



Migração por Mínimos Quadrados usando condição de imagem com amplitude verdadeira: uma abordagem no domínio da imagem

Natiê Almeida Albano* (UFPA), Jessé Carvalho Costa (UFPA), Jörg Schleicher (UNICAMP)

Copyright 2019, SBGf - Sociedade Brasileira de Geofísica

This paper was prepared for presentation during the 16th International Congress of the Geophysical Society held in Rio de Janeiro, Brazil, 19 to 22 August 2019.

Contents of this paper were reviewed by the Technical Committee of the 16th International Congress of the Brazilian Geophysical Society. Ideas and concepts of the text are authors' responsibility and do not necessarily represent any position of the SBGf, its officers or members. Electronic reproduction or storage of any part of this paper for commercial purposes without the written consent of the Brazilian Geophysical Society is prohibited.

Abstract

Least squares migration (LSM) is a linear inversion of seismic data which aims at providing migrated images with higher resolution and amplitudes proportional to the velocity contrast across the interface. LSM minimizes imaging artifacts produced by limited acquisition aperture and by variations in the subsurface illumination of the seismic wavefield. Originally, LSM was formulated as an inverse linear problem in the data domain. The Born approximation is the linear model used to approximate the recorded wavefield of primary reflections. Although very robust and effective in improving the quality of seismic images, this approach has a high computational cost due the multiple modeling and migration iterations necessary for convergence. Alternatively, the LSM was later reformulated in the image domain. This approach allows us to take advantage of true-amplitude imaging conditions of RTM to improve the results of LSM. This paper investigates the use of true-amplitude imaging for reverse-time migration (RTM) in order to improve LSM in the image domain, also known as migration deconvolution. We validate our LSM implementation with a true-amplitude imaging condition using the Marmousi data set. When compared with the conventional implementation of LSM in the image domain, our deconvolved images present higher resolution and amplitudes that are better correlated with the model reflectivity.

Introdução

A Migração por Mínimos Quadrados (LSM) é um método de inversão sísmica linear. Sua implementação objetiva mitigar problemas no imageamento sísmico devidos a fatores como: abertura limitada dos arranjos de aquisição, iluminação não uniforme em subsuperfície e ruídos associados ao retro-espalhamento.

A LSM implementada no domínio dos dados requer a solução iterativa de um sistema linear. Em cada iteração o campo de onda espalhado é modelado pela aproximação de Born e o resíduo entre os campos espalhados observado e modelado deve ser migrado. O custo computacional de cada iteração é aproximadamente duas vezes o custo de uma migração reversa no tempo

(RTM) (Nemeth et al., 1999; Prucha and Biondi, 2002).

Como alternativa para reduzir o custo computacional da LSM no domínio dos dados, a LSM no domínio da imagem permite um aumento de resolução da migração RTM com um menor custo computacional. Nesta abordagem, uma aproximação numérica do Hessiano da função objetivo da migração por quadrados mínimos é utilizada para solução do sistema linear (Fletcher et al., 2016; Schuster, 2017).

Neste trabalho investigamos o efeito da condição de imagem deduzida por Op't Root et al. (2012) na estimativa numérica do Hessiano para a LSM no domínio da imagem. Esses autores demonstraram, usando análise microlocal, que esta condição de imagem é um inverso assintótico da modelagem Born. No domínio do tempo esta condição pode ser expressa como

$$I_v(\mathbf{x}) = \frac{1}{P'(\mathbf{x})} \sum_s \int_t dt \left[\frac{\partial p_s(t, \mathbf{x}; \mathbf{x}_s)}{\partial t} \frac{\partial q_r(t, \mathbf{x}; \mathbf{x}_r)}{\partial t} + c^2 \nabla p_s(t, \mathbf{x}; \mathbf{x}_s) q_r(t, \mathbf{x}; \mathbf{x}_r) \right], \quad (1)$$

em que $p_s(t, \mathbf{x}; \mathbf{x}_s)$ configura o campo de onda da fonte, $p_r(t, \mathbf{x}; \mathbf{x}_r)$ o campo de onda dos receptores, $c(\mathbf{x})$ a velocidade de propagação, $P'(\mathbf{x})$ denota a auto-correlação da segunda derivada temporal do campo de onda da fonte e uma integral temporal é aplicada no campo de onda do receptor $q_r(t, \mathbf{x}; \mathbf{x}_r)$, i.e.,

$$P'(\mathbf{x}) = \sum_s \int_t dt \left(\frac{\partial p_s(t, \mathbf{x}; \mathbf{x}_s)}{\partial t} \right)^2, \quad (2)$$

$$q_r(t, \mathbf{x}; \mathbf{x}_s) = \int_0^T p_r(t, \mathbf{x}; \mathbf{x}_r) dt. \quad (3)$$

Devido à propriedade de ser exatamente o inverso assintótico da modelagem Born, a condição de imagem (1) oferece amplitudes verdadeiras proporcionais aos coeficientes de reflexão, sendo denominada neste trabalho por condição de imagem com amplitude verdadeira.

Por outro lado, convencionalmente a condição de imagem baseada na correlação cruzada proposta por Claerbout (1985) produz uma boa estimativa dos refletores em subsuperfície. Mas, se o modelo de velocidade para a migração contém fortes contrastes de vagariedade, dois fatores principais prejudicam a qualidade da imagem migrada: 1- valores de correlação cruzada elevados ocorrem ao longo de toda a trajetória do evento de reflexão produzindo artefatos de baixa frequência na imagem migrada e 2- o campo de onda perde amplitude rapidamente com a profundidade.

Para mitigar estes efeitos, aplica-se o filtro Laplaciano na imagem migrada para atenuar os ruídos de baixa

frequência, enquanto que a perda de amplitude do campo de onda com a profundidade pode ser compensado dividindo a correlação cruzada pela iluminação da fonte (Biondi, 2006), i.e.,

$$I_c(\mathbf{x}) = \frac{1}{P(\mathbf{x}; \mathbf{x}_s)} \nabla^2 \left[\int_t p_s(t, \mathbf{x}; \mathbf{x}_s) p_r(t, \mathbf{x}; \mathbf{x}_r) dt \right], \quad (4)$$

em que $P(\mathbf{x}; \mathbf{x}_s)$ é a autocorrelação do campo de onda da fonte e corresponde ao termo de compensação de iluminação.

Nosso objetivo neste trabalho é investigar as possíveis vantagens para LSM no domínio da imagem a partir da utilização da condição de imagem com amplitude verdadeira da equação (1), a partir da comparação com a LSM usando a condição de imagem com filtro Laplaciano e compensação de amplitude da equação (4).

A Figura 1 mostra o efeito de cada uma dessas condições de imagem na RTM convencional, na qual podemos notar um melhor resultado quando se utiliza a condição de imagem com amplitude verdadeira. Esse melhor imageamento é mais expressivo com o aumento da profundidade (compare as regiões delimitadas pelo retângulo vermelho).

No entanto, apesar do melhor desempenho da condição de imagem com amplitude verdadeira (1) no imageamento das estruturas do modelo do Marmousi, efeitos da abertura limitada dos arranjos de aquisição e variação na iluminação ainda se fazem presentes, sendo necessário aplicar a LSM.

Consequentemente, combinar a condição de imagem de amplitude verdadeira com o imageamento por LSM no domínio da imagem pode ser uma alternativa para mitigar estes efeitos a medida que as vantagens oferecidas por essa condição de imagem sejam preservadas.

Migração por Mínimos Quadrados Dominio da Imagem

A LSM no domínio da imagem consiste em resolver o sistema linear

$$\mathbf{m}_{mig} = \mathbf{H}\mathbf{m}, \quad (5)$$

em que \mathbf{m}_{mig} é a imagem migrada, \mathbf{m} a refletividade verdadeira e \mathbf{H} é a matriz Hessiana. Nos problemas de inversão sísmica linear, a matriz Hessiana é obtida da aproximação de Gauss-Newton $\mathbf{H} = \mathbf{L}^T \mathbf{L}$, sendo \mathbf{L} o operador de modelagem linear e \mathbf{L}^T o seu adjunto.

A equação (5) expressa que a imagem migrada \mathbf{m}_{mig} é obtida a partir de uma relação convolucional entre a refletividade verdadeira \mathbf{m} e a matriz Hessiana \mathbf{H} . A imagem migrada é explicada como uma versão filtrada da refletividade verdadeira, devido ao efeito de borramento provocado pela matriz Hessiana. Para este problema, a função objetivo é estabelecida como

$$J(\mathbf{m}) = \|\mathbf{H}\mathbf{m} - \mathbf{m}_{mig}\|^2, \quad (6)$$

em que a refletividade que minimiza (6) é dada por

$$\mathbf{m} = \mathbf{H}^{-1} \mathbf{m}_{mig}. \quad (7)$$




Figura 1: Imagem migrada RTM. (a) Usando condição de imagem com compensação de amplitude/filtro Laplaciano. (b) Usando condição de imagem com amplitude verdadeira.

Aproximação Born

A equação da onda acústica,

$$\frac{1}{c^2(\mathbf{x})} \frac{\partial^2 p(\mathbf{x}, t)}{\partial t^2} = \nabla^2 p(\mathbf{x}, t) + f(t, \mathbf{x}), \quad (8)$$

apresenta uma relação não linear entre a velocidade de propagação $c(\mathbf{x})$ e campo de onda $p(\mathbf{x}, t)$. Essa é a expressão que comumente governa o operador de modelagem nos problemas da RTM, mas sua aplicabilidade no problema da LSM requer sua forma linearizada. A aproximação Born é a forma mais usual de se obter linearização do problema direto (Snieder, 2004). Esta aproximação consiste em aplicar uma perturbação de primeira ordem no parâmetro físico do meio, no caso a velocidade de propagação $c(\mathbf{x})$,

$$c(\mathbf{x}) = c_0(\mathbf{x}) + \delta c(\mathbf{x}), \quad (9)$$

a qual provoca uma perturbação no campo de onda proporcional a δp

$$p(t, \mathbf{x}) = p_0(t, \mathbf{x}) + \delta p(t, \mathbf{x}). \quad (10)$$

Substituindo as perturbações (9) e (10) na equação da onda (8), e considerando que estamos interessados somente no espalhamento primário do campo de onda, os termos de perturbações superiores à primeira ordem podem ser negligenciados (Tarantola, 2005). Supondo ainda que o campo $p_0(t, \mathbf{x})$ satisfaz uma equação da onda com distribuição de velocidade $c_0(\mathbf{x})$ e a mesma fonte da equação (8), podemos concluir que as perturbações tem que satisfazer

$$\frac{1}{c_0^2(\mathbf{x})} \frac{\partial^2 \delta p(t, \mathbf{x})}{\partial t^2} - \nabla^2 \delta p(t, \mathbf{x}) = \frac{2\delta c(\mathbf{x})}{c_0^3(\mathbf{x})} \frac{\partial^2 p_0(t, \mathbf{x})}{\partial t^2}. \quad (11)$$

A expressão (11) corresponde à equação da onda linearizada formulada a partir da chamada aproximação de Born. Esta governa a aplicação do operador de

modelagem L nos problemas de inversão sísmica linear. A linearização corresponde ao fato de que uma perturbação no parâmetro do modelo, referente ao termo fonte (lado direito de 11), gera uma perturbação no campo de onda ($\delta p(t, \mathbf{x})$).

Aproximação da matriz Hessiana via Point Spread Function

A utilização das point spread functions (PSFs) como aproximação da matriz Hessiana é mais intuitivo e comparativo que matemático. Do ponto de vista óptico, a PSF é definida como sendo a resposta ao impulso de um sistema óptico focalizado. Dado um objeto pontual, a resposta impulsiva, quando este é submetido a um sistema focal, refere-se a um ponto desfocalizado, cujo desfoque é configurado pela PSF. Este ponto borrado é resultado da convolução entre o objeto e a função de borramento, a chamada PSF do sistema óptico. Removido o efeito da função de borramento, a imagem do objeto apresenta maior resolução.

Por analogia, a equação (5) expressa exatamente o mesmo resultado. Cada ponto na imagem migrada \mathbf{m}_{mig} é resultado da convolução entre a refletividade de ponto único \mathbf{m} com a matriz Hessiana \mathbf{H} . O ponto imagem migrado refere-se a uma versão borrada do ponto de refletividade, cuja função de borramento é definida pela matriz Hessiana (Valenciano, 2008) e Lecomte (2008).

No imageamento sísmico, a PSF é obtida da resposta ao impulso da modelagem seguida da migração, como esquematiza a Figura 2.




Figura 2: Esquema para estimativa numérica da PSF. Um valor pontual de velocidade $c(\mathbf{x})$ é modelado e o dado é posteriormente migrado, o resultado é a PSF.

Na prática, as PSFs são obtidas da seguinte forma:

- 1- Amostra-se uma malha, regular ou não, de pontos espalhadores de valores de perturbações de velocidade, e esta é dada como modelo para a modelagem Born (11).
- 2 - O dado Born é migrado através de um modelo de velocidade suavizado, o mesmo utilizado para o termo fonte da modelagem Born (c_0) e para a migração do dado sísmico (para coerência na solução do sistema linear (5)), como resultado temos as PSFs.




Figura 3: PSF para uma malha regular de pontos difratores. (a) Pontos difratores. (b) Respostas PSFs.

A Figura (3) exemplifica as PSFs, obtidas para uma malha

de pontos amostrados regularmente. Cada PSF expressa a matriz Hessiana associada àquele mesmo ponto na imagem migrada. As PSFs para os pontos que não são amostrados na malha são obtidas a partir de técnicas de interpolação.

Deconvolução da Imagem Migrada

A LSM no domínio da imagem é caracterizada como um processo deconvolucional. O objetivo é remover o efeito de borramento provocado pela matriz Hessiana na imagem migrada através da solução iterativa do sistema linear (5). Mas, para oferecer bons resultados, a utilização das PSFs como aproximação da matriz Hessiana requer aplicação de janelamento e de interpolação.

Janelamento das Point Spread Functions

Experimentos preliminares mostraram que a extração de uma PSF e utilização direta no algoritmo de otimização gera imagens deconvolvidas com artefatos ruidosos e descontinuidades, à medida que se busca um melhor ajuste da função objetivo (6). A aplicação de janelamento nas PSFs para suavização das bordas pode mitigar esses efeitos. Neste trabalho utilizamos a janela Nuttall para este finalidade (Heinzel et al., 2002).

Considerando l_x e l_z os espaçamentos horizontal e vertical entre as PSF na malha, a janela de amostragem de uma PSF deve ser uma fração desses espaçamentos, escolhida de modo que não seja grande o suficiente para apresentar contribuição da PSF vizinha, e não tão pequena de modo que valores da PSF sejam negligenciados.

A amostragem da janela não é geral, uma vez que o tamanho e formato de cada PSF dependem da iluminação da fonte e do valor de velocidade no ponto espalhador.




Figura 4: Janelamento das PSFs. (a) Desenho esquemático da janela, em que J_z e J_x é uma fração do espaçamento l_z e l_x entre as PSF da malha. (b) PSFs sem janelamento. (c) PSFs janeladas.

Neste trabalho, utilizamos um janelamento radial das PSFs. Para estimativa do raio da janela, como o ponto central de cada PSF é conhecido, calculamos o raio de dispersão que concentra maior energia da PSF (σ_r) através da média harmônica ponderada da distância radial

$(r_{i,j})$, utilizando como ponderação o valor absoluto da amplitude da PSF ($R_{i,j}$), ou seja,

$$\sigma_r \equiv \frac{\sum |R_{i,j}|}{\sum |R_{i,j}|/r_{i,j}}, \quad (12)$$

em que $r_{i,j} = \sqrt{x_{i,j}^2 + z_{i,j}^2}$. Para que toda a PSF seja janelada, não somente a região de maior energia, devemos requerer que o raio da janela seja maior que o raio de dispersão de máxima energia da PSF. Aqui, adotamos para o raio da janela o dobro do raio de dispersão máxima da PSF.

A Figura 4 mostra de forma esquemática os elementos necessários para o janelamento radial da PSF e o resultado da aplicação da janela Nuttall para um plano imagem de PSFs.

Interpolação das Point Spread Functions

Neste trabalho, usamos a interpolação bilinear para estimativa das PSFs nos pontos da malha nos quais estas não são amostradas. Dado um ponto no espaço da imagem migrada que não possua uma PSF associada, a implementação consiste em localizar, no plano das PSFs, as quatro PSFs em torno desse ponto para serem utilizadas na estimativa da PSF a ser interpolada, como esquematiza a Figura 5.




Figura 5: Esquema para interpolação bilinear da PSF $R(\mathbf{x}, \mathbf{z})$ para os pontos que esta não é amostrada na malha.

Para interpolar uma PSF com centro na posição \mathbf{x} , utilizamos a interpolação bilinear, usamos

$$\begin{aligned} R(\mathbf{x} + \Delta\mathbf{x}) &= \frac{(x_3 - x)}{L_x} \frac{(z_2 - z)}{L_z} R_1(\mathbf{x}_1 + \Delta\mathbf{x}) \\ &+ \frac{(x_4 - x)}{L_x} \frac{(z - z_1)}{L_z} R_2(\mathbf{x}_2 + \Delta\mathbf{x}) \\ &+ \frac{(x - x_1)}{L_x} \frac{(z_2 - z)}{L_z} R_3(\mathbf{x}_3 + \Delta\mathbf{x}) \\ &+ \frac{(x - x_2)}{L_x} \frac{(z - z_1)}{L_z} R_4(\mathbf{x}_4 + \Delta\mathbf{x}), \quad (13) \end{aligned}$$

em que os vetores $\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3$ e \mathbf{x}_4 , a partir de cada um dos centros, referem-se à origem das respectivas PSFs e $\Delta\mathbf{x}$ um mesmo deslocamento desta posição.

Atualização do modelo

O modelo, i.e., a imagem deconvolvida, é obtido através da solução iterativa do sistema linear (5). reescrito abaixo.

Neste trabalho, a solução foi obtida através do algoritmo de otimização Gradiente Conjugado. Para sanar o efeito do mal-condicionamento aplicamos uma formas simples de regularização, que consiste em adicionar um fator de amortecimento λ que penaliza o aumento dos valores da solução. Sob essas condições, o sistema linear (5) pode ser reescrito como

$$\begin{bmatrix} \mathbf{H} \\ \lambda \mathbf{I} \end{bmatrix} \mathbf{m} = \begin{bmatrix} \mathbf{m}_{mig} \\ 0 \end{bmatrix}. \quad (14)$$

Na equação (14), quanto menor o valor do parâmetro λ , o algoritmo de otimização busca oferecer um melhor ajuste entre as imagens da função objetivo (6). Por outro lado, um valor muito pequeno de λ pode gerar imagens ruins devido a busca de um ajuste que não pode ser explicado pela imagem migrada ou pela matriz Hessiana. Aqui, o valor ótimo de λ foi testado manualmente.

A cada iteração do algoritmo do Gradiente Conjugado, o sistema linear (14) é resolvido. Para isto, cada ponto na imagem migrada utiliza a PSF correspondente àquele ponto, caracterizando-se como uma linha da matriz Hessiana. Para os pontos nos quais não foram geradas PSFs, a interpolação é aplicada (durante a solução do sistema linear). O resultado é o modelo \mathbf{m} que melhor ajusta a função objetivo (6), também chamado de imagem migrada deconvolvida, Figura 6.




Figura 6: Representação do problema da LSM no domínio da imagem. Conhecidas a imagem migrada e a matriz Hessiana, a imagem migrada deconvolvida pode ser obtida.

Resultados

Utilizamos o dado sintético do modelo Marmousi para testar a nossa implementação da LSM no domínio da imagem de acordo com a metodologia discutida nas seções anteriores. A solução do sistema linear (14) para a LSM com condição de imagem com compensação de amplitude/filtro Laplaciano teve como entrada \mathbf{m}_{mig} a imagem migrada da Figura 1.a e para a LSM com condição de imagem com amplitude verdadeira usamos a imagem migrada da Figura 1.b. As PSFs das Figuras 7.a e 7.b são as entradas \mathbf{H} para as respectivas LSMs.

Como resultado obtivemos as respectivas imagens migradas deconvolvidas, Figuras 8.a e 8.b




Figura 7: PSFs para uma malha regular com valores de perturbação de velocidade do modelo Marmousi. (a) PSFs usando condição de imagem com compensação de amplitude filtro Laplaciano. (b) PSFs usando condição de imagem com amplitude verdadeira.




Figura 8: Resultado da LSM do modelo Marmousi. (a) Imagem migrada deconvolvida usando condição de imagem com compensação de amplitude filtro Laplaciano. (b) Imagem migrada deconvolvida usando condição de imagem com amplitude verdadeira.

Para os dois resultados da LSM, as imagens migradas deconvolvidas (Figuras 8.a e 8.b) apresentam maior resolução que as respectivas imagens migradas convencionalmente (Figuras 1.a e 1.b) mostrando que o efeito de borramento da matriz Hessiana foi diminuído durante o processo de deconvolucional.

Quando comparamos as imagens migradas deconvolvidas, é possível notar que a imagem deconvolvida resultante da LSM utilizando condição de imagem com amplitude verdadeira apresenta melhores

resultados que a imagem deconvolvida com a LSM utilizando condição de imagem com compensação de amplitude/filtro Laplaciano. Notamos que a imagem deconvolvida com a nossa proposta, além da melhora de resolução devido ao uso da LSM, apresenta preservação de amplitudes mesmo com o aumento da profundidade, compare as regiões delimitadas pelo retângulo branco. O efeito contrário é observado quando utilizamos a condição de imagem com compensação de amplitude/filtro Laplaciano.

Fatores que interferem na LSM

Os resultados das deconvoluções mostrados na seção anterior dependeram do ajuste de três fatores: aplicação de janelamento nas PSFs, espaçamento entre as PSFs e do parâmetro de amortecimento λ da solução. O efeito de cada um desses fatores na deconvolução é mostrado a seguir apenas para a LSM com condição de imagem com amplitude verdadeira.

Aplicação de janelamento nas PSFs

A Figura 9 apresenta o efeito produzido na imagem deconvolvida de acordo com a aplicação ou não do janelamento nas PSFs.




Figura 9: Efeito do janelamento das PSFs sobre a imagem migrada deconvolvida. (a) Sem janelamento Nuttall radial. (b) Com janelamento Nuttall radial.

A Figura 9 permite concluir que a aplicação de janelamento nas PSFs produz imagens deconvolvidas com maior resolução (compare as regiões indicadas pelos retângulos brancos) e melhor posicionamento dos refletores (compare as regiões indicadas pelas setas).

Espaçamento entre as PSFs

Espera-se que quanto menor o espaçamento entre as PSFs, melhor o resultado da deconvolução, já que informação mais acurada da Hessiana é utilizada. A Figura 10 mostra o efeito provocado na deconvolução da imagem migrada devido ao espaçamento entre as PSFs.




Figura 10: Efeito do janelamento entre as PSFs sobre a imagem migrada deconvolvida. (a) PSFs espaçadas de 250 metros. (b) PSFs espaçadas de 500 metros.

A Figura 10 mostra uma pequena melhora oferecida pelo

menor espaçamento entre as PSFs (observe as regiões indicadas pelas setas). Nessa região, o contraste abrupto de velocidade entre a camada salina e o sedimento é melhor explicado pelas PSFs de menor espaçamento, resultando na melhor localização do refletor. Podemos supor que a escolha do espaçamento entre as PSFs depende da complexidade do modelo. Quanto maior a variação, menor deve ser este espaçamento, desde que uma PSF não interfira na outra.

Os resultados das deconvoluções apresentados na Figura 8 são referentes ao espaçamento de 250 metros entre as PSFs. Isto demandou de uma maior custo computacional devido as PSFs terem sido estimadas para diferentes grids alternados do modelo. Para cada grid, uma modelagem e uma migração são realizadas. Isto é necessário para garantir que em um grid não haverá interferência entre as PSFs devido estarem muito próximas o suficiente umas das outras.

Fator de amortecimento λ na solução

A Figura 11 mostra o efeito provocado na imagem deconvolvida dependendo da escolha do parâmetro de amortecimento λ no sistema linear (apenas um detalhe da imagem é considerado).




Figura 11: Efeito da escolha do parâmetro de amortecimento λ da solução sobre a imagem migrada deconvolvida.

Quanto menor o valor de λ , mais a função objetivo é ajustada. No nosso problema, esse maior ajuste resulta em maior resolução da imagem deconvolvida. No entanto, quando λ é muito pequeno, a tentativa de um maior ajuste pode resultar em obstrução na imagem deconvolvida. Efeito de bordas podem surgir, bem como ruído na imagem (seta na imagem com $\lambda = 0.05$) devido a tentativa de ajuste de informações não explicadas pela matriz Hessiana. Os resultados das deconvoluções apresentados na Figura 8 são referentes à $\lambda = 0.20$.

Conclusão

Neste trabalho, propusemos a aplicação da LSM no domínio da imagem a partir da migração RTM com amplitude verdadeira. Nossos experimentos numéricos indicam que a abordagem proposta, quando comparada à LSM usando condição de imagem com compensação de amplitude/filtro Laplaciano, produz imagens migradas com maior qualidade de imageamento.

Mostramos que o resultado da LSM depende, além da

condição de imagem para RTM, da escolha de outros parâmetros: janelamento das PSFs, densidade das PSFs na malha de discretização do modelo e da regularização do sistema linear utilizado para deconvolver a imagem migrada. Utilizamos janelamento Nuttall radial das PSFs.

Obtivemos melhores resultados efetuando a estimativa do raio de dispersão da PSF através da média harmônica ponderada da distância radial, utilizando como ponderação o valor absoluto da amplitude da PSF.

Mostramos também que, quanto maior a densidade das PSFs na malha melhor a qualidade da imagem e maior o custo computacional. Neste trabalho efetuamos experimentos numéricos para avaliar a menor densidade de PSFs que não degrada a imagem e utilizamos interpolação bilinear para reduzir o número de PSFs necessárias sem comprometer a qualidade da imagem.

Finalmente, o parâmetro de regularização, que modula o amortecimento na solução do sistema linear, também afeta a resolução das imagens migradas. Quanto menor o parâmetro de regularização maior a resolução da imagem migrada, mas quando muito pequeno produz artefatos que degradam a imagem. A seleção do parâmetro de regularização, portanto, depende dos objetivos do interprete em relação à resolução desejada para a imagem.

Referências

- Biondi, B. L., 2006, 3d seismic imaging: Society of Exploration Geophysicists.
- Claerbout, J. F., 1985, Imaging the earth's interior: Blackwell scientific publications Oxford, 1.
- Fletcher, R. P., D. Nichols, R. Bloor, and R. T. Coates, 2016, Least-squares migration—data domain versus image domain using point spread functions: The Leading Edge, 35, 157–162.
- Heinzel, G., A. Rüdiger, and R. Schilling, 2002, Spectrum and spectral density estimation by the discrete fourier transform (dft), including a comprehensive list of window functions and some new at-top windows.
- Lecomte, I., 2008, Resolution and illumination analyses in psdm: A ray-based approach: The Leading Edge, 27, 650–663.
- Nemeth, T., C. Wu, and G. T. Schuster, 1999, Least-squares migration of incomplete reflection data: Geophysics, 64, 208–221.
- Op't Root, T. J., C. C. Stolk, and V. Maarten, 2012, Linearized inverse scattering based on seismic reverse time migration: Journal de mathématiques pures et appliquées, 98, 211–238.
- Prucha, M. L., and B. L. Biondi, 2002, Subsalt event regularization with steering filters, in SEG Technical Program Expanded Abstracts 2002: Society of Exploration Geophysicists, 1176–1179.
- Schuster, G. T., 2017, Seismic inversion: Society of Exploration Geophysicists.
- Snieder, R., 2004, A guided tour of mathematical methods for the physical sciences: Cambridge University Press.
- Tarantola, A., 2005, Inverse problem theory and methods for model parameter estimation: siam, 89.
- Valenciano, A. A., 2008, Imaging by wave-equation inversion: Citeseer, 69.