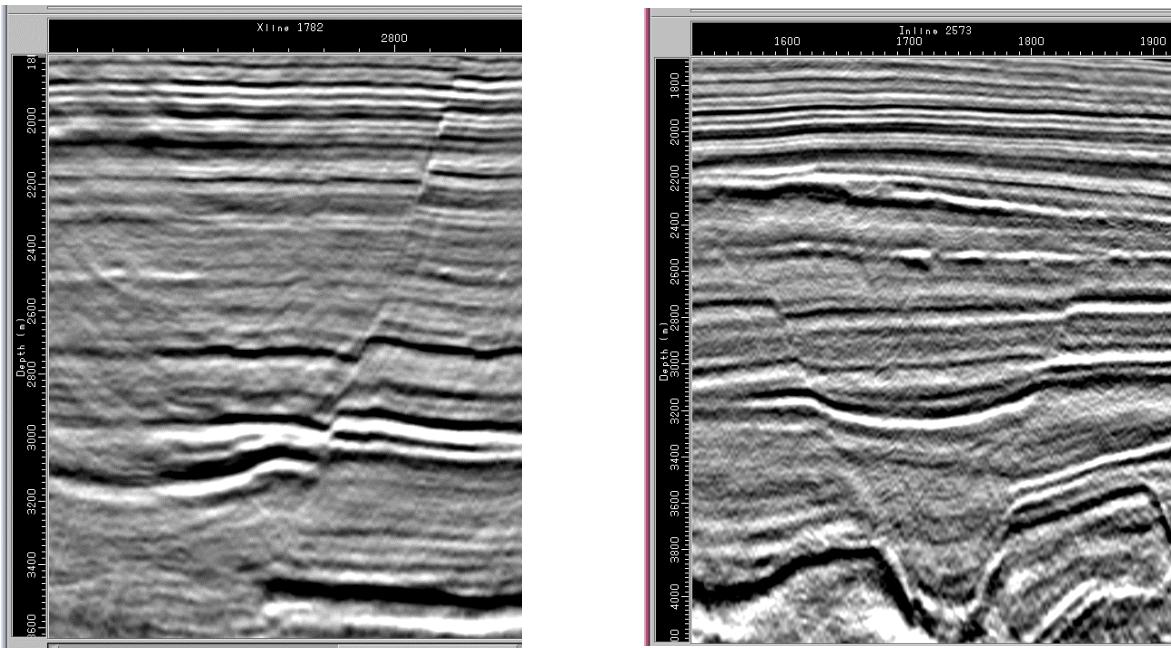


Figure 2 - a) PSDM enhance paleocene reservoir; b) PSDM enhance oligo-miocene reservoir.

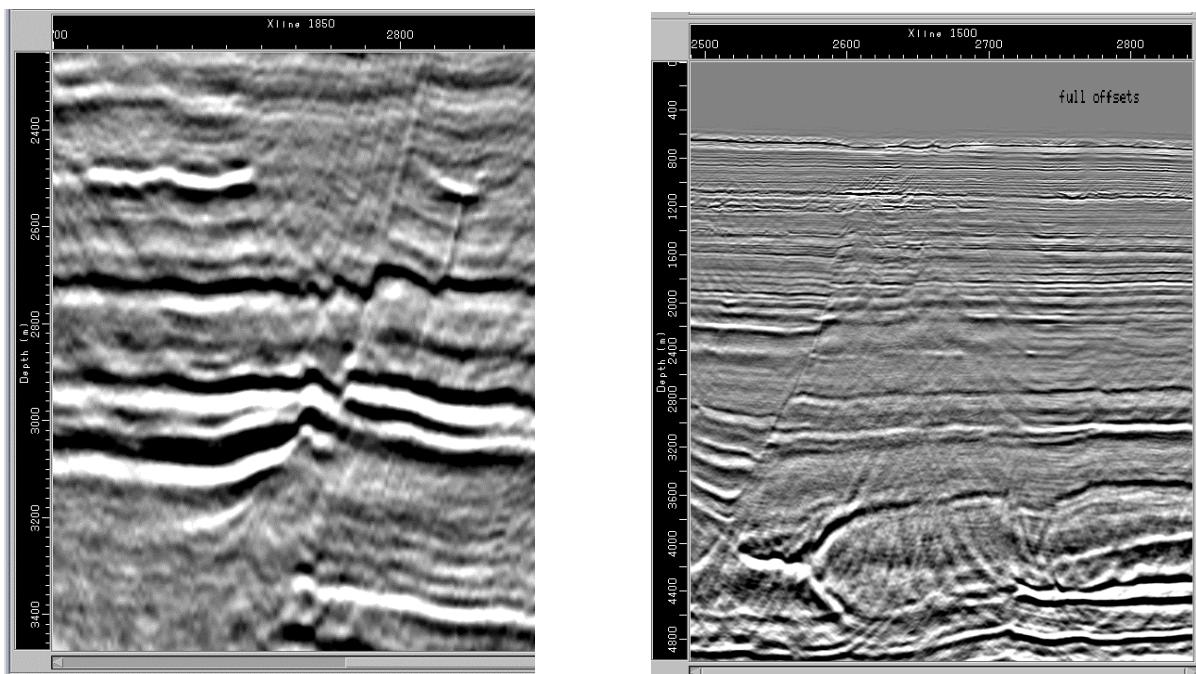


Figure 3 - a) PSDM enhance Paleocene and Oligo-Miocene reservoir; b) PSDM seismic section.



A comparative study on periodic noise cancellation

Telesson Neves Teles, DQE/UESB, Brazil, telesson@uesb.br

Abstract

Three approaches for canceling periodic noise on seismic traces are presented and compared. This included the Wiener, the Recursive Least Squares and the Adaline (Adaptive Linear network) filtering performances. The noise-cancellation can be performed in both stationary (time-invariant) and non-stationary periodic noise environment. Improvement in performance with respect to the conventional Notch filtering is achieved because the noise-cancellation is effected by subtracting the actual estimated periodic signal from the input seismic data to each time sample. In order to show the effectiveness of the presented cancellation procedures, the time and frequency domain curves and results for predictive deconvolution of synthetic corrupted traces, with and without cancellation schemes, are presented.

Introduction

Seismic data are frequently contaminated by periodic noise. It can be originated from many sources during the seismic acquisition as power-line interference, rotating machinery and so on. These interferences generally overlap the seismic signal spectrum and may vary during the seismic trace recording. This type of noise can result degradation in the pre-stack processing of the seismic traces.

In order to reduce these degradation effects, several methods of attenuating this type of interference are proposed. The main goal is to increase the signal-to-noise ratio (S/N) of the seismic trace in order to get improvement of the further pre-stack processing stages. Take into account the periodic nature of the noise, it can be described by its Fourier series (sum of sinusoidal components). In this way, the application of many Notch filters (analog or digital) is the traditional way of dealing with this kind of noise. However, this method has disadvantages, it attenuates the desired signal frequencies around the Notch frequencies. As pointed out by Linville and Meek (1992), this limitation can be overcome by using a Wiener filter to estimate the parameters (amplitude and phase) of the sinusoidal components of the periodic noise. The estimated periodic noise is then subtracted (canceled) from the seismic trace. This method works well only for stationary periodic noise, i.e., when the amplitude and phase of the sinusoidal components don't vary along the seismic trace.

When the parameters of the periodic interference vary along the trace (non-stationary signal), alternative methods must be used. The use of any of above methods would lead to unacceptable distortion of the desired signal. Adaptive noise cancellation is an alternative way of removing non-stationary noise contribution from a signal, where, in a certain extent, a priori knowledge of the signal statistics is not necessary. Many authors have described the importance of the adaptive noise cancellation in geophysical applications in the past few years (Harris et al, 1991; Linville and Meek, 1992; Dragoest, 1995). It is essentially a filter with self-adjusting characteristics. The coefficients of the filter may vary and cannot be specified in advance. They are adjustable or modifiable automatically in order to improve its performance in accordance with some criterion, allowing the filter to adapt to changes in the input signal characteristics. In this paper two approaches for adaptive canceling of periodic noise in seismic data are presented. They are the Adaline network, which uses the LMS (least mean square) algorithm in the net learning, and the RLS (recursive least squares) algorithm. These techniques are two of the most widely applied methods in adaptive signal processing. The Adaline network was originally introduced by Bernard Widrow in 1975 and since then has found many technical applications (Haykin, 1994). In the same way, the RLS is the most widely used algorithm in engineering applications (Astrom et al, 1995). Although these filters can lead with time variant periodic signals, they present the problem of the learning time. That is, if a transient occurs and the periodic signal parameters change, the filter will take some time to learn the new parameters. Both methods don't require any matrix inversion procedure in opposition to the Wiener filter design. In the numerical results and discussion section, the adaptive performances of these two methods are presented and compared with the Notch and Wiener filter ones.

In order to evaluate the importance of the periodic noise canceling in the seismic processing, results for time and frequency domain curves and for predictive deconvolution of the output trace after applying the Notch, Wiener, Adaline network and RLS filters are also presented.

All the algorithms presented in this work require that the fundamental frequency of the periodic interference be known exactly. This is a simple task. In this work, the automatic frequency search

Periodic noise cancellation

procedure described by Linville and Meek (1992) was used.

Periodic Noise Cancellation

The figure 1 shows the usual scheme for noise cancellation that uses a reference noise signal $n_1(n)$, which is correlated with the interference signal $n_2(n)$ of the seismic records. The inner n represents the discrete time. The primary input consists of seismic $s(n)$ and interference (periodic noise) $n_2(n)$ signals while the reference input consists, in our case, of multiple sinusoidal (sine and cosine) signals, which are harmonic components of the periodic noise $n_1(n)$.

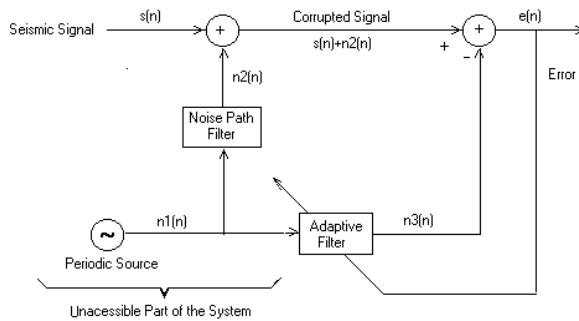


Figure 1: Noise Cancellation Scheme

The system tries to reduce the impact of the noise in the primary input exploring the correlation between the reference noise input and the interference $n_2(n)$. This is equivalent to the minimization of the mean-square error $E[e^2(n)]$ where

$$e(n) = s(n) + n_2(n) - n_3(n)$$

Having in mind that, by assumption, $s(n)$ is correlated neither with $n_2(n)$ nor with $n_1(n)$, we have

$$E[e^2(n)] = E[s^2(n)] + E[n_2(n) - n_3(n)]^2.$$

In other words, the minimization of $E[e^2(n)]$ is equivalent to the minimization of the difference between $n_2(n)$ and $n_3(n)$. Obviously that $E[e^2(n)]$ will be minimal when $n_3(n) \approx n_2(n)$, i.e. when the impulse response of the adaptive filter closely mimics the impulse response of the noise path. The minimization of $E[e^2(n)]$ can be achieved by updating the filter coefficients, as explained in the following.

The figure 2 shows the filter structure used for periodic (multiple sinusoidal) noise canceling in this work. $d(n)$ is the corrupted input seismic trace,

containing both the desired signal and the periodic noise, assumed uncorrelated with each other; $x_i(n)$ are the sinusoidal reference signals which are correlated with the periodic interference; w_i are the filter coefficients computed/updated by a specific algorithm; $y(n)$ is the estimated interference signal; finally, $e(n)$ is the output trace obtained by subtracting the estimated interference signal from the input signal. The output signal $e(n)$ is also a prediction error signal which is used for feedbacking the algorithm in order to adjust the filter coefficients. The number of the filter coefficients depends on how many sinusoidal components (harmonics) have the periodic interference. In this way, we use an algorithm to learn the Fourier series coefficients that constitute the periodic noise. That is, we use an model-based filter, where the model is the Fourier series of the periodic noise. This kind of filter is called FLC (Fourier Linear Combiner) based filter.

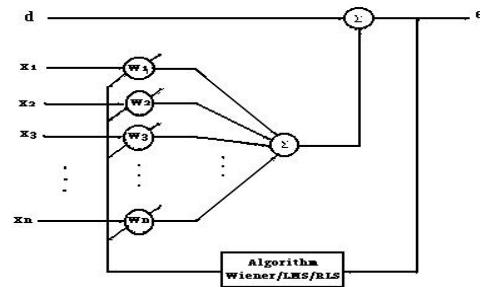


Figure 2: Schematic Diagram of the Filter

In case of stationary interference, the mean square error is exactly a quadratic function of the filter coefficients, with a single and defined minimum point. The filter coefficients correspond to this point, which determines the optimum Wiener solution. The filter coefficients are computed by solving the so called Wiener-Hopf equations, which are obtained by making the derivatives of the quadratic error function with respect to the filter coefficients equal to zero. This linear system of equations depends on both the auto-correlation of the reference signals and the cross-correlation between these signals and the input one. The algorithm must be applied to the portion of the trace where the interference level is greater than the desired signal, as on the part of the data before the first arrived or on the final gate of the trace.

If the interference is not stationary, i.e., the amplitude and phase of each harmonic vary along the trace, we have to consider adaptive algorithms, which adjust the filter coefficients from sample to sample such that the error signal is minimized according to some criterion. Common approaches are the Adaline

Periodic noise cancellation

neural network and the recursive least squares (RLS). The first one uses the least mean square (LMS) algorithm in the updating of the synaptic weights (filter coefficients) and can be seen as an approximation of the discrete Wiener filter and the second one is based on the well known least squares method.

In the LMS algorithm, the Wiener-Hopf equations are modified by using the steepest descent algorithm. It requires the gradient information at each sample instant, which depends on the correlation matrices described above. The algorithm uses then the instantaneous estimates of these matrices in order to evaluate the required gradient. In non-stationary situation, the orientation of the quadratic error surface varies with the time, so that the LMS algorithm proceeds simultaneously the seeking and tracking of the minimum point in the parameter (filter coefficients) space. The convergence and stability of the algorithm can be controlled by a learning parameter (μ). The main limitations of the LMS algorithm are the convergence rate and the sensibility to variations of the auto-correlation matrix conditioning.

The RLS algorithm is an on-line version of the least square (LS) method. The ordinary least square solution is obtained using all data points of the trace and the estimated parameters can be computed by any suitable matrix inversion technique. Clearly, the LS method is not applicable for on-line adaptive filtering. The RLS algorithm improves the estimated parameters using each acquired new data sample of the input trace by means of a recursive method. The algorithm is based in the matrix inversion lemma that allows the matrix inversion in a recursive way. In the RLS algorithm the filter coefficients can be updated for each new sample without repeatedly solving the matrix inversion. In order to remove the effects of the old past data and to allow the tracking the varying parameters, an exponential forgetting factor (λ) can be used in the algorithm. This factor will control the stability and rate of convergence in the adaptive process. The main limitation of the RLS algorithm is the numerical instability problem.

An extensive theoretical treatment on the Wiener, Adaline Network and RLS methods as well as the related algorithms can be found in Haykin (1994) and Astrom (1995).

Numerical Results and Discussion

In order to show how the cancellation schemes work, a seismic trace with a periodic interference composed of two sinusoids was generated. The seismic trace

was generated by the convolution between a minimum phase wavelet and a white reflectivity sequence. In this first experiment we added two stationary sinusoids (60 and 120 Hz) with different amplitudes and initial phases. In this case, the Wiener filter efficiently removes the sinusoidal interference without attenuating the desired signal, as we can see from the amplitude spectrum in figure 3. It is important to remind that the notch filter couldn't get the same result, because it removes the signal information around the notch frequencies.

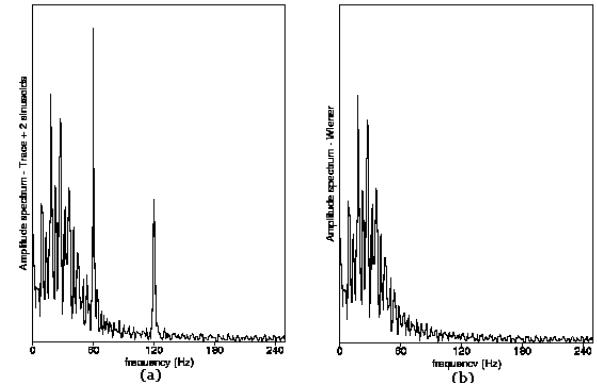


Figure 3: Amplitude spectrum of the (a) input (corrupted signal) and (b) output (filtered signal).

In the second experiment we showed how the adaptive algorithms work. A periodic signal with two harmonic components was generated. The amplitude and phase of the first one were changed at the sample 600. The same occurs for the second sinusoid at the sample 1200. We can see from the figure 4 the adaptive performance of the Adaline and RLS filters for a suitable choice of the parameters μ and λ , respectively. This figure shows the tracking of the sinusoids parameters (amplitude and phase) by both LMS and RLS algorithm.

The performances of the adaptive cancellation schemes in a non-stationary environment were evaluated in a third experiment. A seismic trace was generated as in the first experiment. Now, we change the amplitude and phase of the sinusoids at the center of the trace. In this case the Wiener filter had not the same performance as before, so that the output trace still contained sinusoidal components. Then we applied the Adaline and RLS filters. In order to increase convergence, the algorithms were initialized with the filter coefficients estimated by the Wiener algorithm. Both algorithms efficiently removed the periodic interference from the corrupted trace as can be seen in figure 5. The RLS algorithm required more computation time than the Adaline filter. However,

Periodic noise cancellation

the RLS algorithm showed superior convergence properties.

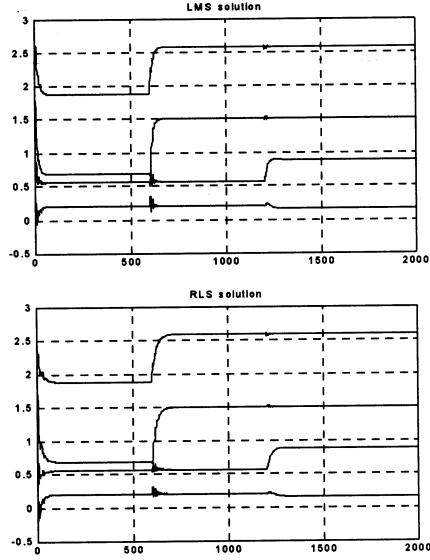


Figure 4: LMS and RLS tracking

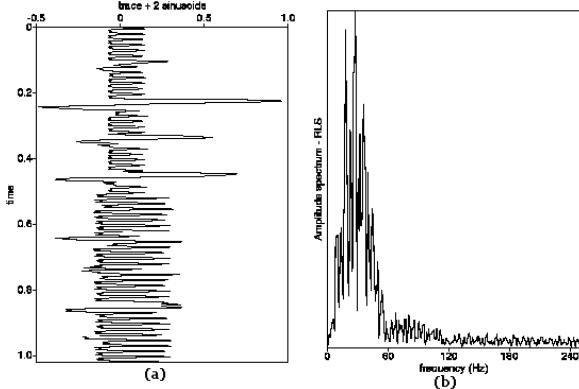


Figure 5: (a) Seismic signal corrupted by non-stationary periodic noise. (b) Amplitude spectrum after RLS filter.

We also showed the importance of applying the periodic noise cancellation as a pre-processing step. We evaluated the results for predictive deconvolution of the output traces after the notch, Wiener, Adaline and RLS filtering. In the two first cases, the deconvolution leads to poor signal to noise ratio and to signal distortion when seismic traces are corrupted by non-stationary periodic noise. These effects were minimized when we applied the adaptive cancellation scheme prior to deconvolution, as can be seen in figure 6.

Considering the three filters evaluated in this work, we can conclude that the Wiener filter is the best choice for stationary periodic noise. In the non-

stationary situation, it is clear that the choice of the adaptive approach to be applied is always a tradeoff between computational complexity and fast convergence.

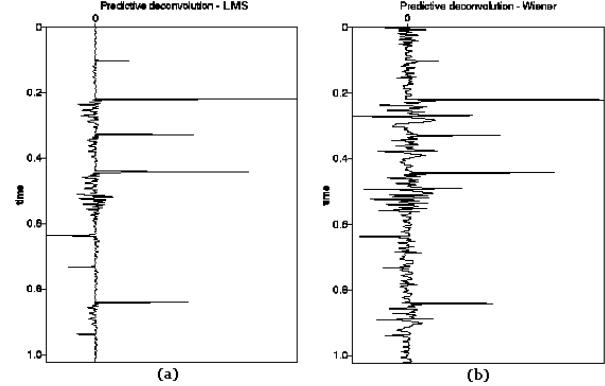


Figure 6: Predictive deconvolution of the output (filtered) trace after (a) Adaline and (b) Wiener filtering. The input trace was corrupted by a non-stationary periodic interference.

Conclusions

Three filters for stationary and non-stationary periodic noise cancellation in the seismic traces were presented and evaluated. The algorithms removed the periodic interference while leaving the desired seismic signal almost unperturbed. In the stationary case the Wiener filter showed the best performance, but it demanded a matrix inversion. In the non-stationary case the RLS filter showed a good convergence while the Adaline/LMS filter showed a good computation efficiency. It confirms the tradeoff between computational complexity and fast convergence. It was also shown the importance of canceling periodic (multiple sinusoidal) noise before any pre-stacking seismic processing scheme.

References

- Astrom, K., Goodwin, G. and Kumar, P., 1995. Adaptive Control, Filtering and Signal Processing. New York, Springer-Verlag.
- Dragoest, B., 1995. Geophysical applications of adaptive-noise cancellation, SEG annual meeting expanded abstract , 1389 – 1392, Houston.
- Harris, D. B., Jarpe, S. P. and Harben, P. E., 1991. Seismic noise cancellation in a geothermal field, Geophysics, 56, 1677 – 1680.
- Haykin, S., 1994, Neural Networks: a Comprehensive Foundation. NY, Macmillan Pub. Company.
- Linville, A. F. e Meek R. A., 1992. Canceling stationary sinusoidal noise, Geophysics , 57, 1493-1501.



A deconvolução consistente em superfície na presença de ground roll.

Armando Lopes Farias, PETROBRAS S/A, Brasil

Resumo

A deconvolução estatística, desde seus primórdios, sempre mereceu variadas considerações. Dentre aquelas que mais se destacam estão as que se propõem a resolver ou atenuar os problemas causados pelas premissas assumidas na deconvolução de Wener monocanal, particularmente relacionadas à aleatoriedade da função refletividade, às características de fase mínima dos termos envolvidos no modelo convolucional, bem como à ausência de elementos estranhos do tipo *ground roll*, que não respeitam as premissas citadas. Apesar da deconvolução consistente em superfície ter surgido para contornar parte destes problemas, poucos ainda são os trabalhos mostrando de forma cabal as situações em que se teria vantagens desta segunda sobre a primeira e as razões para isto. Aqui procuraremos demonstrar que a deconvolução consistente pode ser extremamente vantajosa principalmente na presença de ruídos de baixa freqüência, particularmente onde o ruído for não dispersivo.

Introdução

É largamente sabido que de maneira geral as premissas assumidas no processo de deconvolução não são respeitadas. No caso da refletividade, por exemplo Rosa and Ulrych, 1991, além de outros autores, observaram que ao invés de ser branca ela tem suas amplitudes crescentes com a freqüência. Já para ruídos de baixas freqüências, normalmente é assumido que as filtragens são suficientemente eficientes a ponto do resultado não perturbar o processo de deconvolução. Acontece que soluções do tipo filtro de freqüência ou balanceamento espectral não devem ser utilizados antes da deconvolução, restando pois o recurso das filtragens multicanais, que nem sempre são suficientemente eficientes. Estes dois problemas em particular, bem como o ruído aleatório, foram abordados por Cary and Lorentz (1993), quando foi verificado que a função refletividade e o *ground roll*, sob certas circunstâncias, tendem a ser capturados pelo termo *offset*. Nestas condições a definição do operador de deconvolução apenas com os termos tiro e receptor poderia proporcionar resultados muito mais consistentes com a *wavelet* a ser deconvolvida, diminuindo as distorções geradas por falsas premissas. Aqui veremos que o termo *offset* normalmente só consegue capturar o *ground roll* em situações especiais, não conseguindo fazê-lo quando o ruído é dispersivo.

O modelo teórico da deconvolução consistente em superfície

Para estudarmos a deconvolução consistente em superfície, faremos uso de um modelo convolucional simples:

$$y(t) = w(t) * i(t) + x(t),$$

onde $y(t)$, $w(t)$ e $i(t)$ são respectivamente o traço sísmico, a *wavelet* de fase mínima associada aos efeitos de propagação de superfície, também de fase mínima, e a função refletividade. Já $x(t)$ representa eventuais ruídos adicionados ao traço sísmico presentes na janela de autocorrelação, sendo que aqui destacaremos como sendo o *ground roll* e os ruídos aleatórios. Mas como podemos assumir que o traço sísmico pode ser definido pelos quatro termos de consistência, podemos redefiní-lo como:

$$y(t) = s_i(t) * r_j(t) * m_n(t) * g_k(t),$$

onde $s_i(t)$, $r_j(t)$, $m_n(t)$ e $g_k(t)$ representam o termo tiro, o receptor, o *offset* e o CDP respectivamente. Os subscritos i , j , n e k representam o posicionamento dos diferentes termos, sendo que $n = j - i$ e $k = (i + j)/2$. No caso de uma deconvolução monocanal o operador não discrimina os elementos presentes dentro da janela de autocorrelação. Assim toda a informação lida será invertida, gerando um operador de fase mínima daquela informação. Portanto a função refletividade e eventuais ruídos de baixa freqüência presentes na janela de autocorrelação serão deconvolvidos.

Na deconvolução consistente, desde que o traço pode ser distribuído em seus vários elementos de consistência, também o operador pode ser composto de forma conveniente, excluindo informações que eventualmente não se queira deconvolver. Se por exemplo, durante o processo de distribuição das amplitudes lidas na janela de autocorrelação, as informações relativas à função refletividade e aos ruídos de fonte, forem capturados pelo termo *offset*, e o ruído aleatório for capturado pelo termo CDP, ou seja, se os

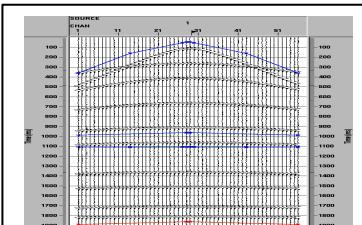


Fig. 1 - Modelo com a função refletividade.

A deconvolução e o ground roll

dois termos capturarem o fator $x(t)$ do modelo convolucional, o operador de deconvolução ideal seria aquele onde se aplicasse apenas os termos tiro e receptor. Assim exercitando esta hipótese no domínio da freqüência:

$$O(f) = \frac{e^{-i\mathbf{q}_s(f)} e^{-i\mathbf{q}_r(f)}}{|S_i(f)| |R_j(f)|}$$

Desta forma ao se aplicar este operador no traço $Y(f)$, ainda no domínio da freqüência:

$$Y'(f) = \frac{|S_i(f)| |R_j(f)| |M_n(f)| |G_k(f)|}{|S_i(f)| |R_j(f)|} \times e^{i\mathbf{q}_s(f) + i\mathbf{q}_r(f) + i\mathbf{q}_m(f) + i\mathbf{q}_g(f) - i\mathbf{q}_s(f) - i\mathbf{q}_r(f)}$$

$$Y'(f) = |M_n(f)| |G_k(f)| e^{i\mathbf{q}_m(f)} e^{i\mathbf{q}_g(f)}$$

Ou seja, caso a hipótese considerada esteja correta, a função refletividade, o ruído aleatório e o *ground roll* não seriam deconvolvidos, pois não foram capturados pelos termos tiro e receptor, e o resultado final da deconvolução no tempo neste cenário ideal seria:

$$y'(t) = i(t) + x(t)$$

Portanto, os termos tiro e receptor capturaram apenas a wavelet associada aos efeitos de propagação em suas vizinhanças, regiões que normalmente produzem as maiores absorções devido suas características geológicas.

Os resultados

A figura 1 mostra um modelo onde não se tem nenhuma *wavelet* convolvida, apresentando apenas a função refletividade, de espectro não plano. Os efeitos da deconvolução sobre a refletividade serão analisados para diferentes janelas, sendo que a primeira foi definida nos tempos iniciais, portanto com refletores

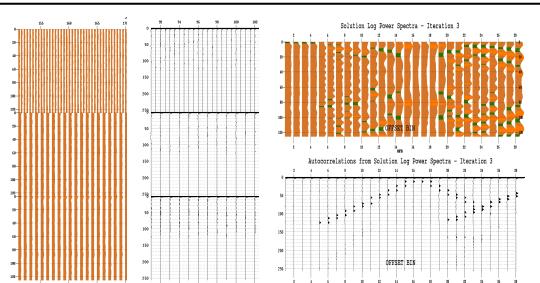


Fig. 2- Espectros de amplitude e as respectivas autocorrelações dos termos CDP (superior esquerda), receptor (central esquerda), tiro (inferior esquerda) e offset (direita), relativos à primeira janela

apresentando forte *move out*, e a segunda nos tempos finais, praticamente não apresentando *move out*. As figuras 2 e 3 mostram os espectros de amplitudes e as respectivas autocorrelações dos termos CDP, recep-

tor, tiro e *offset*. Na figura 2, primeira janela, os espectros dos três primeiros termos são planos, com as autocorrelações concentrando a energia no *lag* zero. No último observamos nos espectros de amplitudes e nas autocorrelações, que cada *offset* capturou de forma diferente a energia do dado. Já na figura 3, enquanto o espectro do termo tiro torna-se colorido,

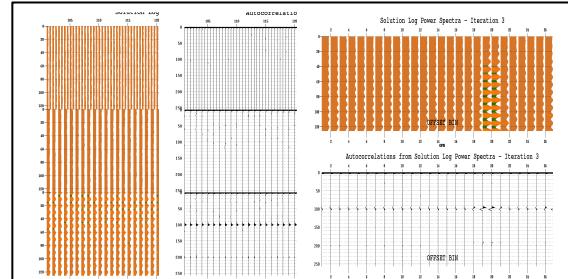


Fig. 3- Espectros de amplitude e as respectivas autocorrelações dos termos CDP (superior esquerda), receptor (central esquerda), tiro (inferior esquerda) e offset (direita), relativos à segunda janela.

todos os outros inclusive o termo *offset*, apresentam-se planos. Como a geologia não varia lateralmente, e o modelo só tem a função refletividade, a única mudança que existe dentro dos diferentes domínios é o *move out*. Desta forma à exceção do *offset*, onde cada *gather* apresenta-se diferente dos outros, no caso da primeira janela, no tiro, receptor e CDP, ao contrário, todos se repetem. Desta forma a alta freqüência, representada neste caso pelas variações na refletividade com o *offset*, será capturada por aquele termo. No caso da segunda janela, devido à ausência de *move out*, não mais vai existir variação da refletividade com o *offset*, ou seja, não mais se terá altas freqüências para ser capturada pelo termo *offset*. Neste caso todas as informações do dado são comuns a todos os *gather's*, caracterizando-se assim um comportamento branco. Como o primeiro termo sempre captura as baixas freqüências é de se esperar que neste caso a função refletividade se concentre no termo tiro.

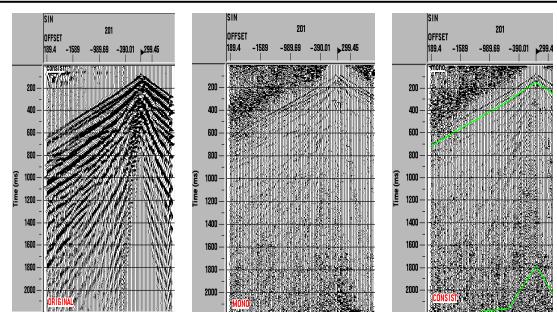


Fig. 4- Tiro original (esquerda), com deconvolução monocanal (centro) e deconvolução consistente (direita).

A deconvolução e o ground roll

No caso do *ground roll* a distribuição de sua amplitude estará condicionada à forma como ele se distribui no *gather*. Sempre que as características do terreno não variarem em demasia, mantendo-se relativamente invariável lateralmente, e não seja dispersivo, a tendência é que ele seja capturado pelo termo *offset*, independente da ordem de cálculo durante a recursão. Se ele ocorrer ocasionalmente, não sendo dispersivo, a tendência é não ser capturado por nenhum dos termos. Se no entanto ele for dispersivo, ocupando boa parte do *gather*, estando presente em todo o dado, provavelmente será capturado pelo primeiro termo da recursão. Isto só não ocorrerá caso o ruído ocorra ocasionalmente, o que fará com que fique no primeiro termo da recursão que não seja o *offset*.

Portanto não existe uma regra geral de captura do *ground roll* pelos termos da deconvolução consistente. É bem verdade que existe uma tendência favorável à deconvolução multicanal relativamente à monocanal, mas no caso do *ground roll* dispersivo e ocasional a tendência é por respostas semelhantes, não obstante a possibilidade de melhora esteja sempre na deconvolução consistente.

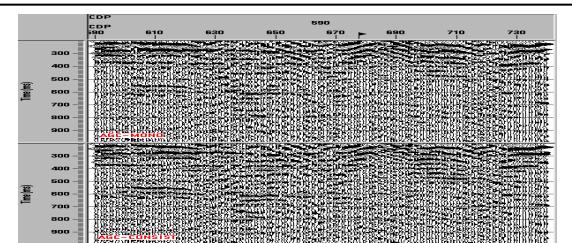


Fig. 5- Seções empilhadas com deconvolução monocanal (superior) e deconvolução consistente (inferior).

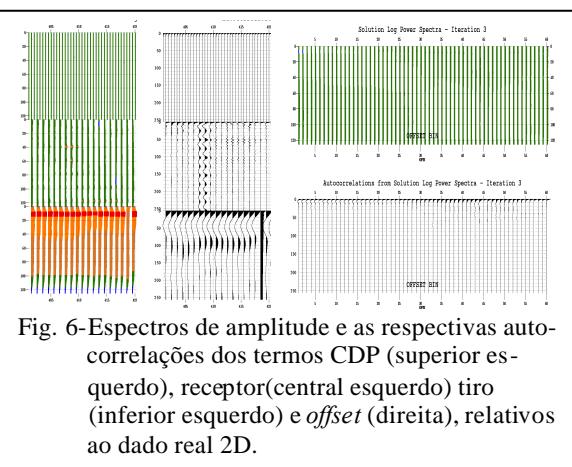


Fig. 6-Espectros de amplitude e as respectivas autocorrelações dos termos CDP (superior esquerdo), receptor(tiro) (central esquerdo) e offset (direita), relativos ao dado real 2D.

Para ilustrar as diferenças entre a deconvolução monocanal e a deconvolução consistente na pre-

sença de *ground roll*, lançaremos mão de dados reais, sendo que o dado com *ground roll* dispersivo é um 2D, enquanto o não dispersivo é um 3D. Na figura 4 vemos a comparação entre a deconvolução monocanal e a consistente para o 2D, no domínio do tiro. É notório que o *ground roll* foi deconvolvido nas duas situações, pois a baixa freqüência foi reduzida de forma considerável. Na figura 5 vemos os resultados dos empilhamentos, diferindo apenas pelas deconvoluções, mostrando pequenas diferenças.

Já a figura 6 mostra os espectros de amplitudes dos elementos de consistência e as respectivas autocorrelações. A notória captura da baixa freqüência pelo termo tiro justifica o resultado, explicado pelo fato do ruído ser dispersivo, espalhado no *gather*.

A figura 7 mostra a comparação entre as duas deconvoluções no caso do *ground roll* não dispersivo. Neste caso observamos com clareza que enquanto a deconvolução monocanal efetivamente trabalhou as baixas freqüências, a deconvolução consistente praticamente não alterou o *ground roll* presente no dado. Na figura 8 comparamos os efeitos das deconvoluções no dado empilhado. Também aí é possível observar melhores resultados na deconvolução consistente, principalmente na região entre 200 e

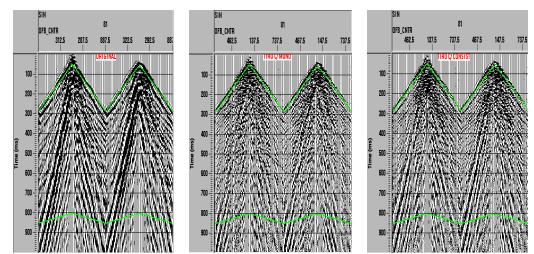


Fig. 7-Tiro original (esquerda), com deconvolução monocanal (centro) e deconvolução consistente (direita).

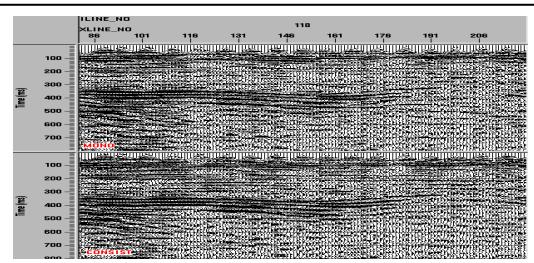


Fig. 8-Seções empilhadas com deconvolução monocanal (superior) e deconvolução consistente (inferior).

300ms, onde se tem a menor razão entre o sinal e o ruído de baixa freqüência.

A deconvolução e o ground roll

Conclusões.

Como regra geral a deconvolução consistente em superfície propicia melhores resultados do que a deconvolução monocanal, para dados terrestres. Podemos atribuir estas diferenças principalmente a função refletividade e aos ruídos de fonte. Os efeitos da refletividade são menos perceptíveis, ainda assim é de se esperar sua exclusão do operador de deconvolução no caso da deconvolução consistente, diferentemente do que ocorre na deconvolução monocanal. Já no caso dos ruídos de fonte, destacadamente o *ground roll*, as diferenças aumentam na medida que diminui a razão entre o sinal e o ruído. No entanto isto só ocorre em situações onde o ruído não é dispersivo e tem larga ocorrência lateral. Outras situações sempre vão gerar resultados intermediários, pois na medida que o ruído se espalha pelo *gather*, maiores serão as possibilidades do primeiro termo capturá-lo, contornando o operador, no caso de ser tiro ou receptor. Ainda assim esta contaminação será sempre menor do que aquela ocorrida no operador da deconvolução monocanal.

Bibliografia.

- Rosa, A. L. R. and Ulrych, T., J., 1991, Processing via spectral modeling: Geophysics, 56, 1244-1251.
Cary, P., W., and Lorentz G., A., 1993, Four-component surface-consistent deconvolution: Geophysics, 58, 383-392.

Agradecimentos.

Agradeço à Petrobras por ter propiciado condições para a realização deste trabalho. Agradeço também as sempre bem vindas e sensatas sugestões de Adelson Santos, Wander Nogueira de Amorim, Heron Schots, Margarida Mítico e André L. R. Rosa.



CRS seismic processing: a quick tutorial

V. Grosfeld, R. Biloti and R. Portugal

State University of Campinas, Brazil

Abstract

The aim of this work is to present an alternative way that could be introduced in the conventional seismic processing, using a macro model independent method. We will show how to take advantage of the results of this process to incorporate them in the normal flowchart of processing. We also present a didactic synthetic example to illustrate how the flowchart works.

Introduction

In the last few years a new method to obtain a zero-offset (ZO) stack section was introduced in the literature: common reflection surface (CRS) stack (Mann et al., 1999). It is macro-velocity model independent method and has the advantage of using more traces than the conventional process. Moreover, the CRS stack method also provides several kinematic parameters, which can be used to invert a velocity model. Consequently, the introduction of the CRS method into the conventional seismic processing can be advantageous. This work presents an alternative flowchart seismic process based on CRS and totally model independent.

CRS method

The CRS method is based on a multi-parameter travelttime approximation, called the hyperbolic travelttime formula(Tygel et al., 1997) which relates the travelttime of two rays. One of them is taken as reference ray, and is called central ray. In the CRS method, the central ray is chosen as a ZO ray and its reflection point is called Normal Incidence Point (NIP). The formula read

$$T^2(x_m, h) = \left(t_0 + \frac{2x_m \sin \beta_0}{v_0} \right)^2 + \frac{2t_0 \cos^2 \beta_0}{v_0} (K_N x_m^2 + K_{NIP} h^2),$$

where $x_m = (x_G + x_S)/2 - x_0$ and $h = (x_G - x_S)/2$, x_0 is the coordinate of the central point, x_G and x_S are the horizontal coordinates of the receiver and source, respectively,, t_0 the zero-offset two way travelttime, β_0 the emergence angle measured with

respect to the normal surface,, K_{NIP} and K_N and two wavefront curvatures associated to two hypothetical eigenwaves N-wave and NIP-wave,Tygel et al. (1997), see Figure 1.

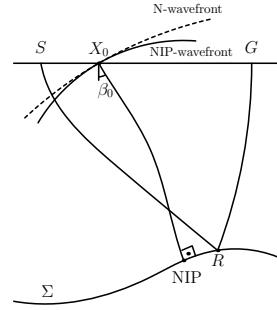


Figure 1: CRS Parameters for a normal central ray X_0 NIP X_0 : the emergence angle β_0 and the NIP- and N-wavefront curvatures. Σ is the reflector, X_0 is the central point coordinate, and S and G are the source and receiver positions for a paraxial ray, reflecting at R .

Processing sequence

The process is the same as the conventional process up to NMO stack, which is automatically performed during the CRS stack. At the end, the CRS stack method came up with three parameter sections, one coherency section and, in general, a more accurate ZO simulated section. The most relevant aspect is that the whole procedure is completely velocity-model independent and a larger number of traces is stacked than in the conventional NMO/DMO process, increasing the redundancy and the signal-to-noise ratio.

Once a ZO section is available, the method also provides a Post Stack Time Migration, without the requirement of having a velocity model in time domain. This can be achieved using only the CRS parameters.

As we have just pointed out, the CRS parameters carry to much information about the media and then we should use this parameters as much as possible. Following this idea, the classical layer-stripping velocity inversion algorithm of Hubral and Krey (1980) can be recast by using

of the CRS (Biloti *et al.*, 2001). It inverts iteratively on the depth homogeneous layers and interface positions. The interfaces are constructed as cubic splines, which are suitable for further block ray tracing algorithms. This process involves low computational costs since the CRS parameter are already available.

Once we have the inverted velocity model, it is possible to perform a complete PreStack Depth Migration (PreSDM), using weights to compensate amplitudes for geometrical spreading. Also, an unweighted PreSDM can be realized followed by a *a posteriori* amplitude correction for some common-reflection points (CRP) gathers (Portugal *et al.*, 2001). This correction is performed in three steps: (i) for the selected depth point compute the traveltimes, incidence angles and geometrical-spreading factors by modeling, using the inverted model; (ii) pick the amplitude from the original data, using the traveltime information and, (iii) multiply them by corresponding the geometrical-spreading. This CRP points are chosen in a unweight PreSDM, which has the characteristic to show a good kinematic image of the subsurface. After the AVO/AVA curves are constructed.

Synthetic example

To illustrate the just described procedure, we show step-by-step how it works on synthetic data. Figure 2 shows the compressional velocity field of synthetic model. The shear-velocity at each point is set to the compressional velocity dived by $\sqrt{3}$. The model is composed by four layers bounded by

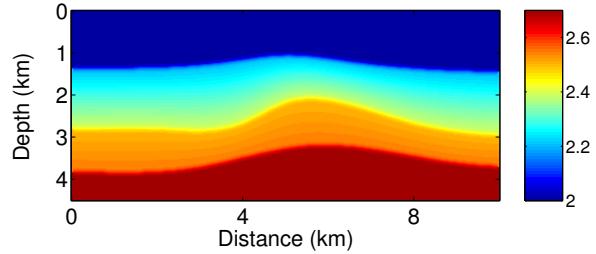


Figure 2: Synthetic model.

smooth interfaces. The top and bottom layers are homogeneous and the two intermediated layers are inhomogeneous both in x -direction and z -direction. The multicoverage data is formed by a collection of 150 common-offset section, with offset varying from 20 m up to 3000 m, with around 500 source-receiver pairs each. In Figure 3 we can see a typi-

cal common-offset section with offset 1500 m. The signal-noise ratio added to the data was 7:1.

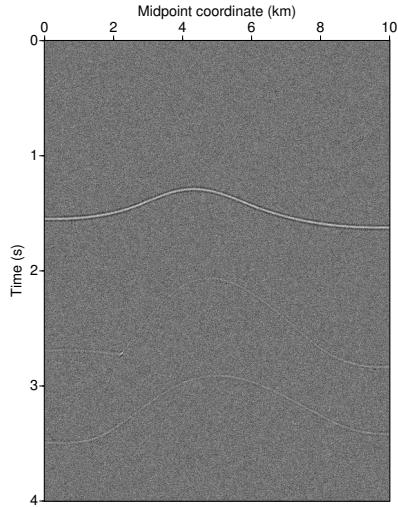


Figure 3: Example of a common-offset section.

After performing the CRS stack method, the obtained simulated ZO section is shown in Figure 4. Note the great improvement in the signal-to-noise ratio. As an example, Figure 5 presents one of the

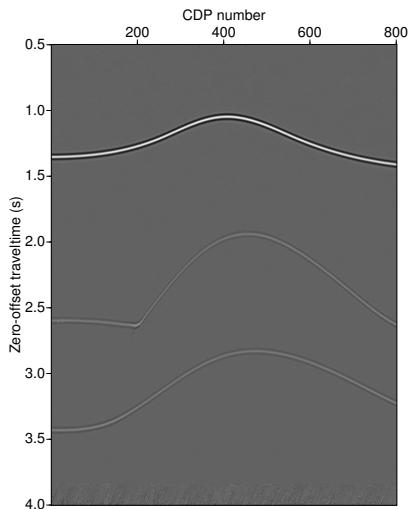


Figure 4: CRS simulated ZO section.

parameters section the emergence angle section. It is important to note that the parameter value for each point of the section make sense only if the point is indeed a reflection event. After the conclusion of the first step of the CRS, we directly proceed to the inversion step. In Figure 6 we show the inverted model where it is possible to observe that the recovered model fits very well the synthetic

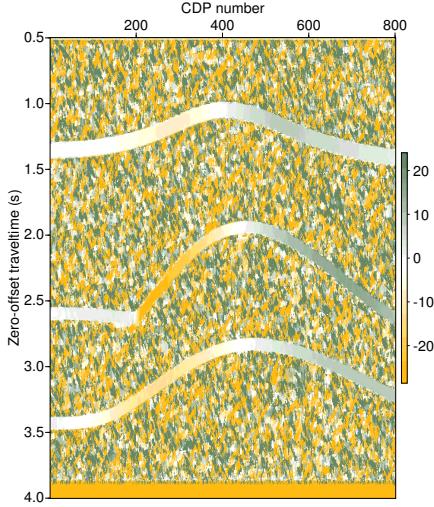


Figure 5: Emergence angle section

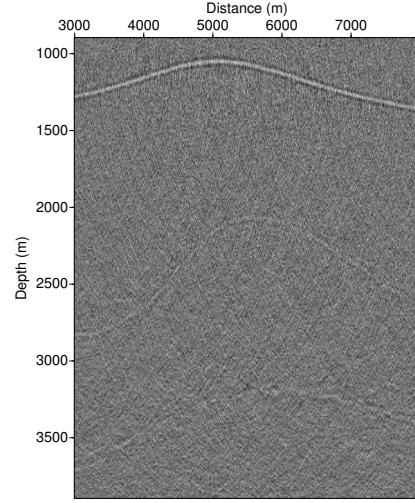


Figure 7: typical migrated section.

model, even in the inhomogeneous layers.

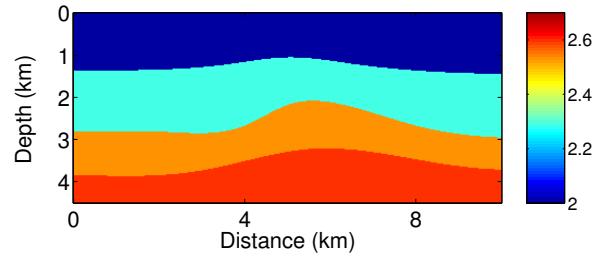


Figure 6: Inverted velocities model.

The velocity model is now smoothed in order to apply PreSDM, which is performed using the traveltime tables generated on the fly by wavefront construction method (Vinje *et al.*, 1993). Each common-offset section is migrated separately (see Figure 7), and then stacked migrated section, see Figure 8.

The stacked migration section does not have information about correct amplitudes, but it serves as an image to chose points (the CRP points) to perform the AVO/AVA curves. This is done as was discussed in the Processing Sequence section. The result for one ponint is show in Figure 9

Conclusion

The CRS method provides a powerful tool to process multi-coverage data. It allow us not only to obtain a good simulated ZO section, but also get a tool for the next steps in the conventional pro-

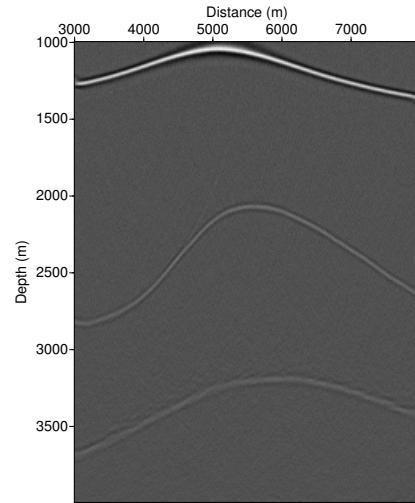


Figure 8: Stacked migrated section.

cesses. One more interesting application, that we are working on is to incorporate the acquisition topography in the method. We hope to obtain good results in cases with strong variations in the acquisition surface.

Acknowledgements

This work was partially supported by FAPESP (Grants 97/12125-8 and 97/12318-0), CAPES and by the sponsors of the WIT Consortium.

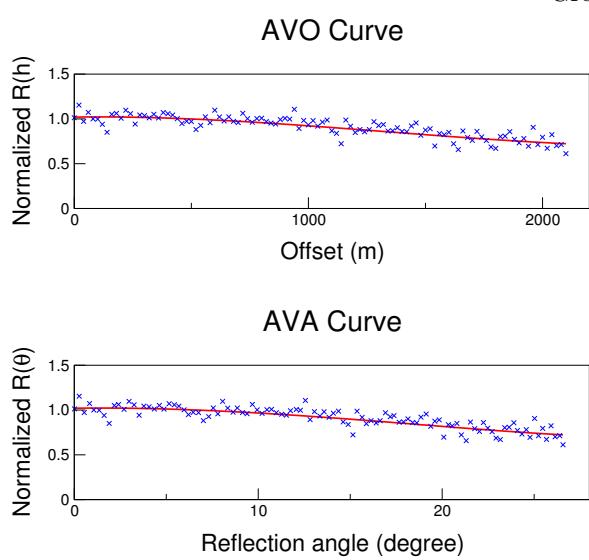


Figure 9: AVO/AVA for a point in the second interface.

References

- Biloti, R., Santos, L., and Tygel, M., 2001, Layered velocity model from kinematic attributes:, *in* 7th International Congress Brazilian Geophysical Society.
- Hubral, P., and Krey, X., 1980, Interval velocities from seismic reflection time measurements: Soc. of Expl. Geophys.
- Mann, J., Hubral, P., Höcht, G., Jaeger, R., and Mueller, T., 1999, Applications of the common-reflection-surface stack:, *in* 69th Ann. Internat. Mtg Soc. of Expl. Geophys., 1829–1832.
- Portugal, R. S., Biloti, R., Santos, L. T., and Tygel, M., 2001, CRS as tool for true amplitude imaging:, *in* 7th International Congress Brazilian Geophysical Society.
- Tygel, M., Muller, T., Hubral, P., and Schleicher, J., 1997, Eigenwave based multiparameter travelttime expansions:, *in* 67th Ann. Internat. Mtg Soc. Of Expl. Geophys., 1770–1773.
- Vinje, V., Iversen, E., and Gjøystdal, H., 1993, Traveltime and amplitude estimation using wavefront construction: Geophysics, **58**, no. 08, 1157–1166.

Deconvolução do Traço Sísmico Complexo

Adriano de Pinho Lima*, João Carlos Guedes Logrado[†] e Milton J. Porsani [‡]

Abstract

The wavelet deconvolution task is usually performed in the real domain by means of the conventional Wiener-Levinson approach. In the present paper we explore the complex domain formed with the analytic traces. A complex version of the Levinson's recursion is used to solve a hermitian system of normal equation. Numeric results for the new complex Wiener-Levinson wavelet deconvolution approach are shown.

Introdução

Desde a sua introdução ao processamento de dados sísmico, a deconvolução tem sido normalmente aplicada no traço sísmico no domínio $x - t$. A sintetização do sinal analítico ou traço complexo, realizada a partir do próprio sismograma, cria a possibilidade de aplicação da deconvolução no domínio do traço complexo. Na deconvolução do traço complexo pode-se utilizar o filtro complexo de Wiener-Levinson de predição unitária resultante da solução de um sistema hermitiano de equações normais. Neste trabalho apresentamos os fundamentos teóricos e resultados relacionados à geração e deconvolução do traço complexo.

No processamento de dados sísmico são empregadas várias técnicas de tratamento de sinais com a finalidade de gerar a melhor imagem possível da geologia da subsuperfície. Entre estas técnicas, a deconvolução é o processo que melhora a resolução temporal através da compressão da *wavelet* (Yilmaz, 1987), minimizando os efeitos distorsivos do pulso sísmico.

Em sua implementação prática a deconvolução tem sido aplicada normalmente ao traço sísmico convencional no domínio $t-x$, pré-empilhamento e pós-empilhamento. Uma outra possibilidade seria a deconvolução do traço complexo. Descrições do filtro Wiener complexo e sugestões da sua aplicação prática na área de deconvolução holográfica são encontradas em (Treitel, 1974). Entretanto não se dispõe até o momento de estudos sobre deconvolução do pulso sísmico complexo.

Este trabalho teve como principal objetivo apresentar a teoria utilizada na geração do traço complexo, e testar o método de deconvolução do pulso complexo no traço complexo em dados reais, pré e pós-empilhamento. A parte deste trabalho que trata da deconvolução do traço complexo tem como base as pesquisas recentes que tem

sido realizadas no CPGG-UFBA.

Análise do traço complexo

A análise do traço complexo trata o traço sísmico $g(t)$ como a parte real de um sinal analítico ou traço complexo, $F(t) = g(t) + ih(t)$ (Taner, 1979). A parte imaginária $h(t)$ também denominada de quadratura ou conjugado e $F(t)$ podem ser determinados unicamente, em termos da Transformada de Hilbert ou então por convolução no domínio do tempo, usando-se o operador de quadratura associado à transformada de Hilbert.

“O sinal analítico não contém componentes de freqüência negativas”, podendo ser obtido a partir do sinal real pela supressão das freqüências negativas (Bracewell, 1965 e Claerbout, 1976). Estas técnicas baseam-se na observação de que o espectro de amplitude do traço complexo desaparece para $w < 0$ e tem 2 vezes a magnitude para $w > 0$. Como a fase mantém-se constante (exceto quando ela não é definida para $w < 0$) o traço complexo pode então ser estimado da seguinte forma: (1) Transformação de Fourier do traço real; (2) Zerando-se as amplitudes para as freqüências negativas e dobrando-se as amplitudes das freqüências positivas, e (3) Transformada inversa de Fourier.

O traço complexo $F(t)$ pode ser visualizado como um traço representado no espaço complexo de um vetor que está continuamente mudando de comprimento e rotação. Assumindo deste modo a forma de uma hélice em espiral que se comprime e se expande ao longo do eixo do tempo como mostra a figura 1. O conceito de

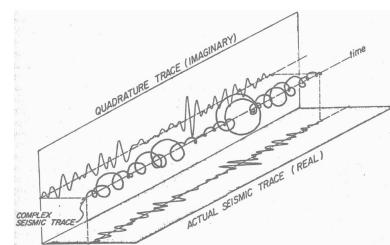


Figura 1: Representação de parte de um traço sísmico complexo em um diagrama isométrico (Taner, 1979).

traço complexo nos permite definir amplitude ou envelope, fase, freqüência instantâneas e polaridade. Estas quantidades também denominadas de “atributos” caracterizam o traço complexo e podem ser *plotadas* de forma semelhante àquelas usadas para *plotar* os traços sísmicos convencionais.

¹PETROBRAS -UN-ES/ATEX/PS

²PETROBRAS -UN-BC/ATEX/PS

³CPGG-UFBA

Filtro Wiener-Levinson complexo

Usualmente o traço sísmico convencional tem sido deconvolvido por filtros reais Wiener-Levinson preditivos. Estes filtros são obtidos pelo método dos mínimos quadrados através da solução de sistemas de equações normais, cuja matriz associada é Toeplitz e simétrica. No caso particular do filtro Wiener complexo de predição unitária, a matriz passa a ser Toeplitz e hermitiana (Treitel, 1974).

O erro de predição do traço complexo será:

$$e_t = x_t - \tilde{x}_t = x_t - \sum_{j=1}^N x_{t-j} \tilde{a}_j$$

Na forma de matriz,

$$\begin{bmatrix} e_0 \\ e_1 \\ \vdots \\ e_M \\ e_{M+1} \\ e_{M+N} \end{bmatrix} = \begin{bmatrix} x_0 & 0 & \dots & 0 \\ x_1 & x_0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & x_M & \ddots & \vdots \\ 0 & 0 & x_M & x_{M-1} \\ 0 & 0 & 0 & x_M \end{bmatrix} \begin{bmatrix} 1 \\ -\tilde{a}_1 \\ \vdots \\ -\tilde{a}_N \end{bmatrix} \quad (1)$$

Ou de forma mais simplificada,

$$\mathbf{e} = [\mathbf{X}_{N+1}] \begin{bmatrix} 1 \\ \mathbf{a}_N \end{bmatrix} \quad (2)$$

$$(1 \quad \mathbf{a}_N^T) = (1, -\tilde{a}_1, \dots, -\tilde{a}_N)$$

Minimizando a forma quadrática, $Q(\tilde{\mathbf{a}}) = \mathbf{e}^H \mathbf{e}$, obtém-se as equações normais:

$$[\mathbf{X}_{N+1}^H \mathbf{X}_{N+1}] \begin{bmatrix} 1 \\ \mathbf{a}_N \end{bmatrix} = \begin{bmatrix} \min(\mathbf{e}^H \mathbf{e}) \\ \mathbf{0} \end{bmatrix} \quad (3)$$

$$\mathbf{X}_{N+1}^H \mathbf{X}_{N+1} = \begin{bmatrix} r_0 & r_1^* & \dots & r_N^* \\ r_1 & r_0 & \dots & r_1^* \\ \vdots & \vdots & \ddots & \vdots \\ r_N & r_{N-1} & \dots & r_0 \end{bmatrix}. \quad (4)$$

$(^H)$ representa transposto e conjugado dos elementos do vetor \mathbf{e} e $(^*)$ o conjugado do número complexo. O filtro de Wiener-Levinson complexo, $(1 \quad \mathbf{a}_N^T)$, pode ser obtido através da Recursão de Levinson complexa e, assim como o traço complexo, assume uma forma de hélice em espiral.

Deconvolução do traço complexo

O dado marítimo da Noruega utilizado para geração do traço complexo e realização dos testes de deconvolução, foi organizado em coleções de traços com ponto médio comum (CMP) onde aplicou-se uma correção de divergência esférica. Os testes de deconvolução, restritos a 164 CMPs e ao intervalo de tempo de 1.0 a 3.0 seg do dado original, consistiram basicamente de comparações de coleções de CMP e seções empilhadas do

dado original e de suas versões com as deconvoluções de fase mínima real e complexa.

A deconvolução de fase mínima real foi feita da maneira tradicional, através da aplicação de um filtro de Wiener real de predição unitária nos dados originais no domínio $x - t$. Na deconvolução complexa, os operadores preditivos de erro foram gerados a partir dos traços complexos. Os filtros complexos foram então aplicados aos traços complexos os quais serviram de base para o cálculo e consequente representação das componentes real e imaginária e dos atributos: envelope e fase.

Embora o dado da Noruega, registrado em lâmina d'água profunda (1.5 seg), apresente uma razoável resolução temporal, são significativos os incrementos da resolução temporal adquiridos com as deconvoluções de Wiener-Levinson real e complexa. Conforme pode ser observado nas figuras 2, 3, 4 e 5 que são apresentadas a seguir, a deconvolução complexa mostrou um significativo incremento na resolução temporal quando comparada à deconvolução convencional. Esta constatação torna-se mais evidente na seção empilhada utilizando-se o atributo de fase.

É importante ressaltar que a qualidade dos resultados poderão ser melhoradas se forem tomadas precauções nas outras fases do processamento, tais como correção da divergência esférica, interpretação das velocidades, mutes etc.

Conclusões

A deconvolução do traço complexo testada no dado da Noruega apresentou resultados interessantes. Foi possível perceber nas diversas seções de atributos sísmicos uma maior resolução temporal em comparação com o método de deconvolução convencional. Considerando que o dado original da Noruega já apresenta uma boa resolução temporal, o resultado obtido foi bastante significativo. Portanto, recomenda-se a aplicação da deconvolução do traço complexo em diferentes tipos de dados reais. Provavelmente, o método sendo testado desta maneira poderá ser melhor avaliado. Entretanto, é fundamental que os dados nos quais serão aplicada esta ou qualquer outra técnica de deconvolução, sejam préviamente tratados da melhor forma possível. Para isto é importante um adequado tratamento dos fatores de propagação, principalmente, dos efeitos distorsivos da divergência esférica e das múltiplas. Estes cuidados não só permitirão obter melhores resultados na deconvolução, como também funções velocidades de boa qualidade. Além de possibilitar uma melhor avaliação dos dados pós-empilhamento. Caso sejam comprovados resultados satisfatórios em trabalhos posteriores, restaria avaliar a relação custo-benefício do método para o seu uso na rotina do processamento.

Referências

- Bracewell R. N., 1965, *The Fourier transform and its application*, Mc Graw-Hill, New York.
 Claerbout, J., 1976, *Fundamentals of Geophysical Data Processing with Applications to Petroleum Prospecting*, Mc Graw-Hill, New York.
 Santos A. M. B., 1984, *Empilhamento horizontal para reflexões além do ângulo crítico* Dissertação de Mestrado, Universidade Federal da Bahia, Salvador, Brasil.
 Taner, M. T., 1979, *Complex seismic trace analysis*, *Geophysics*, **44** 1041-1063.
 Treitel, S., 1974, *The complex Wiener filter*, *Geophysics*, **39** 1041-1063.
 Yilmaz, O., 1987, *Seismic Data Processing*, Society of Exploration Geophysicists - SEG, Tulsa.

Agradecimentos

Adriano Lima e João Logrado agradecem à PETROBRAS a oportunidade do aprimoramento técnico-científico propiciado pela realização do Mestrado no Curso de Pós-graduação em Geofísica da UFBA.
 5

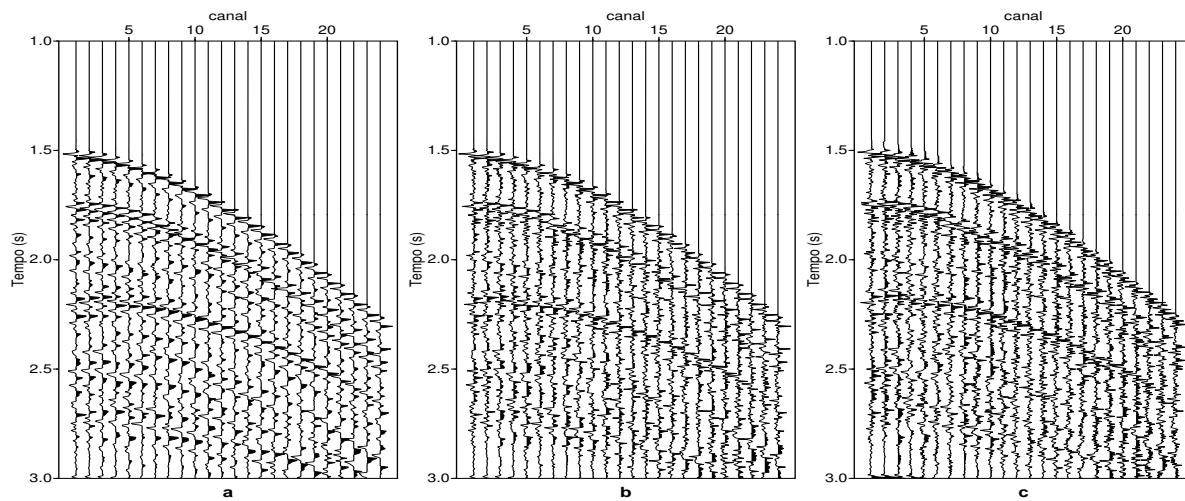


Figura 2: Famílias CMP dos dados da Noruega: sem deconvolução em (a); com deconvolução convencional em (b) e com deconvolução complexa em (c).

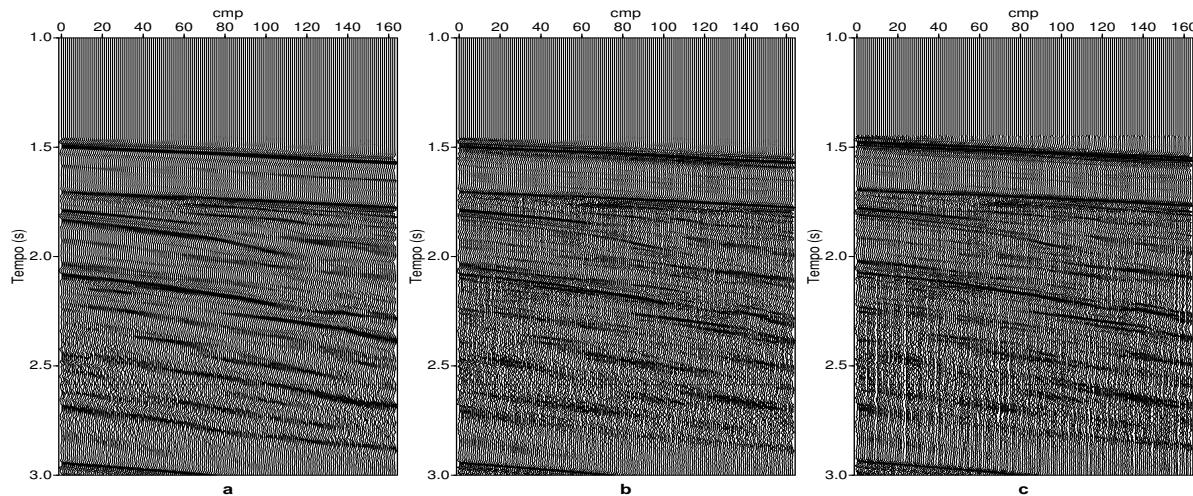


Figura 3: Seções empilhada do dado da Noruega: sem deconvolução em (a); com deconvolução convencional (b) e com deconvolução complexa em (c).

Lima, Logrado e Porsani

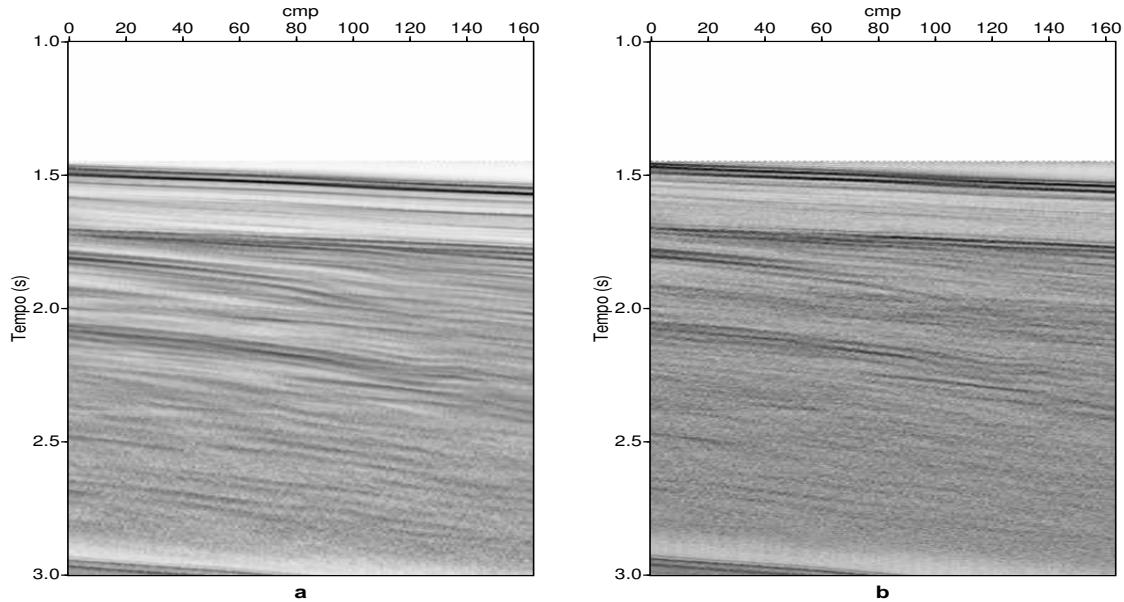


Figura 4: Seções empilhada do envelope. Sem deconvolução em (a) e com deconvolução complexa em (b).

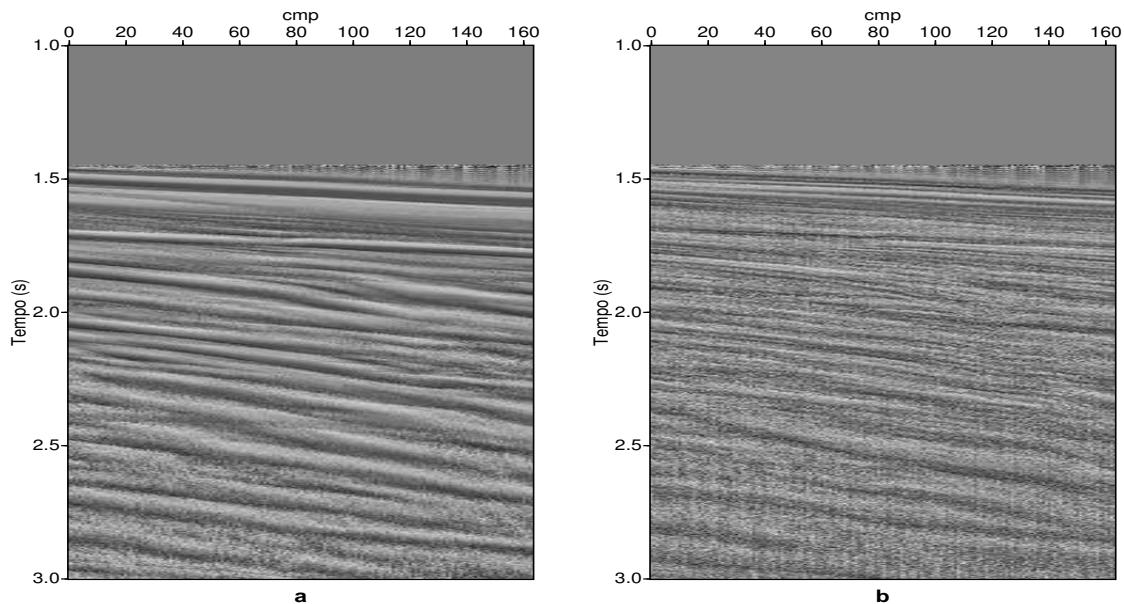


Figura 5: Seções empilhada da fase. Sem deconvolução em (a) e com deconvolução complexa em (b).



Deconvolução iterativa de dados sísmicos utilizando norma L_p

Paulo E. M. de Melo e Milton J. Porsani

CPGG/UFBA

Abstract

This paper presents a norm dependent interactive approach for wavelet deconvolution. It represents an application of the linearized inversion approach based on the L_p norm, proposed by Porsani et al, (2001), in the deconvolution problem. The algorithm is initialized by using the Wiener-Levinson filter. The prediction errors are taken to an exponent factor which is norm dependent, resulting in a non-linear relationship between the filter coefficient and its corresponding output. By using a Taylor expansion of first order, a linear system of equation may be obtained. By solving it in the least-square sense an interactive norm dependent deconvolution approach may be generated. The method was applied in the pre-stack deconvolution of marine seismic data and the results are comparatively discussed with the conventional L_2 approach.

Resumo

Neste trabalho apresentamos um método iterativo para deconvolução do pulso sísmico com base na norma L_p . O método é iniciado com o filtro de Wiener-Levinson (L_2) e corresponde a uma adaptação do método de inversão linearizada com ponderação dos desvios proposto por Porsani et al, 2001. Os erros devidos ao filtro de predição unitária são elevados a um expoente relacionado à norma em uso, definindo assim um relacionamento não linear entre os coeficientes do filtro preditivo e o resultado da deconvolução. Através da expansão de Taylor de primeira ordem obtém-se um sistema linear de equações que é ponderado pelo resultado da deconvolução ao estágio k . A norma a ser utilizada, o número de coeficientes do filtro e o número de iterações são parâmetros a serem definidos. O método foi testado na deconvolução empilhamento utilizando-se dados sísmicos reais de levantamento marítimo e os resultados são comparados e discutidos frente aqueles obtidos com a deconvolução convencional de Winer-Levinson que utiliza a norma L_2 .

Introdução

A deconvolução é uma etapa do processamento de dados por meio da qual é possível aumentar a reso-

lução temporal dos dados sísmicos através da compressão do pulso sísmico. É utilizada também para a atenuação de reflexões de múltiplas que ocorrem nos registros de reflexões sísmicas (Yilmaz, O., 1987). O sismograma registrado é o resultado da convolução de um pulso gerado perto da superfície com a função refletividade do meio, somado aos ruídos de diversas origens (movimento devido aos ventos, ruído do ambiente, etc). Assim, um sismograma de reflexão pode ser matematicamente representado pelo modelo convolucional abaixo:

$$x_t = p_t * e_t + \eta_t. \quad (1)$$

Representamos por: x_t o sismograma registrado (traço sísmico), p_t o pulso sísmico, e_t a função refletividade ou resposta impulsiva da terra, η_t o ruído aditivo e o símbolo $*$ representa a operação de convolução.

O método de deconvolução pode ser descrito em termos de filtros lineares, que são calculados com base na solução de sistemas lineares de equação.

No processo de deconvolução com o filtro de Wiener-Levinson são levados em consideração os seguintes requisitos:

- o pulso é de fase mínima e estacionário;
- a refletividade é branca, e
- a razão sinal/ruído é alta.

Filtro de Wiener-Levinson de predição unitária

O modelo autoregressivo no qual cada amostra, x_t , do traço sísmico pode ser obtida como combinação linear de valores a tempos passados, nos permite representar os erros de predição (traço deconvolvido) na forma:

$$e_t = x_t - m_1 x_{t-1} - m_2 x_{t-2} - \dots - m_N x_{t-N} \quad (2)$$

onde,

$$(1, -m_1, -m_2, \dots, -m_N) = (1 \quad -\mathbf{m}_N^T) \quad (3)$$

representa o operador preditivo de erro.

Os parâmetros (m_1, \dots, m_N) , podem ser obtidos através do método dos mínimos quadrados,

resolvendo-se o sistema linear de equações abaixo:

$$\begin{bmatrix} e_0 \\ e_1 \\ \vdots \\ e_M \\ e_{M+1} \\ e_{M+N} \end{bmatrix} = \begin{bmatrix} x_0 & 0 & \cdots & 0 \\ x_1 & x_0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & x_M & \ddots & \ddots \\ 0 & 0 & x_M & x_{M-1} \\ 0 & 0 & 0 & x_M \end{bmatrix} \begin{bmatrix} 1 \\ -m_1 \\ \vdots \\ -m_N \end{bmatrix} \quad (4)$$

ou de forma mais compacta,

$$\mathbf{e} = \mathbf{X} \begin{bmatrix} 1 \\ -\mathbf{m} \end{bmatrix}$$

Minimizando a forma quadrática, $Q(\mathbf{m}) = \sum \mathbf{e}_t^2$ obtém-se o sistema de equações normais, representado a seguir na sua forma ampliada:

$$\begin{bmatrix} r_0 & r_1 & \cdots & r_N \\ r_1 & r_0 & \cdots & r_{N-1} \\ \vdots & \vdots & \ddots & \vdots \\ r_N & r_{N-1} & \cdots & r_0 \end{bmatrix} \begin{bmatrix} 1 \\ -m_1 \\ \vdots \\ -m_N \end{bmatrix} = \begin{bmatrix} E_N \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (5)$$

onde, E_N representa a soma total dos erros quadrados minimizados.

O sistema de equações normais pode ser resolvido de forma eficiente através do algoritmo conhecido como recursão de Levinson. A matriz dos coeficientes possui estrutura Toeplitz formada por coeficientes da autocorrelação do traço sísmico. O filtro assim obtido é denominado de filtro de Wiener-Levinson.

Com as premissas de que (i) a função refletividade possa ser representada por um processo aleatório não correlacionável com o pulso sísmico, e (ii) que o ruído aditivo possa ser negligenciado, a autocorrelação do traço sísmico representará uma boa estimativa da autocorrelação do pulso que se deseja deconvolver. Com a premissa de que o polinômio associado ao pulso seja de fase mínima, então o filtro de Wiener-Levinson será seu inverso podendo, através da convolução, colapsá-lo a um impulso, deconvolvendo-o por conseguinte.

Deconvolução Iterativa com Norma L_p

Seguindo o procedimento proposto por (Porsani, et al 2001), podemos definir a função-objetivo como segue:

$$Q(\mathbf{m}, \beta) = \sum_{t=0}^M \{f(\mathbf{m}, t)^\beta\}^2 \quad (6)$$

onde,

$$f(\mathbf{m}, t)^\beta = \{e_t^2\}^\beta, t = 0, \dots, M. \quad (7)$$

Efetuando a expansão de Taylor de primeira ordem em torno do modelo \mathbf{m}_k e avaliando para valores discretos de t , obtém-se o sistema de equações associados aos erros linearizados,

$$\tilde{\mathbf{f}}_{\beta_k} = \mathbf{f}_{\beta_k} - \mathbf{F}_{\beta_k} \mathbf{X} \Delta \mathbf{m}_k, \quad (8)$$

\mathbf{F}_{β_k} é uma matriz diagonal cujos elementos na diagonal principal são dados por:

$$f_{jj} = -2\beta [e_j^2]^{\beta-1} e_j$$

O sistema linear representado pela equação (8) pode ser resolvido para $\Delta \mathbf{m}_k$ com o método dos mínimos quadrados. O filtro à iteração $k + 1$ é obtido a partir daquele à iteração k , através da equação:

$$\mathbf{m}_{k+1} = \mathbf{m}_k + \Delta \mathbf{m}_k. \quad (9)$$

Aplicação a dados reais

O método foi aplicado: em um traço sísmico como mostra a figura 1, em um CMP com 24 traços como mostra a figura 2 e antes do empilhamento em toda seção sísmica da Noruega como mostra a figura 3. A deconvolução foi feita com 20 coeficientes, luz branca 1.01 e 10 iterações.

Para a aplicação do método de deconvolução com norma L_p em toda a linha da Noruega foram estabelecidos os seguintes passos:

- Deconvolver traço a traço toda a linha da Noruega com as seguintes normas L_1 e L_2 ;
- Aplicar a correção de NMO;
- Empilhar a seção original e as demais seções deconvolvidas.

Conclusões

Apresentamos um procedimento iterativo para deconvolução do pulso sísmico como função da norma L_p . O método foi aplicado na deconvolução pré-empilhamento de dados sísmicos reais utilizando-se a norma L_1 . Os resultados da deconvolução das famílias CMP's, quanto da seção empilhada exibem uma melhor compressão do pulso sísmico, traduzida pela melhor definição e continuidade lateral das reflexões, comparado àqueles obtidos com a deconvolução de Wiener-Levinson baseada na norma L_2 .

Agradecimentos

P. E. M. Melo agradece à ANP pelo apoio na forma de Bolsa de Estudo e ao Centro de Pesquisa em Geofísica e Geologia (CPGG-UFBA) pelo apoio a este trabalho.

Referências

Yilmaz, O., 1988, Seismic Data Processing, Society of Exploration Geophysics -SEG, v. 2, 526 p.

Carvalho, A. L., 1990, Deconvolução L_1 e aplicações ao processamento sísmico : Master thesis, Univ. Federal da Bahia.

Porsani, M. J., Niwas, S., and Ferreira, N. R., 2001, Robust inversion of vertical electrical sounding data using a multiple reweighted least-square method : Geophysical Prospecting, 49, v.2, 255-264.

Robinson, E. A., 1967, Predictive decomposition of time series with applications to seismic exploration: Geophysical, 32, 418-484.

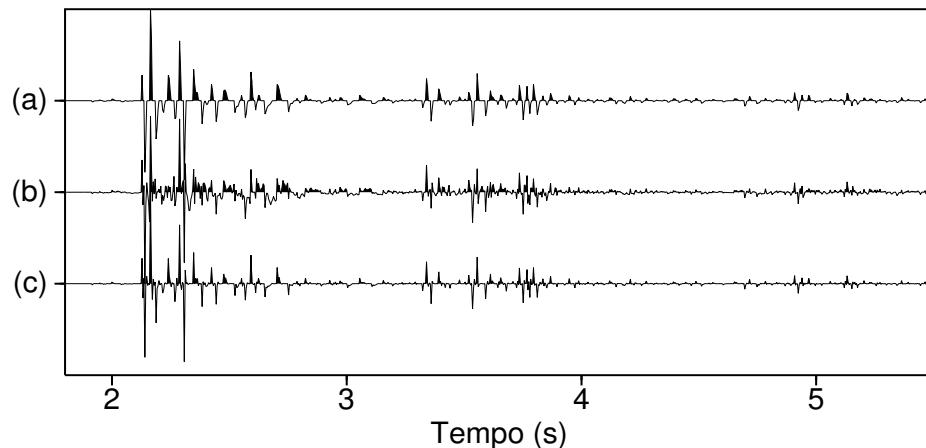


Figura 1: Traço original em (a), traço deconvolvido com norma L_2 em (b) e traço deconvolvido com norma L_1 em (c).

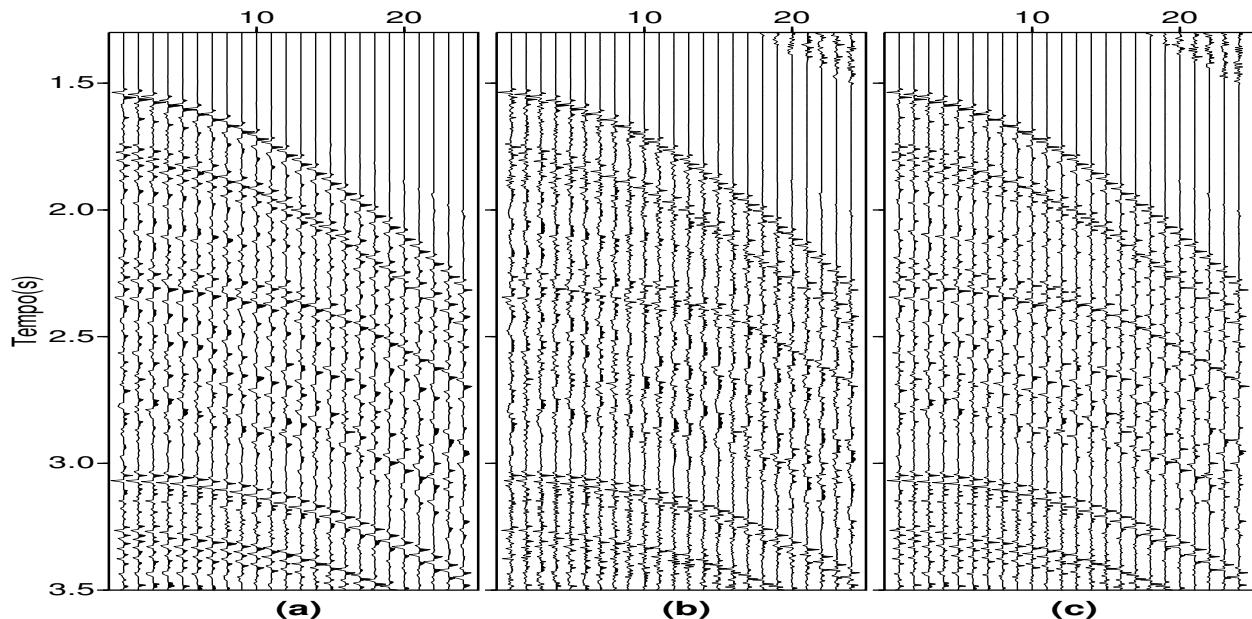


Figura 2: CMP original em (a), CMP deconvolvido com norma L_2 em (b) e CMP deconvolvido com norma L_1 em (c).

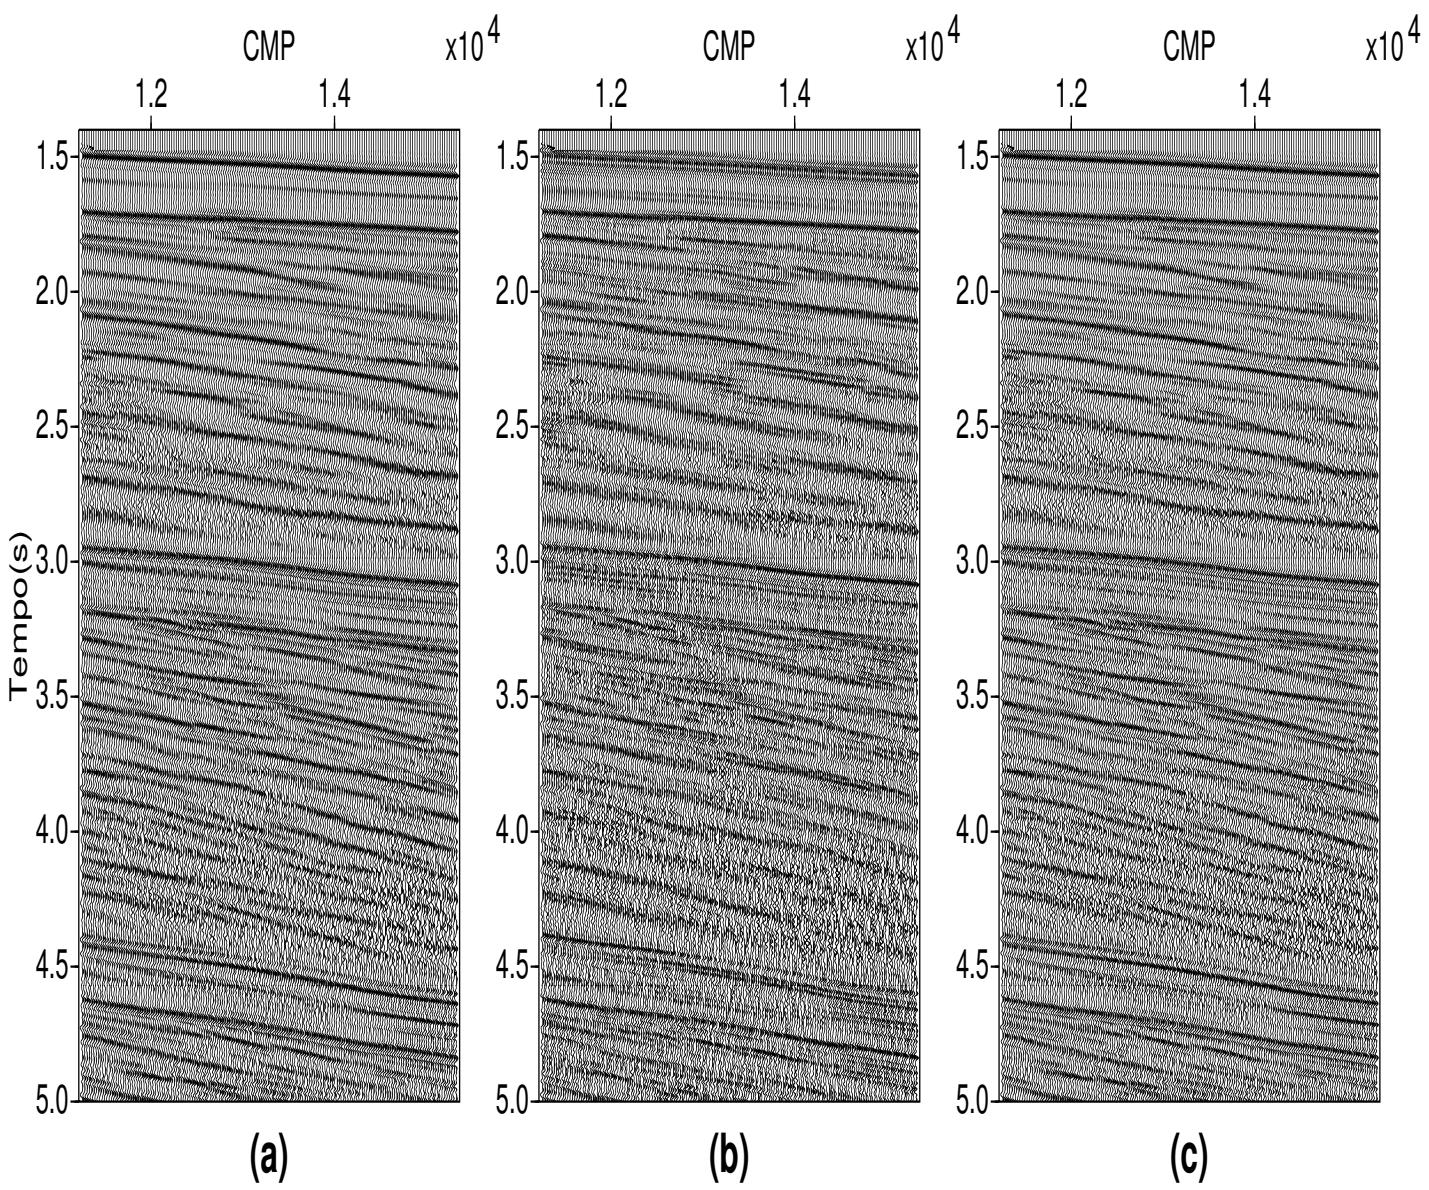


Figura 3: Seção empilhada original em (a), seção empilhada após deconvolução com filtro de Wiener-Levinson (norma L_2) em (b) e seção empilhada após deconvolução iterativa utilizando a norma L_1 em (c).



Empilhamento Sísmico de Superfícies de Reflexão Comum com Mergulhos Conflitantes

Garabito, G.*; Cruz, J. C. R.*; Hubral, P.#; Costa, J.*

*german.jcarlos.jesse@ufspa.br; #Peter.Hubral@gpi.uni-karlsruhe.de

Abstract

In the recent years, based on hyperbolic traveltime paraxial approximation, it was introduced the Common Reflection Surface (CRS) Stack method to simulate a zero offset section from multi-coverage seismic data. For two-dimensional medium, the traveltime depends on three kinematic attributes related to wavefronts of hypothetical waves at the emergence point of the normal incidence central ray. These three parameters can be determined by means of optimization process applied to a coherency analysis of the seismic events. In this work, based on a global optimization to search for the three stacking parameters, we propose an extension of this algorithm to simulate correctly the conflicting dip events. This new methodology is successful applied to synthetic examples.

Introduction

Mueller (1999) propôs um novo método de simulação de seções com afastamento fonte-receptor nulo, denominado empilhamento de superfícies de reflexão comum (*common reflection surface (CRS) stack*). Esta técnica de simulação está baseada na somatória de eventos sísmicos de dados de cobertura múltipla, ao longo de superfícies de empilhamento, produzindo como resultado uma seção simulada com uma alta razão sinal-ruído e uma boa resolução da imagem dos refletores. Como produto adicional do empilhamento CRS obtém-se atributos de ondas hipotéticas, e que podem ser usados em outras etapas do processamento sísmico.

O cálculo da superfície ou operador do empilhamento CRS é realizado usando a fórmula de aproximação hiperbólica do tempo de trânsito do raio paraxial (Tygel et al., 1997). Em meios bidimensionais, o operador do empilhamento é dependente de três parâmetros que estão associados a duas ondas hipotéticas, conhecidas como onda do ponto de incidência normal (onda NIP) e onda normal (onda N), definidas em Hubral (1983). Estes três parâmetros são: 1) O ângulo de emergência do raio de reflexão normal com relação a normal a superfície; 2) o raio de curvatura da onda NIP; e 3) o raio de curvatura da onda N. Portanto, a aplicação do empilhamento CRS requer a determinação, a partir dos dados sísmicos, do grupo ou dos grupos de três parâmetros associados a cada ponto de amostragem da seção de afastamento nulo a ser simulada. Em outras palavras, um ponto da seção de afastamento nulo pode estar formado por um único evento sísmico, mas em alguns casos pode estar

formado pela contribuição de diferentes eventos sísmicos que se interceptam.

Recentemente, em Garabito et al., (2001) foi apresentado uma nova estratégia para a determinação dos três parâmetros do operador de empilhamento CRS, baseado na aplicação de um algoritmo de otimização global para a estimar inicialmente dois parâmetros e posteriormente um parâmetro, sendo que na última etapa os três parâmetros estimados são otimizados para determinar os seus melhores valores por meio de um algoritmo de otimização local. O presente trabalho faz uso deste algoritmo de determinação dos parâmetros de empilhamento para resolver o problema dos mergulhos conflitantes freqüentemente observados nos dados sísmicos.

Empilhamento CRS

No método de empilhamento CRS para o cálculo das superfícies de empilhamento é usada a formula de aproximação hiperbólica de segunda ordem dos tempos de trânsito dos raios na vizinhança (raios paraxiais) a um raio central com afastamento fonte-receptor nulo (Tygel et al., 1997). Em meios 2D, assumindo conhecida a velocidade próxima a superfície, esta formula é expressa em função de três parâmetros independentes medidos no ponto de emergência do raio central: 1) O ângulo de emergência do raio central com respeito da normal à superfície (β_0), 2) o raio de curvatura da onda NIP (R_{NIP}) e 3) o raio de curvatura da onda N (R_N). A onda NIP é uma onda fictícia que se propaga em forma ascendente a partir de uma fonte localizada no ponto de incidência normal do raio central sobre um dado refletor, e a onda N que também se propaga em forma ascendente é uma onda fictícia que explode sobre o refletor com a curvatura local do refletor no ponto de incidência normal. A fórmula da aproximação hiperbólica, aplicável em geometrias de fontes e receptores irregulares, é expressa como:

$$t^2(x_m, h) = \left(t_0 + \frac{2\sin\beta_0}{v_0} (x_m - x_0) \right)^2 + \frac{2t_0 \cos^2 \beta_0}{v_0} \left(\frac{(x_m - x_0)^2}{R_N} + \frac{h^2}{R_{NIP}} \right) \quad (1)$$

sendo t_0 o tempo duplo de afastamento fonte-receptor nulo, v_0 a velocidade próxima a superfície, x_m e h são as coordenadas do ponto médio e do afastamento médio entre a fonte e o receptor, respectivamente, e x_0 é a coordenada do ponto de

Empilhamento Sísmico de Superfícies de Reflexão Comum

emergência do raio central com afastamento fonte-receptor nulo. A coordenada (x_0, t_0) representa um ponto de amostragem da seção de afastamento nulo a ser simulada.

Então, para a um dado ponto de amostragem $P_0 = (x_0, t_0)$ da seção de afastamento nulo, usando a formula (1) deve ser calculada a melhor superfície ou operador de empilhamento CRS correspondente ao trio de parâmetros (β_0, R_{NIP} e R_N) mais ótimos.

O problema fundamental do empilhamento CRS se restringe à determinação do máximo global e dos possíveis máximos locais significativos de uma medida de coerência (função-objeto) definida num espaço de busca tridimensional. Em Garabito et al., (2001) a estratégia de busca destes parâmetros usando um algoritmo de otimização global foi dividida em duas etapas: Na primeira etapa são determinados dois parâmetros (β_0 e R_{NIP}), e na segunda etapa, usando os resultados da etapa inicial, é determinado o terceiro parâmetro (R_N). Para aplicar esta estratégia de busca dos parâmetros do operador de empilhamento CRS, a expressão (1) pode ser rescrita aplicando as seguintes condições.

No caso particular em que $R_{NIP} = R_N$, implica que os dois raios de curvatura passam a definir a posição de um ponto difrator em subsuperfície, ou seja o elemento refletor colapsa num ponto difrator e neste caso R_N não proporciona mais a informação sobre a forma local do refletor. Aplicando esta condição em (1) obtém-se

$$t^2(x_m, h) = \left(t_0 + \frac{2\sin\beta_0}{v_0} (x_m - x_0) \right)^2 + \frac{2t_0 \cos^2 \beta_0}{v_0 R_{NIP}} ((x_m - x_0)^2 + h^2) \quad (2)$$

tornando-se assim dependente de dois parâmetros (β_0 e R_{NIP}). Neste caso, o operador de empilhamento CRS definido pela expressão (2) está associado a um difrator em subsuperfície. As expressões dos tempos de trânsito para a configuração de afastamento comum coincidem com as formulas (1) e (2), mas sob a consideração de $h=\text{constante}$. Aplicando a condição de $h = 0$ na expressão (1), obtém-se a aproximação hiperbólica para a configuração de afastamento nulo, dada por:

$$t^2(x_m, h) = \left(t_0 + \frac{2\sin\beta_0}{v_0} (x_m - x_0) \right)^2 + \frac{2t_0 \cos^2 \beta_0 (x_m - x_0)^2}{R_N} \quad (3)$$

obtendo-se assim uma expressão dependente dos parâmetros β_0 e R_N .

Algoritmo do empilhamento CRS

A determinação dos três parâmetros (β_0, R_{NIP}, R_N) que definem o operador de empilhamento CRS, pode ser formulado como um problema de maximização da medida de coerência *semblance* (função-objeto) com valores dentro de uma região do espaço dos parâmetros, delimitado pelos seguintes intervalos: $-\pi/2 < \beta_0 < \pi/2$ e $-\infty < R_{NIP}, R_N < +\infty$. Descrição do Algoritmo: **Etapa 1** - Para cada ponto de amostragem P_0 da seção de afastamento nulo a ser simulada, são determinados os parâmetros β_0 e R_{NIP} por meio do algoritmo *Simulated Annealing* (SA). A medida de coerência *semblance* é realizada ao longo do operador de empilhamento definido pela expressão (2), nas diferentes configurações de afastamento comum dos dados de cobertura múltipla. **Etapa 2** - Também para cada ponto de amostragem P_0 e usando o valor do parâmetro β_0 já conhecido, é determinado R_N por meio do algoritmo de otimização SA. A busca global é realizada na seção de afastamento nulo resultante da Etapa 1, onde a medida de coerência *semblance* é realizada ao longo das trajetórias de empilhamento definidas pela expressão (3). **Etapa 3** – Tomando como soluções iniciais os valores dos parâmetros das anteriores etapas, é aplicação do algoritmo de otimização local *Variable Metric* (VM) para a determinação dos parâmetros mais ótimos a serem usados para produzir a seção de afastamento nulo simulada pelo processo de empilhamento CRS. Nesta etapa, é usado a formula (1) para o cálculo do operador do empilhamento CRS, também definido ao longo das seções de afastamento comum.

Note que neste algoritmo é determinado apenas um trio de parâmetros (β_0, R_{NIP}, R_N) associados a cada um dos pontos de amostragem P_0 da seção de afastamento nulo. Mas devido ao fato de que alguns eventos da seção de afastamento nulo podem estar compostos pela contribuição de diferentes eventos que se interceptam, é necessário considerar mais de um trio de parâmetros para simular corretamente tais eventos.

Para a incluir a reconstrução de eventos com mergulhos conflitantes na estratégia de empilhamento CRS proposto em Garabito et al., (2001), o algoritmo de otimização global (SA) aplicado na Etapa I foi modificado para buscar ou mapear mais de uma dupla de parâmetros ótimos. Na primeira etapa deste algoritmo, além do máximo global que é determinado

Empilhamento Sísmico de Superfícies de Reflexão Comum

para cada ponto de amostragem da seção de afastamento nulo, também são determinados uma dupla de parâmetros correspondentes ao máximo local mais significativo (β_0^i e R_{NIP}^i). Na segunda etapa, para cada um dos ângulos detectados na etapa anterior, são determinados também por otimização global os correspondentes valores do terceiro parâmetro (R_N^i). Na terceira etapa, também para cada trio determinado nas etapas anteriores é aplicado a otimização local e paralelamente o empilhamento CRS. Note que nos pontos de amostragem onde não se tem intercessão de eventos teremos apenas um trio de parâmetros ótimos.

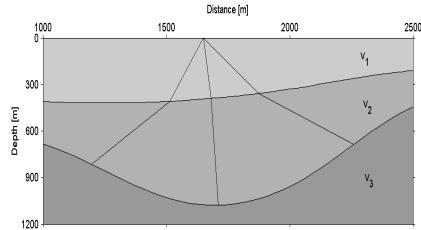


Figura 1. Modelo sintético composto por três camadas.

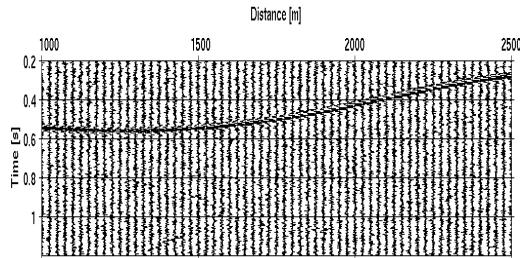


Figura 2. Seção de afastamento nulo modelado, com reflexões primárias e com adição de ruído aleatório.

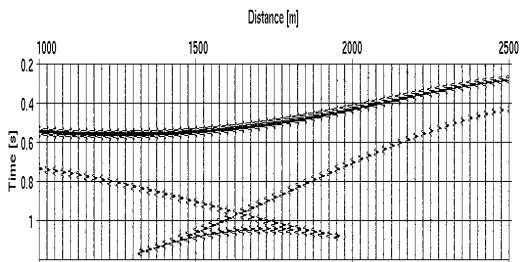


Figura 3. Seção de afastamento nulo, simulada pelo empilhamento CRS.

Exemplo sintético

Este novo algoritmo de simulação de seções com afastamento nulo pelo método de empilhamento CRS, foi aplicado nos dados sintéticos gerados por meio de um algoritmo de traçamento de raios a partir do modelo mostrado na Figura 1, cujas velocidades da

primeira à terceira camadas são: 1500 m/s, 2600 m/s e 3600 m/s. Os dados gerados consistem de 101 seções de fonte comum, cada uma com 48 geofones e com um intervalo de separação entre tiros consecutivos e entre receptores de 25 m. O afastamento mínimo entre uma fonte e o primeiro receptor é de 100 m. O sinal da fonte é o wavelet Gabor com uma freqüência dominante de 40 Hz e intervalo de amostragem de 2 ms. Nestes dados foi adicionado ruído aleatório com distribuição uniforme e uma razão sinal-ruído igual a 5. Como exemplo de estes dados, na Figura 2 mostra-se a seção de afastamento nulo modelada, com adição do mesmo tipo de ruído que os dados.

Na Figura 3 mostra-se a seção de afastamento nulo simulada pelo algoritmo de empilhamento CRS proposto neste trabalho. Devido ao grande numero de traços envolvidos no processo de empilhamento, esta seção simulada tem uma alta razão sinal-ruído e apresenta melhor definição do segundo evento de reflexão, comparado com o mesmo evento da seção de afastamento nulo modelada (Figura 2). Como resultados adicionais foram obtidas a seções de coerência e dos parâmetros β_0 , R_{NIP} e R_N , que não são mostrados no presente trabalho. Para comparação, na Figura 4 mostram-se as seções de afastamento nulo amplificadas na região onde se tem a interseção dos eventos da caustica. A Figura 4a corresponde ao obtido por modelamento direto, mas sem adição de ruído aleatório. A Figura 4b é o resultado do empilhamento CRS considerando apenas um trio de parâmetros para cada ponto de amostragem da seção simulada, e a Figura 4c foi extraída da Figura 3 que foi simulado considerando os dois trios de parâmetros associados à região de caustica. Observa-se que esta ultima seção mostra uma melhor reconstrução zona onde se tem a contribuição dos eventos que se interseparam.

Conclusões e recomendações

Com o propósito de realizar o empilhamento correto dos eventos com mergulhos conflitantes, na primeira etapa do algoritmo de empilhamento CRS proposto em Garabito, et al., (2001), sem nenhum custo adicional no custo computacional desta etapa foi modificado o algoritmo de otimização global para o mapeamento dos máximos com valores de coerências maiores a um dado valor de referência.

Além da melhora significativa na reconstrução da imagem dos pontos da seção onde ocorre a interseção dos eventos, são também obtidos um trio de parâmetros associados a cada um dos eventos. Esta determinação adicional de parâmetros favorece as posteriores aplicações destes parâmetros, como a determinação do modelo de velocidades, correção de amplitudes e outros.

Empilhamento Sísmico de Superfícies de Reflexão Comum

Agradecimentos

Agradecemos à Agencia Nacional do Petróleo pelo suporte econômico ao primeiro autor deste trabalho. Também agradecemos ao Prof. João Batista Correa da Silva pela valiosa contribuição na aplicação dos métodos de otimização.

Referências

- Birgin, E., G., Biloti, R., Tygel, M., and Santos T., L., 1999, Restricted optimization: a clue to a fast and accurate implementation of the Common Reflection Surface Stack method. *J. Appl. Geoph.*
- Garabito, G., Cruz, J., C., Hubral, P., and Costa, J., 2001, Common Reflection Surface Stack: A new parameter search strategy by global optimization. Submitted to Annual Internat. Mtg., Soc. Expl. Geophys.
- Hubral, P., 1983, computing true amplitude reflections in a laterally inhomogeneous earth: *Geophysics*, 48, no. 8, 1051-1062.
- Mann, J., Traub, B., and Hubral, P., 2000, Common Reflection-Surface Stack and Conflicting Dips. 70th Annual Internat. Mtg., Soc. Expl. Geophys., Expanded Abstracts.
- Mueller, T., 1999, The Common Reflection Surface Stack Method – Seismic imaging without explicit knowledge of the velocity model, Ph.D. thesis, Karlsruhe University.
- Tygel, M., Mueller, T., Hubral, P., and Schleicher, J., 1997, Eigenwave based multiparameter travelttime expansions: 67th Annual Internat. Mtg., Soc. Expl. Geophys., Expanded Abstracts, 1770-1773.

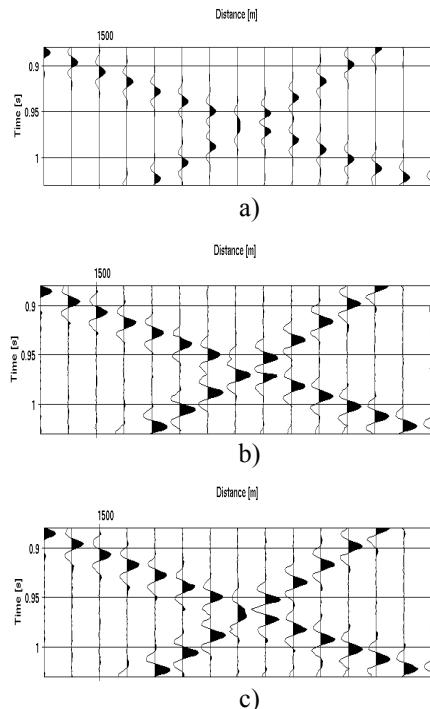


Figura 4. Seções de afastamento nulo, amplificadas na zona de interseção de eventos correspondentes à caustica. a) Seção modelada e sem ruído, b) Seção simulada sem considerar os eventos com mergulhos conflitantes, e c) seção simulada considerando os eventos com mergulhos conflitantes.



From eigenfaces to eigensections

Sam T. Kaplan[†] and Tadeusz J. Ulrych[†]

Abstract

We take the application of the singular value decomposition (*SVD*) to processing two dimensional seismic data (Freire and Ulrych (1988)), and extend it to process three dimensional seismic data. Inspired by the *eigenface* method, we develop an analogous technique for analyzing prestack seismic data. In particular, we investigate noise suppression in the prestack seismic domain using a seismic analogy to eigenfaces which we call eigensections.

Introduction

Consider a hypothetical sub-surface consisting of perfectly flat impedance boundaries. A seismic survey is performed, where the receiver spacing is kept perfectly constant. From such a survey, seismic traces could, of course, be gathered into common midpoint sections (CMP's), each of which would contain the exact same signal, but different realizations of random noise. In such a situation, a clever processing step resulting in an increased signal to noise ratio in the prestack domain would be to simply stack the CMP gathers, thus preserving the consistent signal, while attenuating the unwanted random noise. However, the point of performing the seismic survey in the first place is to find the nature of the sub-surface. We cannot just add together the CMP gathers with the hope of reducing the noise in the prestack domain without first knowing something about the geometry of the sub-surface. Doing so would, of course, attenuate random noise, but more importantly, doing so would destroy signal.

In this paper we show how to increase the signal to noise ratio in the prestack domain while respecting lateral variations in the sub-surface. Our method relies on the use of, what we call, eigensections, and is inspired by eigenfaces. As such, a discussion of eigensections deserves an introduction by way of a brief discussion of eigenfaces. After introducing these ideas, a real seismic data example will be shown.

[†]Department of Earth and Ocean Sciences, The University of British Columbia, 6339 Stores Road, Vancouver, BC, V6T 1Z4, Canada.



Figure 1: fifteen photographs

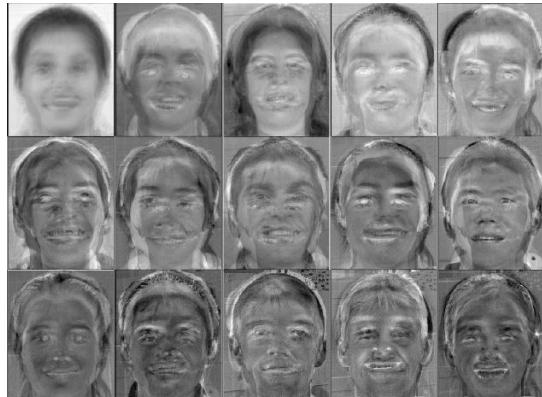


Figure 2: fifteen eigenfaces

Eigenfaces

The eigenface technique (Pentland and Turk (1991); Kirby and Sirovich (1987)) takes a set of photographs and maps them into another set of images (eigenfaces) by way of the singular value decomposition (*SVD*). As an example, consider Figures 1 and 2. Figure 1 shows fifteen photographs which are mapped into the set of eigenfaces shown in Figure 2.

The fifteen eigenfaces are mutually orthogonal and form a sub-space that spans the original photographs. Analyzing the projection of one of the photographs onto the eigenfaces allows for the design of face recognition and detection algorithms. However, it is the images themselves that we are concerned with in this paper. Namely, how these images represent the information contained in the

photographs.

From Faces to Sections

Obviously, just like the photographs in Figure 2, seismic data are images. We apply the eigenface technique to seismic sections and say that these seismic sections map to eigensections which are analogous to the eigenfaces shown in Figure 2.

Singular Value Decomposition

The *SVD* takes a two dimensional matrix, \mathbf{A} , and expands it into a product of three matrices,

$$\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^T. \quad (1)$$

\mathbf{A} is expanded into the product of the matrices \mathbf{U} , Σ , and \mathbf{V} where the columns of \mathbf{U} are the eigenvectors of the matrix $\mathbf{A}\mathbf{A}^T$, the columns of \mathbf{V} are the eigenvectors of the matrix $\mathbf{A}^T\mathbf{A}$, and the diagonal of Σ contains the square roots of the eigenvalues of both $\mathbf{A}\mathbf{A}^T$ and $\mathbf{A}^T\mathbf{A}$, which are called the singular values (σ_i) of \mathbf{A} .

In addition to decomposing \mathbf{A} into three matrices, the *SVD* can be represented as a decomposition of \mathbf{A} into the sum of many matrices.

$$\mathbf{A} = \sum_i \sigma_i \mathbf{u}_i \mathbf{v}_i^T \quad (2)$$

Here, \mathbf{u}_i are the eigenvectors of $\mathbf{A}\mathbf{A}^T$ and \mathbf{v}_i are the eigenvectors of $\mathbf{A}^T\mathbf{A}$. The matrices formed by the outer product, $\mathbf{u}_i \mathbf{v}_i^T$ are called eigenimages (\mathbf{E}_i).

$$\mathbf{E}_i = \mathbf{u}_i \mathbf{v}_i^T \quad (3)$$

The eigenimages can be thought of as the elements of the decomposition. It is these elements, when added together with appropriate weights (the singular values) that give \mathbf{A} . The singular values indicate how important each eigenimage is in the reconstruction of \mathbf{A} (an idea that will be used later in this paper). The thing that makes these eigenimages significant is that when the first k eigenimages are used to approximate \mathbf{A} , they give a matrix \mathbf{A}_k of rank k which is the closest possible approximation to \mathbf{A} for a rank k matrix (Golub and Van Loan (1996)). This means that, depending on its rank, \mathbf{A} can be approximated with a small number of eigenimages.

Also, note that the columns of \mathbf{E}_i are parallel. In fact the columns of \mathbf{E}_i are scalar multiples of \mathbf{u}_i .

A fact which is easily seen by examining equation (3) in its matrix form,

$$\mathbf{E}_i = \begin{bmatrix} u_{i1} \\ u_{i2} \\ \vdots \\ u_{im} \end{bmatrix} \begin{bmatrix} v_{i1} & v_{i2} & \cdots & v_{in} \end{bmatrix} \quad (4)$$

$$= [v_{i1}\mathbf{u}_i \mid v_{i2}\mathbf{u}_i \mid \cdots \mid v_{in}\mathbf{u}_i] \quad (5)$$

Thus, we see that the structural information of \mathbf{E}_i can be expressed using only the vectors \mathbf{u}_i .

SVD In Three Dimensions

So far, we have developed the ideas of the *SVD* in two dimensions. We have seen a two dimensional matrix expanded into a sum of two dimensional eigenimages. However, the purpose of this paper is to show how to filter multiple seismic sections and as a result three dimensional data must be considered where the size of the third dimension is given by p , the number of seismic sections. The way to perform the *SVD* in three dimensions is to manipulate the three dimensional data, turning the three dimensional problem into a two dimensional one, allowing one to use the *SVD* described in the previous section.

Each seismic section is changed from a matrix of two dimensions to a vector of one dimension. This transformation is achieved simply by taking each column of \mathbf{A} and placing it below its previous column, thus stringing \mathbf{A} out into a long one dimensional vector. This is done for p seismic sections giving p vectors ($\mathbf{A}'_1, \mathbf{A}'_2, \dots, \mathbf{A}'_p$) each of length mn . Now, one can create a new matrix (\mathbf{B}),

$$\mathbf{B} = [\mathbf{A}'_1 \mid \mathbf{A}'_2 \mid \cdots \mid \mathbf{A}'_p], \quad (6)$$

which is two dimensional and can be suitably decomposed.

Eigensections

The eigensections are computed by taking the *SVD* of \mathbf{B} ,

$$\mathbf{B} = \mathbf{U}\Sigma\mathbf{V}^T, \quad (7)$$

where,

$$\mathbf{U} = [\mathbf{u}_1 \mid \mathbf{u}_2 \mid \cdots \mid \mathbf{u}_p]. \quad (8)$$

Here, we call the vectors, \mathbf{u}_i the eigensections of the original three dimensional seismic data. Remember

that these eigensections contain all of the structural information required for the re-composition of \mathbf{B} . In order to use the eigensections for the re-composition of \mathbf{B} , it is important to take a step back and point out some basic mathematical facts. First, the vectors \mathbf{u}_i are the eigenvectors of the matrix \mathbf{BB}^T , and thus the vectors \mathbf{u}_i are the eigenvectors of a symmetric matrix. Furthermore, recall that if eigenvectors are recovered from a symmetric $p \times p$ matrix, then there will always be p mutually orthonormal eigenvectors that span a p dimensional subspace. Therefore, we can see that the eigensections must be a set of orthonormal vectors that span a given subspace. Subsequently, it becomes trivial to project new vectors onto this subspace.

If one takes a column of \mathbf{B} ...a seismic section, then this section, \mathbf{A}'_i , can easily be projected onto the subspace spanned by the eigensections. This projection maps the vector representation of the section, \mathbf{A}'_i , to a new vector of dimension p via the following relation,

$$c_{ij} = \mathbf{u}_j^T \mathbf{A}'_i. \quad (9)$$

We get a new set of coordinates, \mathbf{c}_i , for each seismic section, and therefore the seismic sections can be reconstructed by applying these coordinates to the basis of eigensections from which they were computed.

Now, instead of projecting the sections onto all p eigensections, we can project the sections onto the first $k < p$ eigensections. The projection, \mathbf{B}_k , of the columns of \mathbf{B} onto the first k eigensections means that \mathbf{B}_k will be a matrix of rank k . Thus, by eliminating the last $p - k$ eigensections from the projection, \mathbf{B}_k is the approximation to \mathbf{B} with the most incoherent information between the columns of \mathbf{B} (the seismic sections) removed. This idea is used in the next section to filter incoherent information from CMP gathers.

An Example

Figure 3 shows the nine CMP's that will be considered in this example, each CMP consists of twenty traces. For dramatic effect we have added Gaussian random noise to the data.

As already mentioned, we want to increase the signal to noise ratio of these data in the prestack domain without making assumptions about the consistency of the sub-surface. The eigensection technique allows us to do exactly this.

Figure 4 plots the eigensections computed from the data of Figure 3, and scaled by the appropriate singular value, each of which measures the

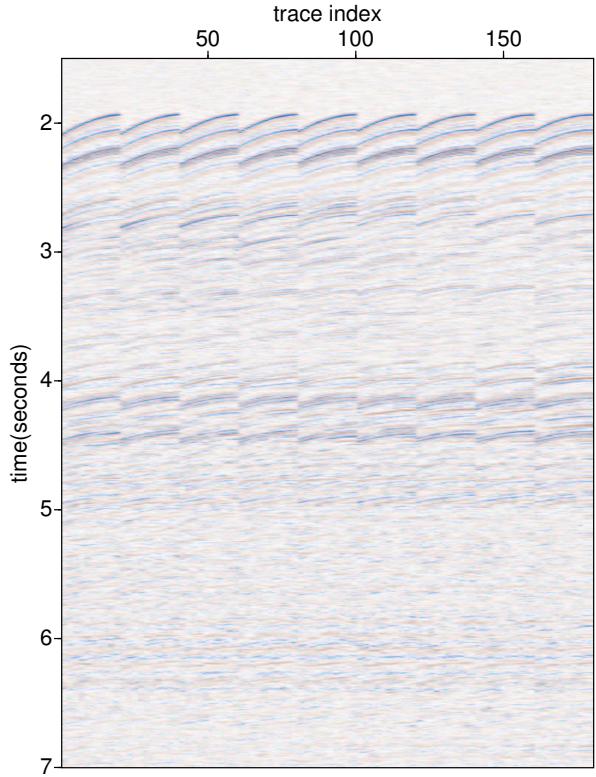


Figure 3: CMP's

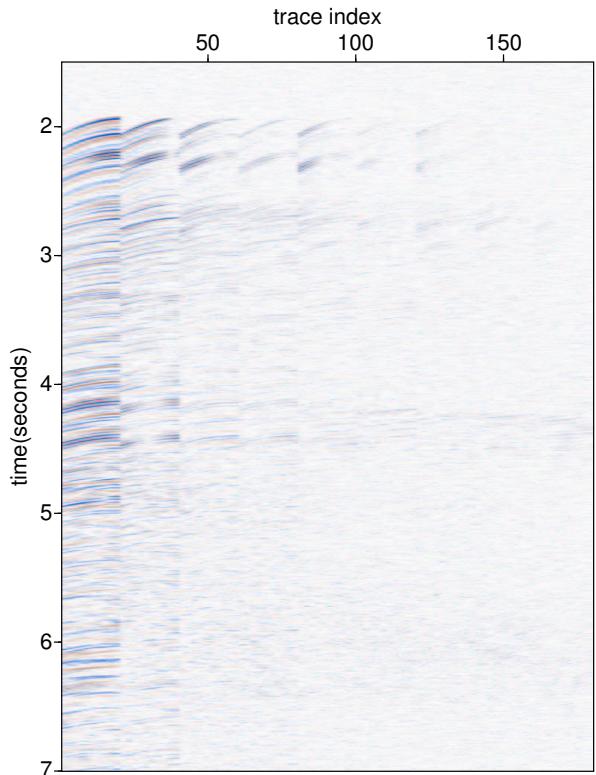


Figure 4: The scaled eigensections computed from the CMP's in Figure 3.

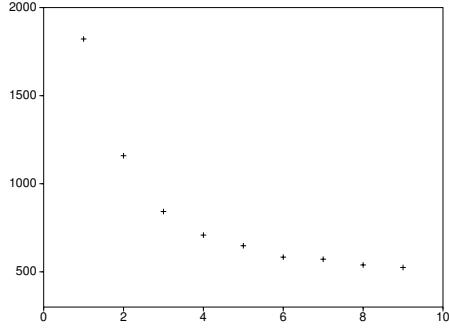


Figure 5: The singular values associated with the respective eigensections of Figure 4.

importance of an eigensection to the reconstruction of any and all of the seismic sections.

By examining Figure 4, we see that there is signal contained in more than just the first eigensection. This means that there is variation amongst the CMP's, and that simply stacking the CMP's to enhance the signal to noise ratio in the prestack domain would not be appropriate. However, we can increase the signal to noise ratio in the prestack domain by considering the reconstruction of a CMP from a weighted sum of eigensections.

Figure 6 shows the fourth CMP of Figure 3 along with a stack of the CMP's and the approximation to the fourth CMP using various combinations of eigensections. The basis for choosing which eigensections to use in the reconstruction of the CMP is based on the magnitudes of the singular values associated with those eigensections (see Figure 5). In Figure 6 we see that as more eigensections are used in the reconstruction, signal that was destroyed in the stack reappears. Of course, we should point out an obvious fact here. One cannot get something for nothing. When more eigensections are used in the reconstruction of the original CMP, both signal and noise are added to the final sum.

A key point in the analysis outlined in this section is that we know which seismic section we are reconstructing when we add together various eigensections. So, we can reconstruct any and all of the CMP's in Figure 3 by adding together the eigensections with different weights, such that we get a unique approximation for each of the CMP's.

Discussion

The study of eigenfaces has, as the ultimate goal, the task of recognizing and detecting human faces. We have taken the eigenface approach and applied

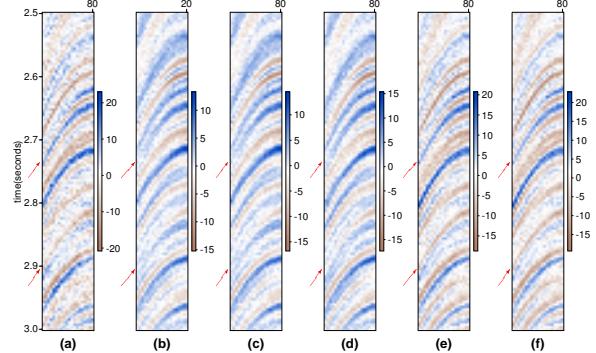


Figure 6: (a) The fourth CMP, (b) the stack, and the CMP's reconstruction using (c) one eigensection, (d) two eigensections, (e) three eigensections, and (f) four eigensections. Notice the events pointed at by the red arrows.

it to geophysics where our ultimate goal is to process and analyze geophysical data. Both eigenfaces and eigensections expand three dimensional data using the *SVD*; however, how eigenfaces are used is quite different from how we think eigensections could be used. In order to recognize a face, the eigenface approach is interested in seeing how a face is re-composed from a set of eigenfaces so that when the weighted eigenfaces are added together the face is reproduced. Analyzing these weights is what gives us the ability to recognize and detect faces. On the other hand, the eigensection approach is interested mainly in the components of the expansion. While the weights may, down the road, lead us to some interesting research, it is the actual eigensections that contain the information we want to analyze.

References

- Freire, S. L., and Ulrych, T. J., 1988, Applications of singular value decomposition to vertical seismic profiling: *Geophysics*, **53**, 778–785.
- Golub, G. H., and Van Loan, C. F., 1996, *Matrix computations: The Johns Hopkins University Press*, 3rd edition.
- Kirby, M., and Sirovich, L., March 1987, Low-dimensional procedure for the characterization of human faces: *J. Opt. Soc. Am. A*, **4**, no. 3, 519–524.
- Pentland, A., and Turk, M., March 1991, Eigenfaces for recognition: *Journal of Cognitive Neuroscience*.



Residual Migration Velocity Analysis in the Plane-wave Domain

Paul L. Stoffa, Department of Geological Sciences and Institute for Geophysics, The University of Texas at Austin; Mrinal K. Sen, and Junru Jiao, formerly Department of Geological Sciences and Institute for Geophysics, The University of Texas at Austin, presently PGS Research

Over the last few years, migration velocity analysis methods have been developed for 2D and 3D models mainly by extending the assumptions and approximations used for RMS velocity models. Computational requirements for these analyses have increased dramatically because top down layer stripping migration is needed to get interval velocities directly instead of using RMS velocities and then converting into interval velocities. We establish exact equations for 1D, 2D and 3D residual migration velocity analysis in the depth plane wave domain. The new method extends the advantages of velocity analysis in the τ - p domain: deriving interval velocities directly by top down residual corrections for all layers after prestack depth migration instead of top down layer stripping migration followed by residual normal moveout. This makes the new method a suitable tool for migration velocity analysis, especially for 3D surveys. We test the method on synthetic data and field data. The examples show that a reasonable velocity model is obtained and most common image gathers are correctly imaged using no more than four iterations.

INTRODUCTION

Some of the research in prestack migration velocity analysis began in the early 1990's (Yahya, 1989 and Liu, 1992). Under the assumptions of small dip, small offset, and/or constant velocity, various analytic functions were derived to express the relation between the true velocity (or the ratio of the migration velocity and the true velocity) and the offset in a Common Image Gather (CIG) after migration. Recently, residual moveout analysis was extended to media with lateral velocity variation (Meng, Bleistein & Wyatt, 1999). Most methods are performed in the offset domain and a top-down layer stripping migration scheme is needed to derive the interval velocity. It is natural to use the offset domain because this is the domain where most prestack depth migration is done and the migrated CIG's are available for the analysis. However, we can also perform prestack depth migration in the plane-wave (τ - p) domain (e.g., Akbar, Sen, and Stoffa, 1996, and Tanis, 1998). After migration, the data are in the z - p domain. Just as in prestack depth migration using x - t data, prestack depth migration using τ - p data and the correct interval velocity-depth model generates events in a CIG in the z - p domain which are horizontally aligned since they represent the image of the same subsurface position obtained at different angles (Whitmore & Garing, 1993). Use of an incorrect velocity-depth model in migration causes misalignment of events in a CIG, i.e., the events on the CIG exhibit a residual moveout. By analyzing the residuals in the CIG, we can derive the depth and the velocity corrections and thus obtain an updated velocity depth model. For example, if the velocity used is lower than the true velocity, the event curves up in the z - p domain after prestack depth migration. Otherwise, it curves down. We will demonstrate how the relationship between the depth and ray parameter for a given event on a CIG can be expressed as an analytic function with the migration velocities and true velocities of

overlying layers as parameters. To derive both lateral and vertical velocity variations, we only need to apply top down layer stripping residual difference corrections for all layers after migration instead of both top down layer stripping prestack depth migration and residual moveout.

Residuals in the z - p domain

Since prestack depth migration focuses most diffraction energy, it is a reasonable approximation now to assume a reflection model for velocity analysis using CIG's after prestack depth migration. Consider a plane wave traveling in a homogeneous medium of constant slowness u and thickness Δz with a angle θ to the vertical direction. If it is reflected at the bottom of the layer, and detected at the top, we can use following equation (Stoffa et al., 1981) to describe the interval delay time, $\Delta\tau(p)$, of this plane wave:

$$\Delta\tau(p) = 2\Delta z(u^2 - p^2)^{1/2}, \quad (1)$$

where $p = u \sin \theta$ is the horizontal slowness or ray parameter and the quantity $\sqrt{u^2 - p^2}$ is the vertical slowness. $\Delta\tau$ is called the vertical delay time because it is the two-way vertical travel time for the plane wave. To invert for thickness from the intercept time, we need to rewrite equation (1) as

$$\Delta z = \frac{\Delta\tau(p)}{2(u^2 - p^2)^{1/2}}. \quad (2)$$

For a stack of N horizontal layers, we sum over the layers and obtain the equation for the depth

$$z = \sum_{j=1}^N \Delta z_j = \sum_{j=1}^N \frac{\Delta\tau_j(p)}{2(u_j^2 - p^2)^{1/2}}, \quad (3)$$

where the subscript j is the layer index; and $\Delta\tau_j$ and u_j are the intercept time and slowness for the j^{th} layer. These equations relate the τ - p domain to the depth domain for a one-dimensional model where the true interval slowness is assumed to be a known parameter. Using equation (3), we can determine the depth of a reflecting horizon from the τ - p data once the slownesses and delay times are interpreted.

For migration, we may not know the true slowness during the initial migration. We use a trial slowness to migrate the τ - p data. This initial slowness u^m can have lateral and vertical variations. After migration, we now assume a local one-dimensional reflection model. The apparent depth for one layer, Δz^m , at a given CIG can be calculated using the flowing equation:

$$\Delta z^m(p) = \frac{\Delta\tau(p)}{2[(u^m)^2 - p^2]^{1/2}}. \quad (4)$$

Residual Migration Velocity Analysis in the Plane-wave Domain

For a stack of N horizontal layers we have:

$$z^m(p) = \sum_{j=1}^N \Delta z_j^m(p) = \sum_{j=1}^N \frac{\Delta\tau_j(p)}{2[(u_j^m)^2 - p^2]^{1/2}}, \quad (5)$$

where u_j^m is the slowness used for the migration and Δz_j^m is the thickness corresponding to u_j^m and $\Delta\tau_j$ for the j^{th} layer. The difference between the true slowness and trial slowness will cause a misfit between the true depth z and migrated depth z^m .

$$z_{\text{res}}(p) = \sum_{j=1}^N \Delta z_j^m(p) \left\{ \frac{[(u_j^m)^2 - p^2]^{1/2}}{(u_j^2 - p^2)^{1/2}} - 1 \right\}. \quad (6)$$

Similar equations can be derived from 2D and 3D dipping layers.

Synthetic Example: SEG/EAEG Salt Model

We selected one 2D line from the SEG/EAEG 3D salt model. The velocities vary from 2.0 km/s to 4.47 km/s at the edge of the salt dome.

We used a 1D velocity model for the initial migration. Velocities increase linearly from a minimum of 1.50 km/s at

the surface to a maximum of 2.80 km/s at the bottom. This initial model is quite different from the true model especially in the salt region.

In Figure 1, from iteration 1 to 6, we used the 1D residual difference correction method and the 2D method was used at iteration 7. After 7 iterations, most CIG's were correctly imaged. We selected CIG 440 as an example to examine the evolution of the CIG's because this CIG crosses the salt dome and most of the horizons. Figures 1a to 1h show the evolution of CIG 440 from the initial migration to iteration 7. Throughout the iterations, the events become horizontally aligned gradually from the shallow part to the deep part as the velocities approach their true values.

We also stacked the 61 traces within each CIG. The structures above the salt dome's top are well imaged after four iterations (Figure 2). After seven iterations, most structures are correctly imaged except for the very deep part (Figure 2c).

Field data example: Line BA6, Carolina trough

We also applied our technique to part of one 2D field line: Line BA6, from the Carolina trough offshore the east coast of the United State acquired by the Institute for Geophysics.

The initial velocity model was derived from stacking velocities by converting RMS velocities into interval

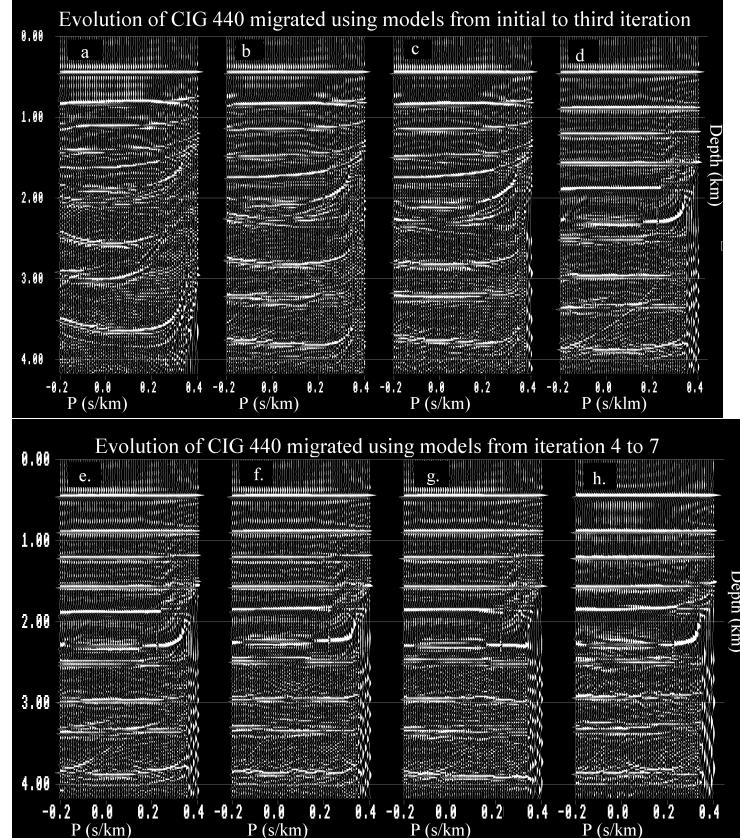


FIG. 1. Evolution of CIG 440 from (a) the initial migration to (h) iteration seven. The flatness of events on the CIG gradually improves with iteration as the velocity depth model becomes closer and closer to the true model.

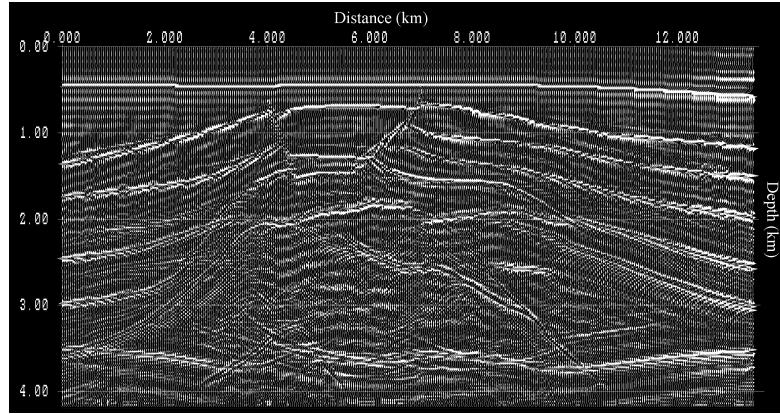


FIG. 2a. Migrated and stacked section using the critical trial 1D velocity model. Since the model is quite far from the true model, the stack is out-of phase and amplitudes are distorted. Therefore, the structures are not correctly imaged.

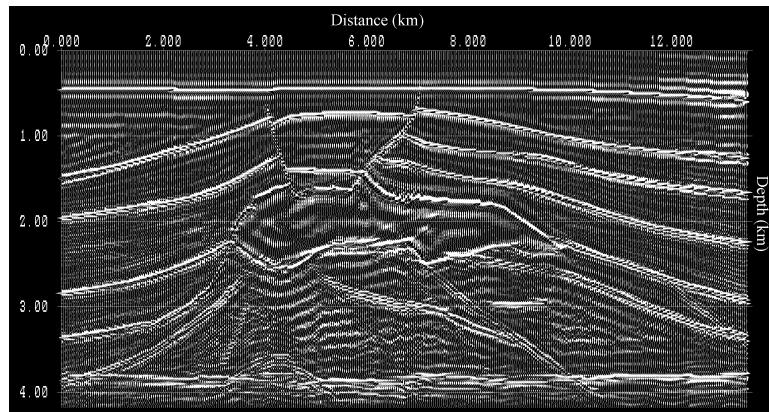


FIG.2b. Migrated and stacked section using the model after iteration four. After four iterations, the structures above the salt dome's top are correctly imaged but there are still more iterations to go to improve the image of the salt dome's bottom.

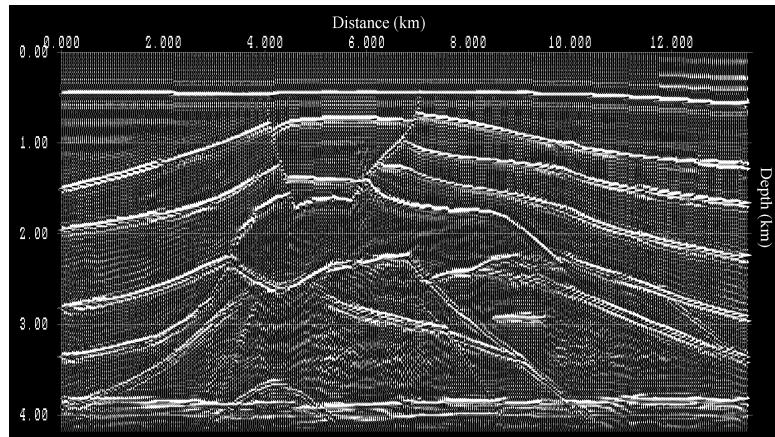


FIG. 2c. Migrated and stacked section using the final model after iteration seven.

velocities using Dix's equation and then smoothing. We performed velocity analysis for 19 layers and on every 10th CIG.

CIG 500 is an example of the evolution of one CIG'. Figure 3 shows the evolution of the CIG from (a) the initial

migration to (e) the fourth iteration, which demonstrates continuous improvement of image quality.

Residual Migration Velocity Analysis in the Plane-wave Domain

CONCLUSIONS AND FUTURE RESEARCH

We have derived the residual depth moveout equations and developed a residual migration velocity analysis method in the depth plane wave domain for 1D, 2D, and 3D models and applied them to both synthetic τ_p data and field data successfully. The main advantage of the new method is that it gives interval velocities directly and is computationally very efficient because only a top down residual correction is needed for velocity analysis after prestack depth migration. The synthetic data examples show that the 2D method gives a better residual migration result than the 1D method when

strong dips are present but the 1D equation also works well for 2D models when the dip angles are small. After getting a revised velocity depth model, one can use the new model to perform residual corrections on the entire data set which will give much better CIG's and stacked sections than those without the residual corrections. Alternatively, we can use the new model to migrate the original data again and then repeat the residual velocity analysis for another iteration. The number of iterations depends on the initial model and the precision required. In the field data example, a reasonable model was obtained after only 4 iterations.

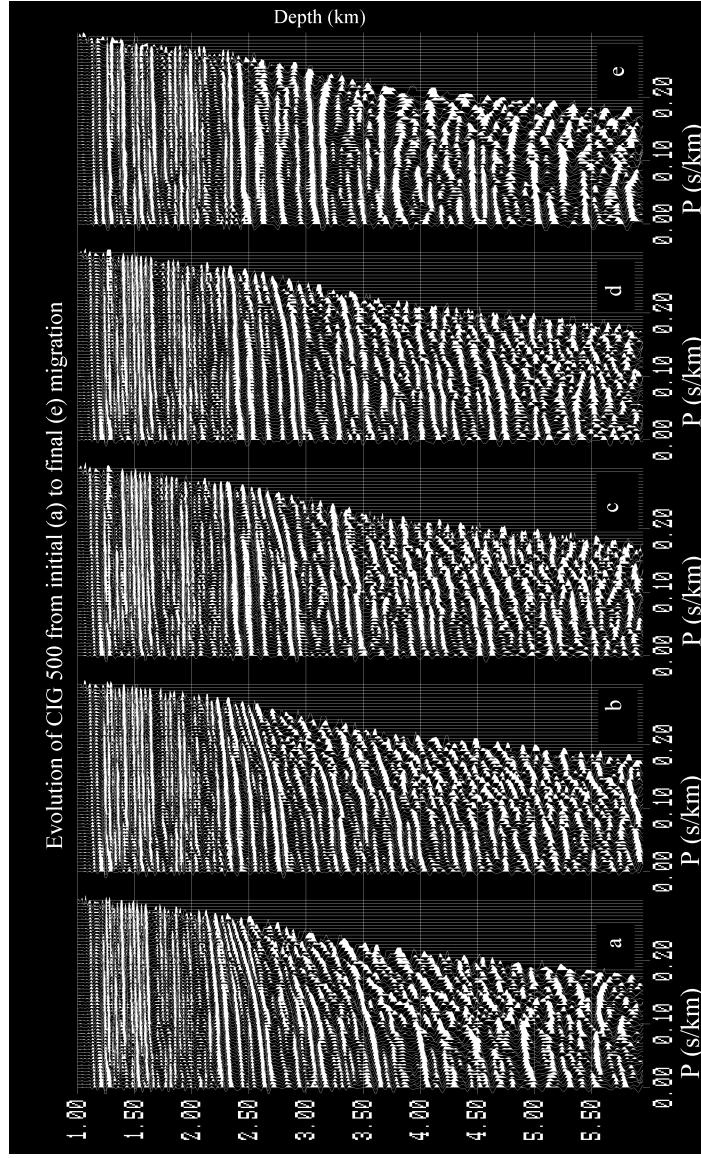


FIG. 3. The evolution of CIG 500 from (a) the initial migration using the initial velocity model derived from stacking velocities to the final migration after four iterations.



Supressão do Ruído de Rolamento Superficial Utilizando Transformada Wavelet 2D

*Marcílio Castro de Matos, Pontifícia Universidade Católica - PUC-RIO e Instituto Militar de Engenharia,
marcilio@ele.puc-rio.br*

Paulo Léo Manassi Osório, Pontifícia Universidade Católica - PUC-RIO, osorio@ele.puc-rio.br

Abstract

Among the various types of noise found in seismic land acquisition there is the one produced by surface waves. This noise is called ground roll, and it can be defined as a group of events that contaminates seismic data by forming a high dip (low velocity) and high amplitude cone, which can dominate near-surface events on the seismic records. We present in this paper a technique based on the 2D wavelet transform to remove the ground roll. The method was tested with real data and the results were very good.

Introdução

Ondas superficiais são uma fonte comum de ruído em dados sísmicos. O ruído de rolamento superficial é a componente vertical das ondas dispersivas e geralmente se encontra em sinais de exploração sísmica terrestre, principalmente, quando não se tomam os devidos cuidados no momento da aquisição destes sinais. Normalmente, no processo de aquisição de dados são formados conjuntos de receptores para suprimir o “ground roll” através de uma filtragem espacial. Entretanto, estes processos tornam a aquisição de dados mais cara, além de não garantirem totalmente a sua eficácia. Portanto, métodos para remoção dos mesmos são bastante importantes para o processamento de sinais sísmicos. Existem vários métodos implementados comercialmente para tal. Entre estes, o mais utilizado é baseado na transformada f-k (Hatton, 1986). Novas técnicas têm surgido, algumas utilizando transformada wavelet em uma dimensão (Deighan, 1997), (Osório, 2000) e em duas dimensões (Deighan, 1996), (Abdul, 2000).

O objetivo deste trabalho é apresentar uma forma de remoção do ruído de rolamento superficial em dados sísmicos terrestres utilizando transformada wavelets em duas dimensões. Foram realizados testes com dados reais para comprovar a eficácia do método.

O Ruído de Rolamento Superficial (“ground roll”)

O ruído de rolamento superficial, ou “ground roll”, é um tipo de onda de Rayleigh que surge nos sinais sísmicos devido ao acoplamento de ondas compressionais e das componentes verticais das ondas cortantes que se propagam ao longo da

superfície livre (Yilmaz, 1987). É a componente vertical das ondas superficiais dispersivas, sendo o principal tipo de ruído coerente em explorações sísmicas terrestres. O cone formado pelo rolamento superficial se caracteriza como uma onda de energia que se propaga com baixa velocidade, baixa freqüência e grande amplitude em relação aos eventos de interesse.

Transformada Wavelet 2D

Existem duas formas diferentes de se computar a transformada wavelet de um sinal em duas dimensões, que no caso de sinais sísmicos são tempo, t , e espaço, x . Basicamente, a primeira consiste em se tomar a transformada wavelet de todas as linhas para depois se tomar a transformada de todas as colunas como está ilustrado na Fig1 (Stollnitz, 1995), ou seja, em se obter uma base para o espaço bidimensional $t \& x$ multiplicando-se as bases unidimensionais em t e x , respectivamente, como representado pela Eq 1.

$$\psi_{j,jk'}(t,x) = \psi_{jk}(t)\psi_{jk'}(x) \quad (1)$$

A desvantagem desta base é a mistura das escalas j e j' .

Entretanto, é possível construir uma base através de uma única escala j , utilizando-se três funções wavelets como base para cada nível j . Estas funções estão representadas na Eq 2 (Cohen, 1993).

$$\begin{aligned} \psi_{jkk'}^H(t,x) &= \psi_{jk}(t)\phi_{jk'}(x), \\ \psi_{jkk'}^V(t,x) &= \phi_{jk}(t)\psi_{jk'}(x), \\ \psi_{jkk'}^D(t,x) &= \psi_{jk}(t)\psi_{jk'}(x). \end{aligned} \quad (2)$$

Já a função escala no nível j é simplesmente o produto das funções escala em uma dimensão e está representada pela Eq 3.

$$\phi_{jkk'}(t,x) = \phi_{jk}(t)\phi_{jk'}(x) \quad (3)$$

Esta forma de decomposição é chamada de Não Padrão ou Não Convencional, sendo a mais utilizada. Consiste, basicamente, em se tomar de

Supressão do Ruído de Rolamento Superficial Utilizando Transformada Wavelet 2D

modo alternado a decomposição entre linha e colunas, como ilustrado na Fig 1.

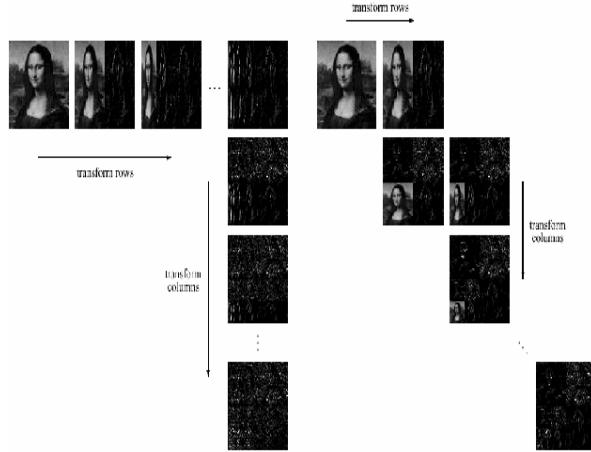


Figura 1: À esquerda a Decomposição Padrão de uma Imagem e à esquerda a Decomposição Não Convencional

Outra forma conveniente de se analisar o resultado da transformada wavelet 2D é entender a decomposição através das bases descritas pelas Eq 2 e Eq 3, como ilustrado nos quatro painéis da Fig 2 (Cohen, 1993). O símbolo A representa o painel de aproximação em cada direção e é análogo a aproximação em uma dimensão, enquanto os outros três painéis correspondem às três componentes wavelets em cada nível j . Como em uma dimensão, cada nível sucessivo tem a metade do número de pontos em ambas as dimensões do nível anterior.

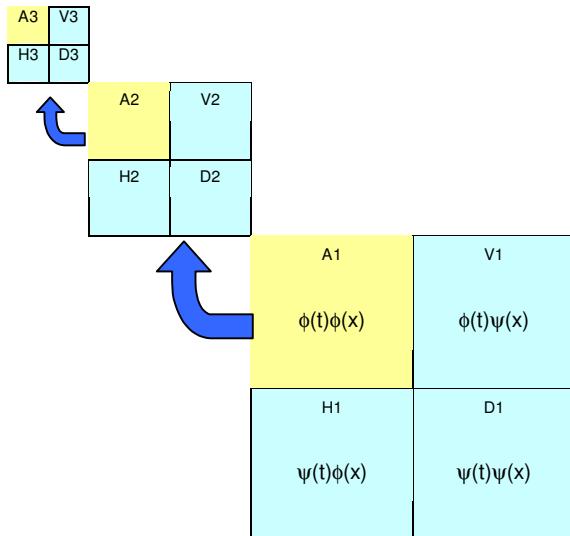


Figura 2: Decomposição em Wavelets 2D

Como indicado na Fig 2, e verificado através da Eq 2, as partes do painel representadas por V1, V2

e V3 possuem ênfase em detalhes verticais, já que são criadas a partir da “aproximação” do sinal em t e da “diferenciação” do sinal em x . Os coeficientes V1, V2 e V3 são chamados de detalhes verticais.

Da mesma forma, H1, H2 e H3 são os detalhes horizontais e D1, D2 e D3 os detalhes diagonais e também são obtidos a partir da aproximação do nível anterior, que no caso do nível 1 é o próprio sinal.

Portanto, ao decompor um sinal sísmico utilizando wavelets, eventos tipicamente com grande mergulho, como o ruído de rolamento superficial, serão enfatizados nos detalhes verticais. Logo, para removê-los, deve-se identificar os mesmos nos detalhes verticais e zerá-los.

A Técnica de Supressão do Ruído de Rolamento Superficial Utilizando Transformada Wavelet 2D

Como descrito, o ruído de rolamento superficial se caracteriza por um cone quase na vertical formado por ondas de baixa freqüência e grande amplitude. Portanto, quando um sinal sísmico contaminado pelo “ground roll” for processado utilizando a transformada wavelet 2D, o ruído de rolamento superficial estará contido principalmente nos detalhes verticais. Desta forma, o método utilizado neste trabalho consiste em identificar o “ground roll” nos detalhes verticais e eliminá-lo, ou seja:

- Decompor o sinal sísmico utilizando a transformada wavelet 2D em quantos níveis se julgar necessário
- Analisar os coeficientes contendo os detalhes verticais identificando possíveis contribuições do ruído de rolamento superficial
- Selecionar estas regiões zerando os coeficientes nas mesmas
- Reconstruir o sinal com os coeficientes selecionados e zerados
- Comparar com o sinal original

Este método foi implementado utilizando como ferramentas o software Matlab e seu Toolbox de Wavelets (Misiti, 1996).

Remoção do Ruído de Rolamento Superficial Utilizando Transformada Wavelet 1D

Para efeito de comparação com o método apresentado, foi utilizada a técnica de remoção de “ground roll” utilizando transformada wavelet em uma dimensão (Deighan, 1997), (Osório, 2000), que consiste, basicamente, em se localizar, traço a traço, o

Supressão do Ruído de Rolamento Superficial Utilizando Transformada Wavelet 2D

ruído de rolamento superficial e removê-lo. Ou seja, como o “ground roll” é um ruído de baixa freqüência, ao se decompor os traços em diferentes escalas utilizando wavelets, este ficará restrito aos detalhes e a aproximação de baixa freqüência. Ao mesmo tempo é possível localizar visualmente o “ground roll”. Portanto, a técnica consiste em se selecionar a região onde o mesmo está concentrado e se filtrar somente o detalhe e a aproximação correspondente. A Fig 3 ilustra como é feita a filtragem utilizando-se este método.

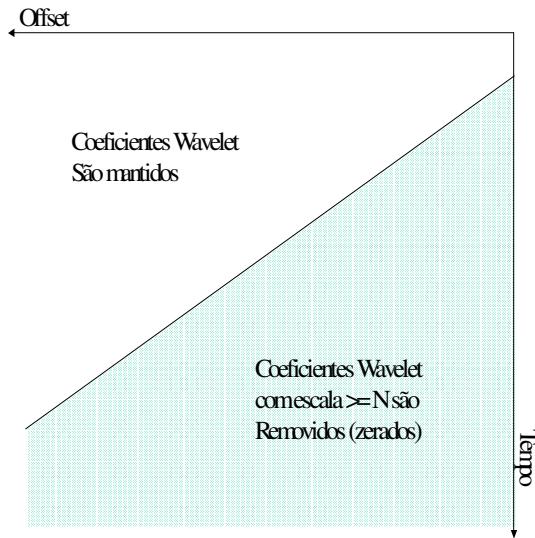


Figura 3: Representação Esquemática da Filtragem Utilizando Wavelets 1D

Resultados Experimentais

O sinal utilizado neste trabalho para fins de demonstração da eficácia do método foi retirado da base de dados disponibilizada por Yilmaz e está descrito em seu livro (Yilmaz, 1987) como sinal n.º 25, que segundo o mesmo foi obtido em Alberta no Canadá. Entretanto, o sistema foi desenvolvido de forma genérica e pode ser utilizado com qualquer sinal sísmico que esteja em formato de matriz. A Fig 4 ilustra o mesmo após a aplicação de AGC (Yilmaz, 1987). A visualização dos sinais 2D e a conversão do formato original do sinal, SEG-Y, para Matlab foram realizadas através da biblioteca SeismicLab (Sacchi, 1997).

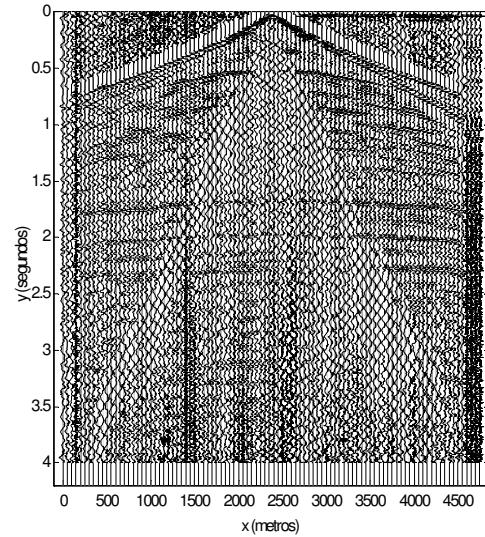


Figura 4: Sinal com AGC

Para a supressão do “ground roll” o sinal escolhido foi decomposto em 3 níveis utilizando a transformada wavelet 2D biortogonal (6.8). Esta wavelet foi escolhida devido a sua simetria, garantindo, portanto, a linearidade de fase desejada na reconstrução de sinais bidimensionais.

Os três detalhes verticais foram analisados e todos os coeficientes abaixo da área selecionada foram zerados. A Fig 5 ilustra o processo para o detalhe vertical 1.

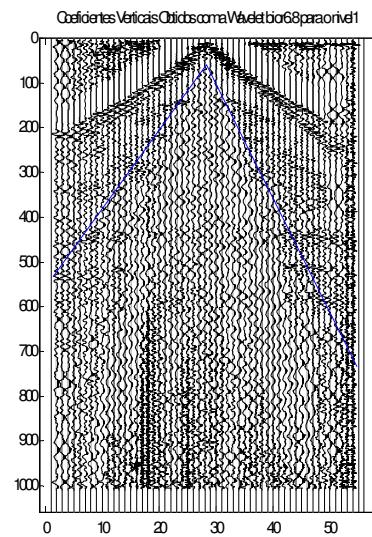


Figura 5: Detalhe Vertical 1 e região selecionada para ser zerada

A Fig 6 ilustra o sinal reconstruído após a remoção dos coeficientes abaixo da linha e confirma o bom resultado na remoção do ruído de rolamento superficial. Portanto, como esperado, o “ground roll”

Supressão do Ruído de Rolamento Superficial Utilizando Transformada Wavelet 2D

estava praticamente restrito aos detalhes verticais na decomposição utilizando wavelets.

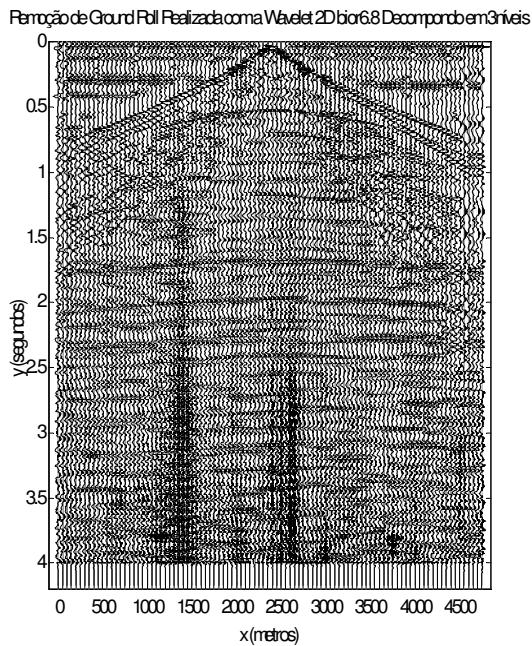


Figura 6: Sinal reconstruído apóis a remoção do “ground roll” com Wavelets 2D

Para efeito de comparação, o mesmo sinal foi filtrado utilizando-se a técnica com wavelet 1D descrita acima. O resultado está ilustrado na Fig 7. Visualmente, pode-se perceber que o resultado utilizando a técnica 2D foi melhor, embora, ambas tenham obtidos bons resultados.

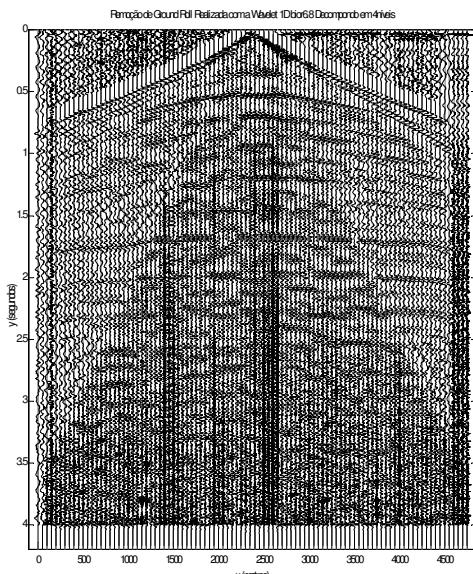


Figura 7: Sinal reconstruído apóis a remoção do Ground Roll com Wavelets 1D

Conclusões

A transformada wavelet bidimensional mostrou ser uma ferramenta bastante poderosa na remoção do ruído de rolamento superficial, principalmente, porque ela leva em conta a correlação espacial entre os traços, o que não ocorre em outros métodos que realizam a análise traço a traço, levando, portanto, em conta somente a variável tempo.

Referências

- Abdul-Jauwad S. H., Khène K. F., 2000, *Two-Dimensional Wavelet-Based Ground Roll Filtering*, 70th Annual Internat. Mtg. Soc. Expl. Geophys.
- Burrus S., Gopinath R. A., Guo H., 1998, *Introduction to Wavelets: A Primer*, Prentice-Hall.
- Cohen, J.K., and T. Chen, 1993, *Quantitative dip bounds for the two-dimensional discrete wavelet transform: Mathematical Methods in Geophysical Imaging*, 2033, 140-157. <http://www.cwp.mines.edu/documents/cwpreports/cwp-130.pdf>
- Deighan A. J., Watts D., 1997, *Ground-roll Suppression Using Wavelet Transform*, Geophysics, Vol. 62, NO. 6, pp 1896-1903.
- Deighan A. J., Watts D., 1996, *2D Filtering Using the Wavelet Packet Transform*, EAGE 58th Conference and Technical Exhibition, Amsterdam, The Netherlands.
- Hatton L., Worthington M. H., Makin J., 1986, *Seismic Data Processing*, Blackwell Scientific Publications.
- Misiti M., Misiti Y., Oppenheim G., Poggi J. M., 1996, *Wavelet Toolbox For Use With Matlab*, The MathWorks Inc.
- Osorio, P.L., e Costa e Silva, M. , 2000, *Aplicação de Wavelets na Supressão de Ruído Sísmico*, XIII Congresso Brasileiro de Automática, pp 539-544.
- Sacchi, M. D., 1987, *SeismicLab Tools to Read/Write and Process SEG-Y with Matlab*, <http://rubble.phys.ualberta.ca/%7Esacchi/SEISMIC LAB/>
- Stollnitz E. J., DeRose T. D., Salesin D. H., May 1995, *Wavelets for Computer Graphics: A Primer, Part 1*, Tutorial IEEE Computer Graphics and Applications.
- Yilmaz O., 1987, *Seismic Data Processing*, Society of Exploration Geophysicists,
- Yilmaz, <ftp://138.67.12.4/pub/data/oz.original/ozdata.25/>

Time-Frequency Filtering using Fractional Spline Wavelet Packets

Deilson M. Tavares, UFRN, Brazil; Felix J. Herrmann, ERL-MIT, USA; Heron A. Schots, PETROBRAS S/A, Brazil

Abstract

Here we present a method for time-frequency filtering using Fractional Spline Wavelet Packets. Possible applications are in improved localization of reflections and ground roll elimination.

Introduction

The standard filters used to eliminate undesirable components from seismic traces are frequency filters and velocity filters. The problem is that the reflections - typically the broad band component of the signal - tend to be affected by filtering operations, which suppress frequencies present in the noise, without regard to time-space position.

To remedy this difficulty a number of time-frequency decompositions have been attempted such as the spectrogram, the Gabor atomic decomposition, the wavelet transforms, continuous and discrete, and the Wigner-Ville transforms [Mallat, Steeghs]. All these decompositions provide systematic means to perform time-frequency filtering, a general term for locally manipulating the frequency content of a signal.

Key aspects of the decompositions are their ability to sparsely represent data, and their ability to be data adaptive. By using non-linear methods it is possible to find an optimal representation for a particular signal from a redundant dictionary of basis functions. We use a combination of two such methods: the Coifmann-Wirkerhouser Best Basis (BB) selection and Matching Pursuit (MP).

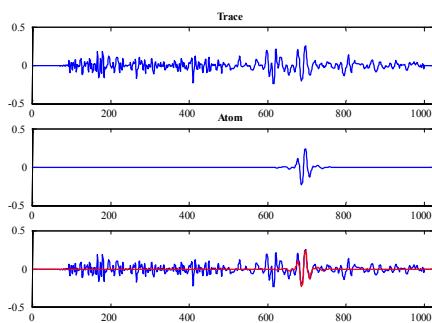


Figure 1 - The first trace is shown with the predominant atom which is parametrized at point 700 by a Fractional Spline Wavelet with $\alpha = 3.90$.

The dictionary we use is composed of Fractional Spline Wavelet Packets (FSWP) [Herrmann1]. These packets are derived from the Fractional Spline Wavelets [Unser]. They have all properties needed to perform atomic decompositions and fit our purposes mainly because they can continuously vary their time-frequency characteristics, i.e. their decay rate for high frequencies (regularity) and their behavior at the origin (vanishing moments and fractional order of differentiation). In this way we can construct fractional splines that are α -Hölder regular, (with $\alpha \in (-1/2, \infty)$) at the knots. Consequently, our atoms can be extremely smooth, almost sine waves or sinc func-

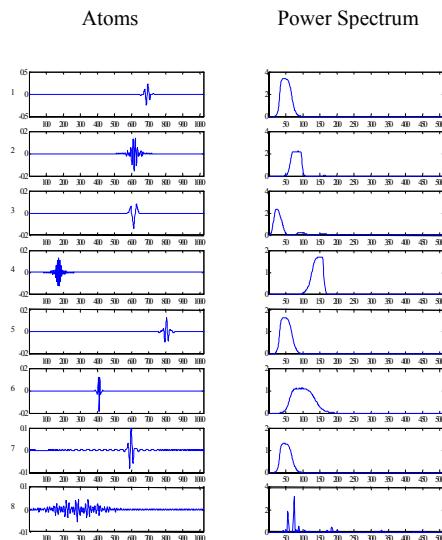


Figure 2 – The eight more representative atoms in the decomposition of the trace.

tions, or jumps. Using a well founded computational scheme, these Fractional Spline Wavelet Packets allow us to find waveforms from a large dictionary that best fit events in the data. In this paper we will show that this FSWP decomposition may perform particularly well for seismic data processing, such as the removal of the ground roll noise component.

Methodology

To reduce the computational complexity we construct our MP dictionary by first conducting a Best Bases selection on the FSWP. So for each trace we compute several α -indexed wavelet packet trees. Then, for each tree we will use Coifman-Wirkerhouser Algorithm to find the BB representation, followed by the

Fractional Spline Wavelet Packets

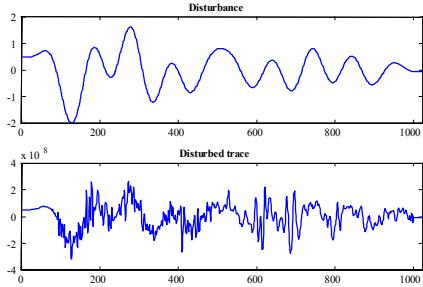


Figure 3 – A low frequency disturbance and the disturbed trace.

“greedy” selection of atoms, using the MP algorithm. The output is an ordered list of atoms, from the most predominant to the faintest. Via composition we can reconstruct the trace again from the list of atoms. This reconstruction converges to the original trace, as the number of atoms tends to infinity. When the dictionary sufficiently closely matches events in the data, the atomic decomposition, followed by a reconstruction using atoms that exceed a noise dependent threshold, also removes additive random noise [Mallat]. In practice, we obtain almost perfect reconstruction for a number of atoms far less (typically 10 % of the sample number) than the number of samples in the trace.

Example

Besides incoherent random noise removal our atomic decomposition also lends itself to eliminate large coherent noise components from the data. For this purpose we disturb the seismic trace of Figure 1, see Figure 3. The seismic trace has a length of 1024. The trace is decomposed into the 100 best correlating atoms from the dictionary. The dictionary of Best Bases vectors was formed using FSWP’s with 100 equally spaced values of $\alpha \in [-0.49, 7]$. Figure 1 shows the most important atom in this decomposition and we see that it fits the event at position 700 quite well.

In Figure 2 we picture the eight most important atoms together with their Fourier spectrum. The estimated α -indexes characterize the transition sharpness and carry information on the lithology. Refer to [Herrmann1, Herrmann2] for a discussion on the litho-stratigraphical information content of the atom’s parameterization.

What we expect of our decomposition is that it fits the perceptible changes in the trace since, typically, reflections that are of most interest occur at sharp

transitions in the earth’s elastic properties. Other, less impulsive components, such as the low frequency disturbance in Figure 3, are not of interest. So, what we would like to do is to remove this disturbance without affecting the broad band time-frequency characteristics of reflection events. These events carry useful information on the geology [Steeghs, Herrmann1, Herrmann2].

The Fourier spectrum of the atoms gives information about their central frequency and bandwidth. The broad band atoms are candidates to represent singularities, that is to say, reflections. The narrow band atoms can be associated with discrete frequency components of slow decay compared with the duration of the trace.

This separation can be used to filter coherent noises that usually decay slowly compared with the reflections. In our application of ground roll removal, the noise has significantly less bandwidth than the reflections. This difference can be used to separate the noise from the data. As an example we apply our method to the disturbed trace of Figure 3. First, we perform an atomic decomposition as in the previous undisturbed case. The only difference is that we use more atoms (130), to compensate for elimination of atoms that are related to the coherent noise. The eight most relevant atoms are shown in Figure 4. As we can see a number of the atoms are related to the disturbance. However, one can also see that most of the atoms pertaining to the unperturbed signal are still there. By using a simple criterion: any atom decaying slowly in a distance of half the disturbance length (which in this case is the total length) was considered as a disturbance component and not taken into account in the reconstruction. In this way we are able to accurately reconstruct the original signal. The filtered result is shown in figure 5, and can be compared with the original trace.

As we can see from these results, application of this method to the elimination of ground roll seems to be promising. As compared to common ground roll removal based on high-pass filtering, our method has the advantage that it affects the low frequencies selectively in time. Primary reason for the better performance is the data adaptation yielding an improved time-frequency localization. This localization allows us to separate the very coherent reflection events from the less coherent ground roll. It will be interesting to compare our proposed method to approaches involving wavelet decompositions mixed with velocity analysis [Deighan, Tavares].

Fractional Spline Wavelet Packets

Conclusion

The atomic decomposition scheme we presented in this paper excels in separating broad band from narrow band or even discrete frequency components. The data adaption in conjunction with the appropriateness of our FSWP dictionary for seismic data are responsible for the accomplished time-frequency localization. As a consequence we are able to identify atoms that are related to the data and filter out those that are related to the noise. The main advantages of our method are:

- Only amplitudes corresponding to disturbances are eliminated in a given portion of the signal.
- Singularities (points characterizing reflections) are unaffected.
- Resulting filtered signal is compressed.
- The method can be integrated with other applications of time-frequency analysis.

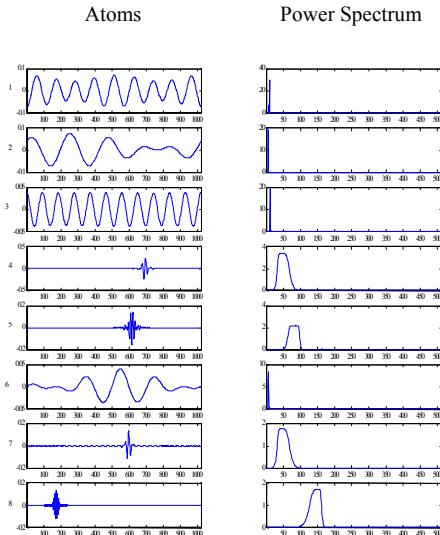


Figure 4 – The eight more important atoms in the decomposition of the disturbed trace.

References

- [Herrmann1] - Herrmann, F. J., 2001, "Fractional Spline Matching Pursuit: a quantitative tool for seismic stratigraphy", Expanded Abstract in the Proceedings of the 71th Annual meeting of the Society of Exploration Geophysicists.

- [Herrmann2] - Herrmann, F. J., 2001, "Seismic facies characterization by monoscaleanalysis", to appear in Geophysical Review Letters
- [Unser] - Unser, M. and Blu, T., 2000, SIAM review, **42**, No. 1, 43-67.
- [Steeghs] - Steeghs, P. H., 1997, "Local Power Spectra and Seismic Interpretation", PhD. Thesis, Delft University of technology.
- [Mallat] - Mallat, S., 1998, "A Wavelet Tour on Signal Processing", Academic Press, San Diego.
- [Deighan] - Deighan, A. J. and Doyle, R. W., 1997, "Ground Roll Supression using the Wavelet Transform", Geophysics, **62**, No. 6, 1896-1903.
- [Tavares] – Tavares, D. M. et al., 2001, "A Ground Roll Filtering with Compact Support in Time", in preparation.

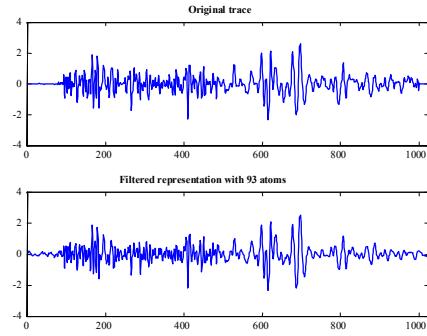


Figure 5 – The original trace and the filtered representation with 93 atoms.

Acknowledgments

We thanks to CAPES, CTPETRO and PETROBRAS S/A for financial support.