

Determinação do campo de velocidades de empilhamento utilizando o algoritmo genético

Danian S. Oliveira* Milton J. Porsani** Paulo E. M. Cunha*, *Petrobrás **CPGG/UFBA e INCT-GP/CNPQ

Copyright 2012, SBGF - Sociedade Brasileira de Geofísica Este texto foi preparado para a apresentação no V Simpósio Brasileiro de Geofísica, Salvador, 27 a 29 de novembro de 2012. Seu conteúdo foi revisado pelo Comitê Técnico do V SimBGF, mas não necessariamente representa a opinião da SBGF ou de seus associados. É proibida a reprodução total ou parcial deste material para propósitos comerciais sem prévia autorização da SBGF.

RESUMO

Foi desenvolvida uma estratégia de *pick* automático dos painéis de *Seblance* que utiliza o método de otimização Algoritmo Genético. A estratégia geral foi baseada em Lumley (1997), que utilizou o Método de Monte Carlo para gerar os modelos aleatórios candidatos ao melhor campo de velocidade. O método de busca global Algoritmo Genético, utilizado neste trabalho, provou ser superior a métodos puramente estatísticos como o método de Monte Carlo por utilizar uma regra de probabilidade para guiar suas buscas entre os modelos dos parâmetros (Sen and Stoffa, 1995). Em conjunto com restrições e penalidades definidas a partir de informação *a priori* obteve-se como resultado um ajuste não linear das velocidades intervalares que convertidas em velocidades *Root Mean Square (RMS)*, melhor maximizam a soma do grupo *Common Mid Point (CMP)* corrigido de *Normal Moveout (NMO)*.

INTRODUÇÃO

Atualmente o bom imageamento de refletores profundos, em especial nas bacias brasileiras, abaixo da camada de sal, tem se mostrado um grande desafio. A obtenção de um campo de velocidades sísmicas que corresponda ao máximo à geologia em subsuperfície e que resulte em uma imagem sísmica focalizada é o principal alvo da etapa de processamento sísmico.

Na última década, a tomografia de reflexão se consolidou como um dos principais métodos de construção do modelo de velocidades para migração de dados sísmicos (Delost et al., 2008). Em um ambiente geológico complexo a tomografia de reflexão mostrou bons resultados na determinação do campo de velocidades sísmicas (Clapp et al., 2004).

Em contrapartida a inversão sísmica pela forma completa da onda (*FWI*) tomou fôlego devido aos avanços

recentes na computação que viabilizaram a utilização desta técnica para a inversão dos modelos de velocidades 2D e 3D (Virieux and Operto, 2009) e também devido à grande sucesso em cenários geologicamente complexos (Pratt et al., 1998; Jaiswal et al., 2009).

Porém Gao et al. (2007) considera a tomografia de tempos de trânsito mais robusta do que tomografia da forma completa de onda (*FWI*) porque as perturbações dos tempos de trânsito são muito menos sensíveis às variações de velocidade do que as perturbações de forma de onda. Sem um modelo de velocidades inicial bastante preciso é mais provável que a esta última dê resultados espúrios, principalmente por causa da natureza altamente não linear da inversão da forma de onda sísmica.

Apesar da análise de velocidade de empilhamento ser, entre estes, o método menos preciso para gerar campo de velocidade ele ainda é utilizado em larga escala pelas principais indústrias de petróleo e de processamento sísmico por ser um método barato e que pode fornecer um bom campo de velocidades inicial para os métodos de tomografia e *FWI*.

METODOLOGIA

O problema principal a ser resolvido gira em torno dos painéis de *Seblance*. Estes painéis são gerados pela correção *normal move out* (Castle, 1994),

$$\Delta t_{nmo} = t_{nmo} - t_0, \quad (1)$$

onde

$$t_{nmo} = t_0 \sqrt{1 + \left(\frac{\Delta \mathbf{x}}{v t_0} \right)^2}, \quad (2)$$

dos grupos *CMP* com diversas velocidades constantes. Estes valores de amplitudes são normalizados pela equação do *Seblance* (Key and Smithson, 1990).

$$NE = \frac{1}{m} \frac{\sum_{n=1} \sum_{i=1} \mathbf{f}_{i,n}}{\sqrt{\sum_{n=1} \sum_{i=1} \mathbf{f}_{i,n}^2}} \quad (3)$$

O método de otimização de busca global algoritmo genético, utilizado para a interpretação automática do *Seblance* gera uma população inicial de modelos de velocidades

intervalares e converte os valores do espaço do parâmetros em binários onde o número de *bits* da cadeia binária possui uma relação (equação 4) com o número de parâmetros do modelo.

$$npar = nbits^2 - 1 \quad (4)$$

Parâmetro	Valor	Posição	Valor binário
v	1500m/s	1	00
	2000m/s	2	01
	2500m/s	3	11

Tabela 1: Exemplo de codificação binária do parâmetro velocidade

A característica principal do Algoritmo Genético é a aplicação de três procedimentos sobre os modelos da população inicial, que visam gerar as modelos descendentes, melhores que os da população inicial. Isto faz com que haja uma rápida convergência para solução. Os três processos são:

- seleção
- cruzamento
- mutação

A avaliação dos modelos da população inicial bem como dos modelos descendentes é chamada de *fitness* (aptidão). Este valor controla se um modelo descendente é aceito ou rejeitado.

Este método foi utilizado em duas etapas. A primeira foi denominada inversão linear (Figura 5), onde se ajusta uma função de velocidades *RMS* que maximiza a integração do *Semblance*.

$$v = v0 + \alpha t^\beta \quad (5)$$

Os valores a serem invertidos são $v0$, que representa a velocidade inicial ou de superfície da água, o gradiente da velocidade (α) e β , que pode ser entendido como a curvatura da função velocidade.

A função velocidade *RMS* construída nesta etapa (Figura 6) se torna a guia utilizada para definir o espaço dos modelos do ajuste não linear. Clapp et al. (1998) faz uma interpolação do campo de velocidades *RMS* interpretado na forma convencional, utilizando o *Semblance* como pesos para valorizar os eventos coerentes. De forma semelhante foi utilizado os valores do *Semblance* para restringir o número de soluções do espaço nulo deste problema inverso não linear (Figura 7).

A segunda etapa da inversão realiza o ajuste não linear do *Semblance* (Figura 8). A partir da função guia são

gerados vários modelos aleatórios de velocidades intervalares em tempo. É feita a medida do *fitness* destes modelos e, então, estes sofrem os processos do Algoritmo Genético em n iterações até que algum critério de parada seja satisfeito.

Esta metodologia foi aplicada em dois modelos de velocidades 1D, um modelo de 4 camadas (figura 1) e outro de 16 camadas (figura 5), para avaliar os algoritmos gerados em Fortran.

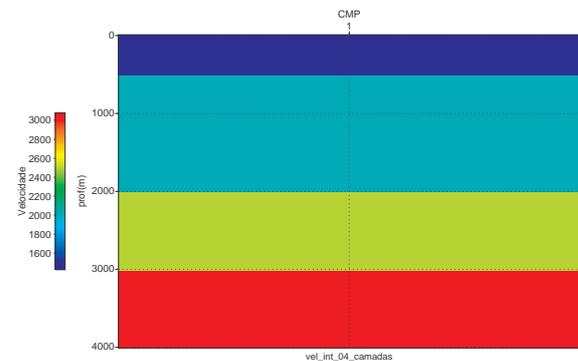


Figura 1: Modelo de velocidades intervalar de 04 camadas.

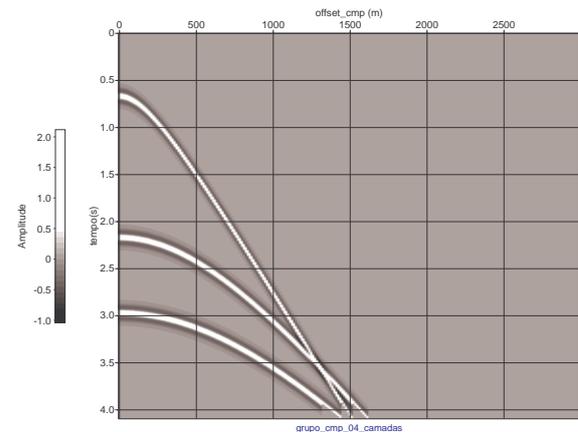


Figura 2: Grupo *CMP* modelado analiticamente.

Os grupos de *CMP* foram geradas pela convolução de um pulso *Ricker* de 20 *Hertz* com deltas de *Dirac* posicionados nos tempo de trânsito calculados analiticamente pela equação de *NMO* (figura 2 e 6).

RESULTADOS

O resultado final é um campo de velocidades *RMS* que melhor ajusta o *Semblance* segundo os critérios definidos anteriormente.

O ajuste linear é representado pelas figuras 5 e 11. As curvas pretas representam as velocidades *RMS* e as vermelhas, as velocidades intervalares em tempo. Esta úl-

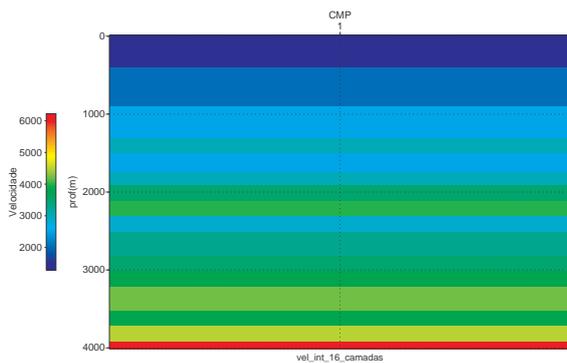


Figura 3: Modelo de velocidades intervalar de 16 camadas.

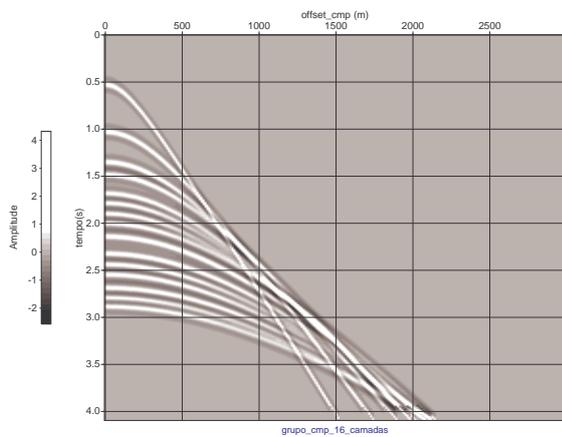


Figura 4: Grupo *CMP* modelado analiticamente.

tima define a função guia, limite do espaço de modelos (figuras 6 e 12), que pode ser condicionada pelo *Semblance* (figuras 7 e 13).

O ajuste não linear realizado nestes modelos (figuras 8 e 14) utiliza duas informações *a priori*: os tempos de reflexão *zero-offset* do fundo do mar e do embasamento (último evento de reflexão) e o número de velocidades intervalares que se deseja inverter.

Esta última informação *a priori* foi definida como sendo o número de camadas verdadeiro para cada modelo.

As curvas de convergência das figuras 9 e 15 mostram os *fitness* normalizados das populações geradas em cada iteração. A curva vermelha representa os modelos mais aptos enquanto que a de cor azul os modelos de menor aptidão, e a curva verde é a média das duas anteriores.

DISCUSSÃO E CONCLUSÕES

Foi apresentado uma metodologia para geração automática do campo de velocidades de empilhamento através do ajuste não linear dos painéis de *Semblance*. As velocidades invertidas podem ser comparadas com os funções

velocidades verdadeiras (figuras 9 e 15).

Apesar das limitações do método, os resultados apresentados mostram que os algoritmos utilizados são robustos e eficientes para alcançar o objetivo proposto.

AGRADECIMENTOS

Agradecemos à PETROBRAS e ao CNPq/INCT-GP pelo apoio a esta pesquisa.

REFERÊNCIAS

- Castle, R. J., 1994, A theory of normal moveout: Geophysics, **59**, 983–999.
- Clapp, R. G., Sava, P., and Claerbout, J. F., 1998, Interval velocity estimation with a null-space: SEP Report, **97**, 147–157.
- Clapp, R. G., , and et al., 2004, Incorporating geologic information into reflection tomography: Geophysics, **69**, no. 2.
- Delost, M., , and et al., 2008, First-arrival traveltome tomography using second generation wavelets: Geoph. Prosp., **56**, 505–526.
- Gao, F., , and et al., 2007, Waveform tomography at a groundwater contamination site: Surface reflection data: Geophysics, **72**, no. 5, G45–G55.
- Jaiswal, P., , and et al., 2009, Seismic imaging of the naga thrust using multiscale waveform inversion: Geophysics, **74**, no. 6.
- Key, S. C., and Smithson, S. B., 1990, New approach to seismic-reflection event detection and velocity determination: Geophysics, **55**, 1057–1069.
- Lumley, D. E., 1997, Monte carlo automatic velocity picks: SEP Report, **75**, 1–25.
- Pratt, R. G., , and et al., 1998, Gauss-newton and full-newton methods in frequency-space seismic waveform inversion: Geophys. J. Int., , no. 133, 341–362.
- Sen, M., and Stoffa, P. L., 1995, Global optimization methods in geophysical inversion, volume 4 of **Advances in Exploration Geophysics** Elsevier, Amsterdam.
- Virieux, J., and Operto, S., 2009, An overview of full-waveform inversion in exploration geophysics: Geophysics, **74**, no. 6.

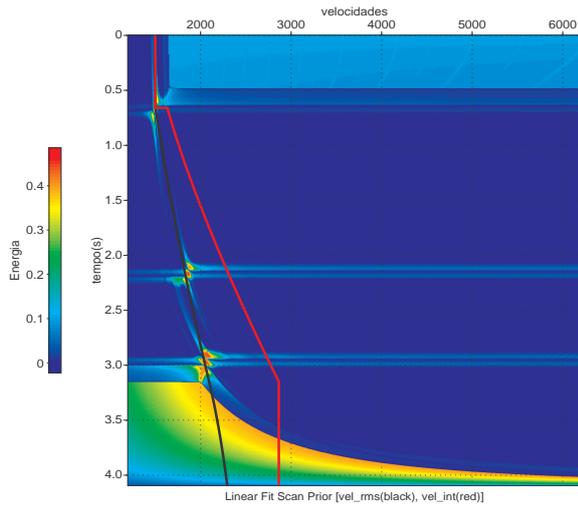


Figura 5: Ajuste linear do modelo de 04 camadas.

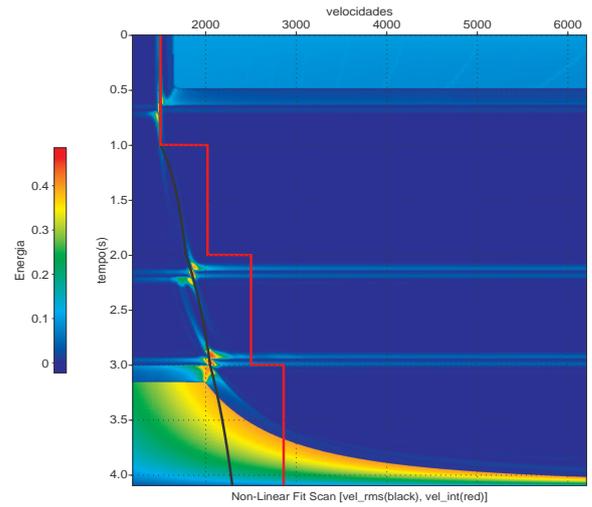


Figura 8: Ajuste não linear do modelo de 04 camadas

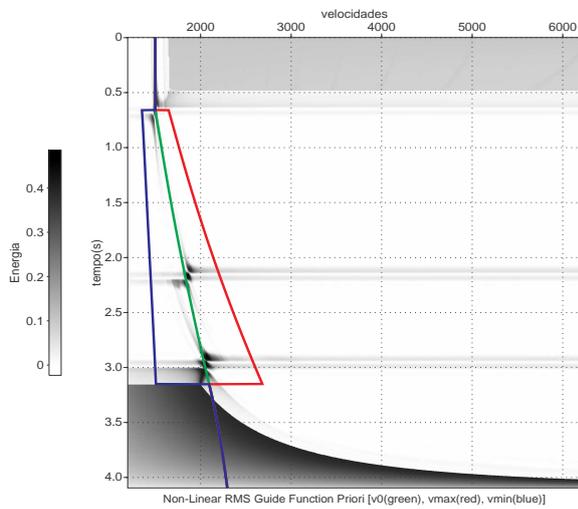


Figura 6: Espaço de modelos gerados a partir da função guia.

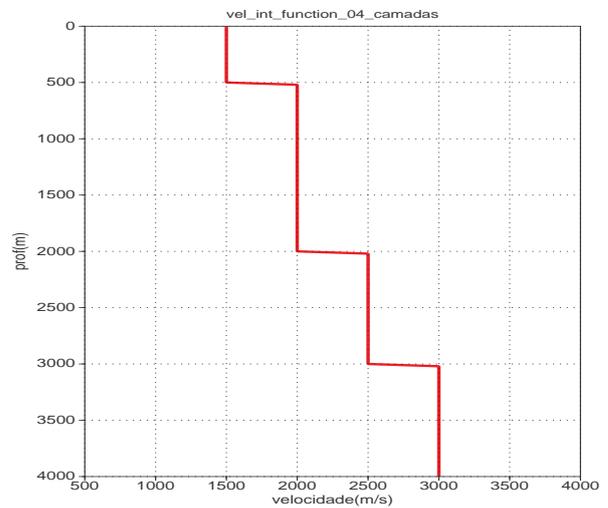


Figura 9: Função velocidade intervalar em profundidade verdadeira

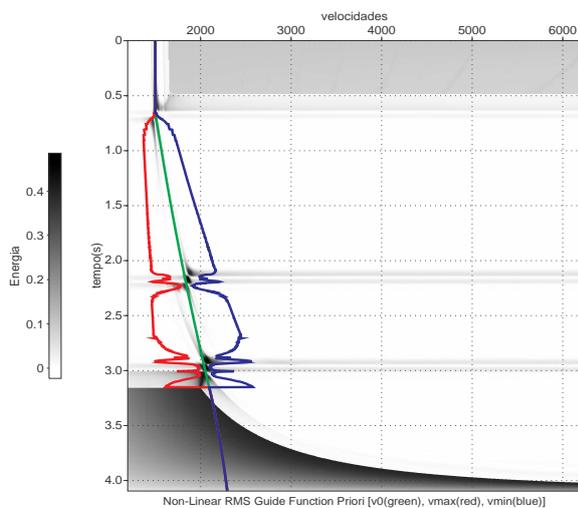


Figura 7: Espaço de modelos ponderados pelo *Semblance*.

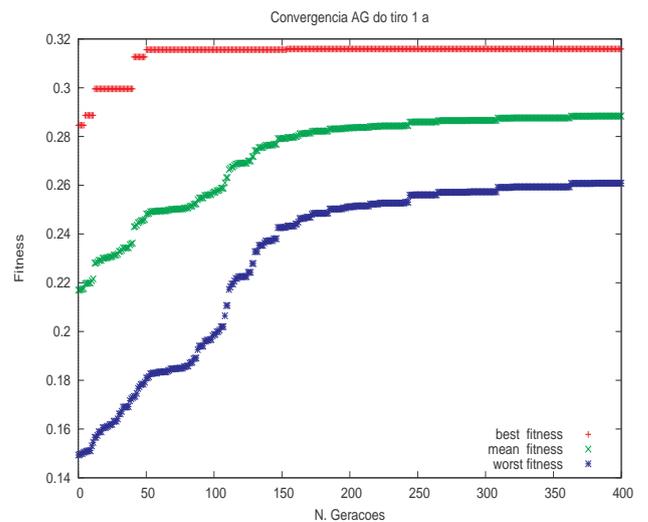


Figura 10: Curva de convergência do modelo de 04 camadas

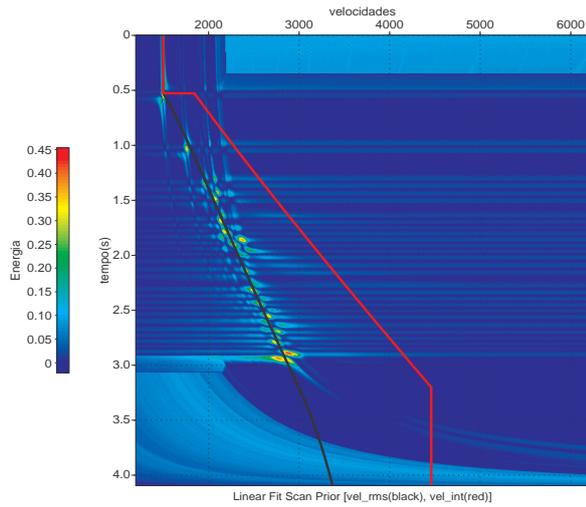


Figura 11: Ajuste linear do modelo de 16 camadas.

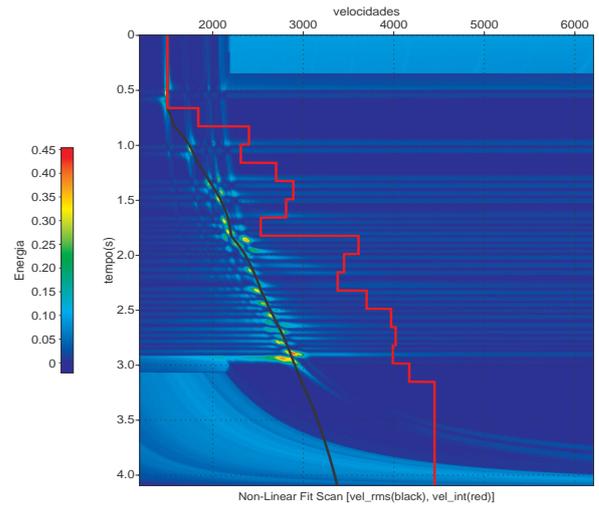


Figura 14: Ajuste não linear do modelo de 16 camadas

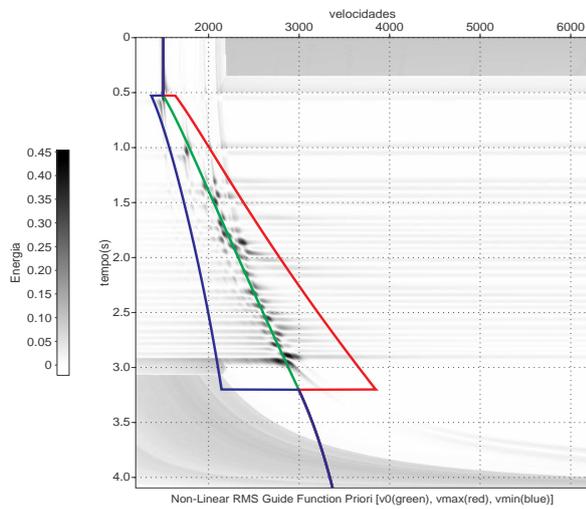


Figura 12: Espaço de modelos gerados a partir da função guia.

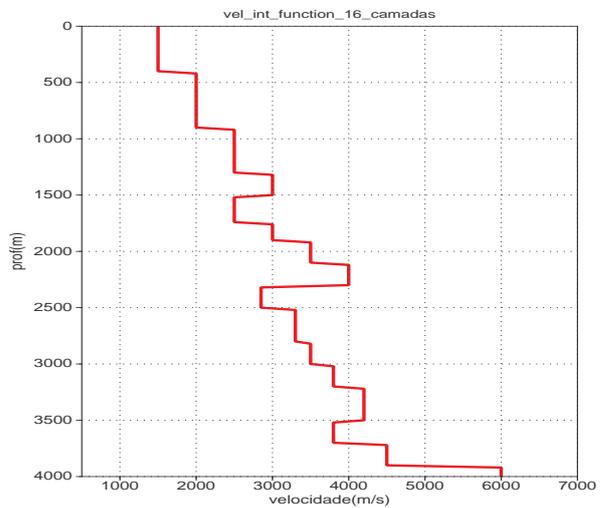


Figura 15: Função velocidade intervalar em profundidade verdadeira

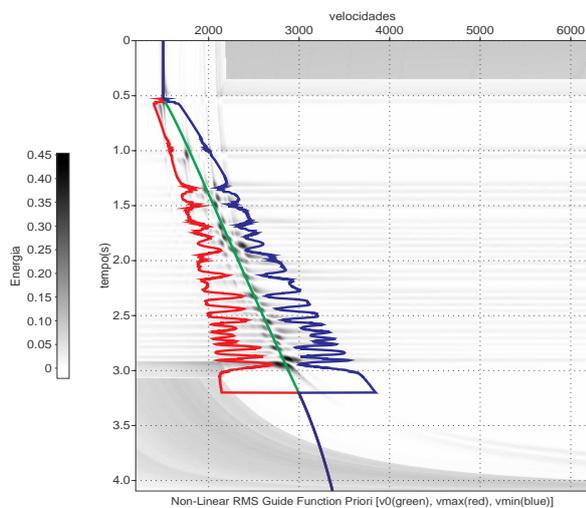


Figura 13: Espaço de modelos ponderados pelo *Semblance*.

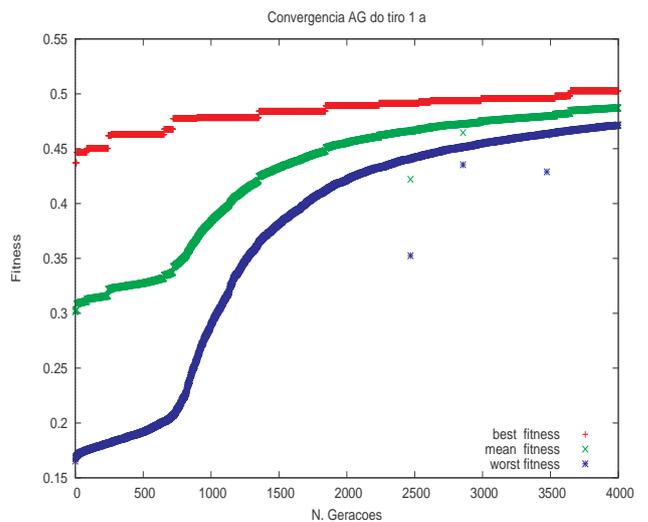


Figura 16: Curva de convergência do modelo de 16 camadas