



**UNIVERSIDADE FEDERAL DO PARÁ**

**CENTRO DE GEOCIÊNCIAS**

**CURSO DE PÓS-GRADUAÇÃO EM GEOFÍSICA**

**DISSERTAÇÃO DE MESTRADO**

**DETECÇÃO DE REFLETORES SÍSMICOS POR REDE NEURAL  
DISCRETA**

**ALEXANDRE BELTRÃO FERREIRA**

**BELÉM  
2000**



UNIVERSIDADE FEDERAL DO PARÁ  
CENTRO DE GEOCIÊNCIAS  
CURSO DE PÓS-GRADUAÇÃO EM GEOFÍSICA

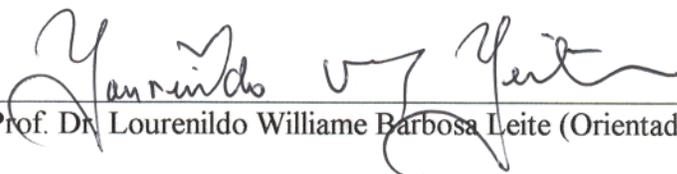
**DETECÇÃO DE REFLETORES SÍSMICOS POR REDE NEURAL  
DISCRETA**

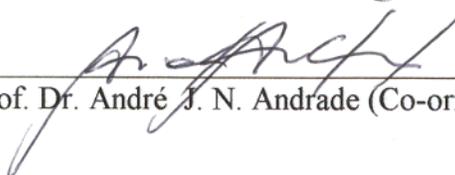
DISSERTAÇÃO APRESENTADA POR  
**ALEXANDRE BELTRÃO FERREIRA**

COMO REQUISITO PARCIAL À OBTENÇÃO DE GRAU DE MESTRE EM CIÊNCIAS NA  
ÁREA DE GEOFÍSICA

Data de aprovação:    /    /1999

**COMITÊ DE TESE:**

  
Prof. Dr. Lourenildo Willame Barbosa Leite (Orientador)

  
Prof. Dr. André J. N. Andrade (Co-orientador)

  
Prof. Dr. Sérgio Luciano Moura Freire

**BELÉM  
1999**

REPRODUTORES BRASILEIRO S/A  
13 SET 10 53 AM  
000000  
000000

## **AGRADECIMENTOS**

Agradeço primeiramente à **Deus** por ter me dado saúde e paz para concluir esse trabalho. Posteriormente agradeço ao meus pais, **João Aberides Ferreira Filho, Adalcira Beltrão Ferreira e Adair Pamplona Beltrão**, pelo incentivo e apoio ao longo dessa jornada. Agradeço também ao meu co-orientador e amigo **André Andrade** por acreditar na minha capacidade intelectual e por ter me orientado durante meu Mestrado em Geofísica. Agradeço ao Coordenado do Centro de Pós-Graduação em Geofísica (CPGf) Prof. João Carlos Ribeiro Cruz, ao Prof. Lourenildo W. B. Leite e ao CNPq pelo suporte em forma de bolsa de estudo. Por fim, gostaria de agradecer aos meus amigos que de alguma forma contribuíram para o meu sucesso.

## SUMÁRIO

<b>AGRADECIMENTOS</b> .....	i
<b>RESUMO</b> .....	1
<b>ABSTRACT</b> .....	2
<b>1-INTRODUÇÃO</b> .....	3
<b>2-DADOS SÍSMICOS DE REFLEXÃO</b> .....	6
2.1-MODELO CONVOLUCIONAL SIMPLES.....	7
2.2-PULSO FONTE.....	8
2.2.1- Propriedades dos pulsos fonte.....	10
2.3-FUNÇÃO REFLETIVIDADE SIMPLES.....	13
2.4-CÁLCULO DO SISMOGRAMA SINTÉTICO.....	15
2.5-RUÍDOS SÍSMICOS.....	16
2.6-DECONVOLUÇÃO SÍSMICA CLÁSSICA.....	19
2.6.1-Filtro ótimo de Wiener-Hopf.....	19
<b>3 - DECONVOLUÇÃO COM A REDE NEURAL ARTIFICIAL</b> .....	23
3.1 - REDE NEURAL ARTIFICIAL.....	23
3.1.1 - Neurônio artificial.....	24
3.1.2 - Estrutura e classificação geral das redes.....	25
3.2 - REDE NEURAL DE HOPFIELD.....	28
3.2.1 - Neurônio binário.....	29
3.2.2 - Neurônio contínuo.....	31
3.2.3 - Função de Liapunov.....	32
3.3 - MÉTODO DE DECONVOLUÇÃO DE WANG E MENDEL.....	35
3.3.2 - O problema da deconvolução com a rede de Hopfield.....	35
3.3.2.1 - A rede neural para a recuperação da refletividade.....	35
3.3.2.2 - A rede neural para a extração do pulso-fonte.....	39
<b>4 - DECONVOLUÇÃO COM A REDE NEURAL DISCRETA (RND)</b> .....	43
4.1 - POTENCIAL DE ENTRADA OU ATIVAÇÃO.....	43
4.2 - FUNÇÃO DE ATIVAÇÃO.....	43

4.3 - FUNÇÃO DE LIAPUNOV.....	44
4.4 - VARIAÇÃO DA FUNÇÃO DE LIAPUNOV.....	46
<b>5 - RND PARA A RECUPERAÇÃO DA DISTRIBUIÇÃO DOS COEFICIENTES DE REFLEXÃO .....</b>	<b>49</b>
5.1 - PARÂMETROS LIVRES E A FUNÇÃO DE LIAPUNOV.....	49
5.2 - RESULTADOS.....	52
5.2.1 - Pulso fonte de fase-mínima.....	52
5.2.2 - Pulso fonte de fase-máxima.....	64
5.2.3 - Pulso fonte de fase-mista.....	70
5.2.4 - Avaliação do modelo convolucional simples.....	75
5.2.5 - Modelo da teoria do raio.....	77
5.2.6 - Comparação da RND com o filtro ótimo Wiener-Hopf.....	81
<b>6 - CONCLUSÕES.....</b>	<b>83</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>84</b>
<b>I - APÊNDICE A - Demonstração da condição <math>w_{ij} \geq 0</math>.....</b>	<b>86</b>

## RESUMO

As redes neurais artificiais têm provado serem uma poderosa técnica na resolução de uma grande variedade de problemas de otimização. Nesta dissertação é desenvolvida uma nova rede neural, tipo recorrente, sem realimentação (*self-feedback loops*) e sem neurônios ocultos, para o processamento do sinal sísmico, para fornecer a posição temporal, a polaridade e as amplitudes estimadas dos refletores sísmicos, representadas pelos seus coeficientes de reflexão.

A principal característica dessa nova rede neural consiste no tipo de função de ativação utilizada, a qual permite três possíveis estados para o neurônio. Busca-se estimar a posição dos refletores sísmicos e reproduzir as verdadeiras polaridades desses refletores.

A idéia básica desse novo tipo de rede, aqui denominada rede neural discreta (RND), é relacionar uma função objeto, que descreve o problema geofísico, com a função de Liapunov, que descreve a dinâmica da rede neural. Deste modo, a dinâmica da rede leva a uma minimização local da sua função de Liapunov e conseqüentemente leva a uma minimização da função objeto. Assim, com uma codificação conveniente do sinal de saída da rede tem-se uma solução do problema geofísico.

A avaliação operacional da arquitetura desta rede neural artificial é realizada em dados sintéticos gerados através do modelo convolucional simples e da teoria do raio. A razão é para explicar o comportamento da rede com dados contaminados por ruído, e diante de pulsos fonte de fases mínima, máxima e misturada.

## ABSTRACT

The artificial neural networks have proven to be a powerful technique in solving a wide variety of optimization problems. In this work, we develop a new recurrent network, with no self-feedback loops, and no hidden neurons, for seismic signal processing, where this neural network gives the true polarity, reflectors location and magnitude estimations. The main characteristic of this neural network is the use of a type of activation function which permits three possible states of neurons, to estimate the position of the seismic reflectors in such way to reproduce its true polarities.

The basic idea of this new neural network type, denominated here by discrete neural network (DNN), is to relate a cost function, that describes the geophysical problem, with the Liapunov function, that describes the neural network dynamics. In this way, the dynamics of the network leads to a local minimization of the Liapunov function, and will consequently lead to a minimization of the cost function. Thus, with a convenient output signal codification of the neural network a geophysical problem solution is obtained.

The operational evaluation of this neural network architecture is performed with synthetic data obtained through the simple convolutional model and seismic ray theory, and its behavior explained with additive noise in the data with minimum, maximum and mixed phase time source pulses.

## 1-INTRODUÇÃO

O processamento de dados sísmicos de reflexão ocupa um lugar de grande relevância na prospecção de hidrocarbonetos, envolvendo um alto custo computacional em função das suas peculiaridades e da grande quantidade de informação. Assim sendo, o desenvolvimento de algoritmos, com o objetivo de melhorar e acelerar o processamento de dados sísmicos, é de grande importância para a indústria do petróleo.

O uso de redes neurais artificiais no processamento sísmico tem sido apresentado como um novo formalismo para o tratamento desta classe de problemas, com o objetivo de aumentar a velocidade de processamento e de minimizar o custo computacional segundo Wang & Mendel (1992).

Uma rede neural artificial é basicamente uma simulação em computador do funcionamento do cérebro humano, a qual consiste de vários elementos simples de processamento, interligados mutuamente por meio de conexões diretas e ponderadas. Uma das vantagens mais exploradas das redes neurais é a sua utilização para classificar padrões de entradas em diferentes categorias. Hoje em dia a variedade de redes neurais artificiais a serem experimentadas é enorme, pois dependendo do modelo de cada neurônio, pode-se ter uma simples soma das entradas desses neurônios, bem como conjuntos complexos de equações diferenciais. A informação a circular na rede pode ser em um único sentido ou em vários. Os neurônios podem ainda ser atualizados simultaneamente ou com intervalos temporais entre eles, resultando assim em um número quase ilimitado de combinações possíveis. Desta forma, uma rede neural pode ser treinada de modo a conhecer um determinado número de padrões de entradas reproduzindo-os em suas saídas, e podendo a mesma ser utilizada para reproduzir o padrão original quando este lhe é apresentado com ruído ou incompleto.

Na geofísica existem problemas que não possuem uma formulação analítica completa. Por exemplo, no processamento sísmico de sinal, encontram-se freqüentemente modelos lineares bastante simples, cuja teoria baseia-se em suposições que na maioria dos casos não são realistas com a natureza física do fenômeno. No entanto, a utilização de modelos simples tem apresentado bons resultados para o tratamento do dado sísmico, onde um exemplo são os filtros deconvolutivos, ou de maneira mais geral, nos filtros de compressão de sinal.

Trabalhos recentes têm mostrado que a arquitetura do processamento paralelo e os algoritmos de redes neurais artificiais possuem grandes vantagens em comparação aos algoritmos tradicionais, Wang & Mendel (1992). Por exemplo, a rede neural de Hopfield tem provado ser uma poderosa técnica na resolução de uma ampla variedade de problemas de otimização [Barbosa, 1989], destacando a sua aplicação baseada em modelos lineares, mas que apresenta resultados de boa qualidade para o tratamento de modelos não lineares.

O objetivo dessa dissertação é apresentar uma nova arquitetura de rede neural do tipo recorrente para o processamento do sinal sísmico, aqui denominada como rede neural discreta. Além disso, apresentar um processamento computacional eficiente, mostrando um resultado satisfatório na localização e na estimativa dos coeficientes de reflexão das descontinuidades sísmicas. A principal característica desta arquitetura de rede é apresentar três estados discretos possíveis para os seus neurônios, em razão da sua particular função de ativação. Isto torna possível a correta detecção das polaridades dos refletores sísmicos.

A idéia básica envolvida nesse processamento é relacionar uma função objeto, que descreve o problema geofísico, com a função de Liapunov, que descreve a dinâmica da rede neural. Deste modo, a dinâmica da rede leva a uma minimização local da função de Liapunov e, conseqüentemente, à minimização da função objeto. A conveniente codificação do sinal de saída da rede leva a uma forma de solução do problema geofísico.

O problema da localização em profundidade, ou no tempo, dos refletores sísmicos, por meio da rede neural discreta, pode ser entendido na forma de um filtro deconvolutivo, da feita que o processo necessita do conhecimento prévio do pulso fonte. A rede neural discreta apresenta uma robustez sensivelmente superior aos filtros convencionais na condição de não-correlacionalidade entre sinal e ruído. Todavia, no que diz respeito à amplitude verdadeira de cada refletor sísmico, este somente é recuperado dependendo do nível de ruído existente no sinal sísmico, visto que quanto maior é o ruído, menor precisão se obtém na estimativa da magnitude dos coeficientes de reflexão.

Neste trabalho avalia-se a qualidade dos resultados e da robustez das respostas da rede neural discreta sobre dados sintéticos, gerados com a teoria convolucional simples e com a teoria do raio.

No Capítulo 2 é apresentado um resumo sucinto das formas de aquisição do dado sísmico, tais como os modelos matemáticos da convolução linear, e o método assintótico de alta

freqüência conhecido como teoria do raio. Apresenta-se também o formalismo tradicional na forma dos filtros de compressão simples de sinal.

No Capítulo 3 é realizado uma abordagem geral das redes, com ênfase na rede neural de Hopfield. Avalia-se ainda o comportamento da deconvolução com a rede de Hopfield segundo o método apresentado por Wang & Mendel (1992).

No Capítulo 4 é feita a apresentação formal da rede neural discreta do tipo recorrente com a conceituação de seus parâmetros livres. É analisado ainda sua convergência para um mínimo local da função de Liapunov.

No Capítulo 5, a rede neural discreta é aplicada para a recuperação da distribuição dos coeficientes de reflexão com a definição conveniente dos específicos parâmetros livres da rede. Avalia-se os resultados sobre dados gerados com o modelo convolucional simples, para os casos com ruído e pulsos fontes variados, e também sobre dados obtidos com a teoria do raio na forma de seções sísmicas de afastamento-nulo (*zero offset*).

No Capítulo 6 é realizada uma avaliação final da aplicação dessa arquitetura de rede para o processamento sísmico de sinais, indicando ainda as possíveis extensões dessa dissertação.

## 2 – DADOS SÍSMICOS DE REFLEXÃO

A sísmica de reflexão é o método geofísico mais utilizado por estar relacionada à prospecção petrolífera e por permitir uma maior resolução. Este método requer a existência de uma fonte artificial projetada para gerar um pulso transiente, que deve possuir energia, conteúdo de frequência, duração, amplitude e fase espectrais, que sejam condizentes com os objetivos da pesquisa ou prospecção. Esta fonte gera uma onda sísmica que incide no meio, retornando em seguida à superfície após a reflexão nas interfaces que marcam mudanças nas propriedades físicas das formações geológicas. O mapeamento da estrutura da subsuperfície é baseado nas medidas dos tempos duplos de reflexão. Os eventos sísmicos refletidos são detectados através de sensores que se encontram distribuídos na superfície. Os sensores podem ser geofones (utilizados em ambientes terrestres) ou hidrofones (para o caso marinho), e eles descrevem no registro a variação temporal dos deslocamentos do solo.

A partir dessa descrição, pode-se resumir que o dado sísmico resulta de um sistema que consiste em três partes principais: uma fonte de entrada, um arranjo de detectores e um sistema registrador habilitado para gravar as informações desses detectores gerando os sismogramas, ou traços sísmicos. Estes traços são utilizados nas operações de processamento de sinais, sendo posteriormente interpretados em relação à posição e intensidade de cada horizonte refletor em subsuperfície. Vale ressaltar que o tratamento dos dados não é simples, na realidade ele requer um alto grau de conhecimento dos princípios básicos da propagação de ondas sísmicas, tais como transmissividade, refletividade, refração, dispersão, estiramento, espalhamento, e atenuação dessas ondas através das camadas estratificadas.

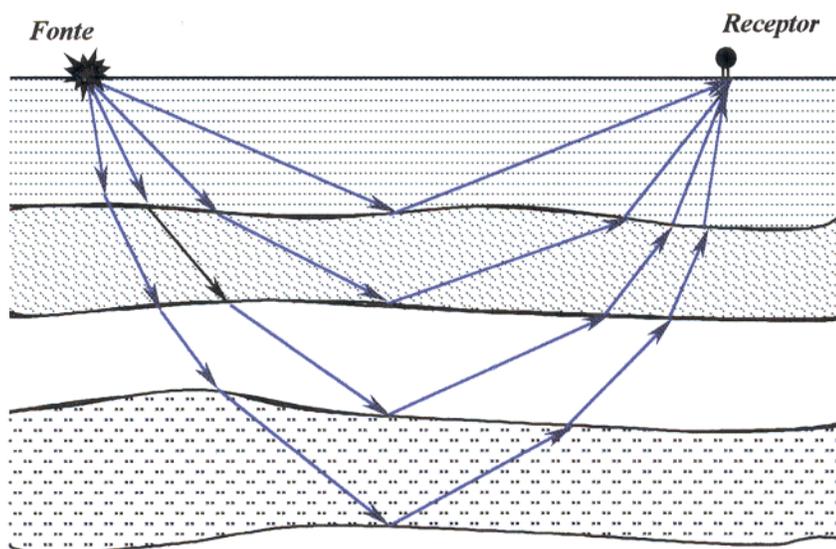
A prospecção sísmica é baseada no fato de que um pulso, gerado num ponto localizado próximo à superfície, tem condições de retornar a outros pontos dessa superfície, devido à presença de descontinuidades físicas das camadas geológicas em subsuperfície.

Os intervalos de tempo, decorridos entre o instante em que é gerado o pulso e os relativos às chegadas, são proporcionais às distâncias percorridas pelas trajetórias correspondentes, e às velocidades do meio.

## 2.1 – MODELO CONVOLUCIONAL SIMPLES

A subsuperfície é aqui representada por uma bacia sedimentar, composta por camadas que apresentam propriedades físicas e litológicas distintas. A Figura 2.1 mostra um modelo geológico simples da resposta da bacia sedimentar ao pulso sísmico, onde as interfaces apresentam variações na impedância acústica. Essas variações são responsáveis por reflexões que são registradas na superfície por receptores devidamente arranjados.

A impedância acústica de uma camada é definida como sendo o produto da densidade pela velocidade. Estes dois parâmetros definem, do ponto de vista sísmico, as propriedades desse meio para a propagação das ondas geradas pelo pulso-fonte.



**Figura 2.1** – Modelo geológico simples para uma bacia sedimentar, ilustrando trajetórias de reflexão sísmica.

A representação física do modelo convolucional é segundo o diagrama de blocos mostrado na Figura 2.2, onde:  $f(t)$  é a função pulso fonte (*Wavelet*);  $h(t)$  é a função sistema, ou função transferência, representando a bacia sedimentar;  $g(t)$  é a função saída do sistema linear (sismograma).



**Figura 2.2-** Diagrama de blocos do modelo convolucional simples e sem ruído.

## 2.2 – PULSO FONTE

Existem várias formas para representar a parte temporal da onda emitida na literatura. A Figura 2.3 ilustra quatro tipos comuns de funções utilizadas na geração de sismogramas sintéticos.

O pulso-teste Berlage,  $B(t)$ , é unilateral, causal, [Figura 2.3 (a)], e corresponde ao produto de quatro partes: uma constante, uma exponencial, uma senóide e a função degrau-simples (Heaviside)  $u(t)$ , cuja expressão é dada por (2.1). Esta função, (Aldridge 1990), é controlada por cinco parâmetros  $(A, n, \gamma, f_o, \phi_o)$ .

$$B(t) = Au(t)t^n e^{-\gamma t} \cos(\omega_o t + \phi_o), \quad (t \geq 0), \quad (2.0)$$

onde:  $A$  é o fator de amplitude;  $n$  é um expoente amplificador;  $\gamma$  é o coeficiente de decaimento exponencial;  $\phi_o$  é um deslocamento de fase;  $\omega_o = 2\pi f_o$  é a velocidade angular.

$$u(t) = \begin{cases} 1, & t > 0 \\ 0, & t < 0 \end{cases}. \quad (2.1)$$

Esta função tem para o cálculo da transformada de Fourier,

$$B(f) = \frac{A\Gamma(n+1)}{2(2\pi i)^{n+1}} \left[ \frac{e^{+i\phi_o}}{(f - F_1)^{n+1}} + \frac{e^{-i\phi_o}}{(f - F_2)^{n+1}} \right], \quad (2.2)$$

onde:  $F_1 = +f_o + i\frac{\gamma}{2\pi}$ ;  $F_2 = -f_o + i\frac{\gamma}{2\pi}$ ;  $\Gamma(1) = 1$ ;  $\Gamma(n) = n!$ . O espectro de amplitude tem um máximo ao redor de  $f_o$ , e decai assintoticamente a zero nas frequências altas na ordem  $\approx f^{-(n+1)}$ . (Leite 1998).

Outra função bastante comum é o pulso de Ricker,  $R(t)$ , não causal [Figura 2.3 (b)] que aparece na solução da equação de onda em uma dimensão para um meio visco-elástico. Esta função é controlada pelos parâmetros  $(x, v, \rho, \eta)$ , e descrita por

$$R(t) = -\left(1 - \frac{a^2 t^2}{2}\right) e^{-\frac{a^2 t^2}{4}}, \quad |R(\omega)| = \frac{4\sqrt{\pi}}{a^3} \omega^2 e^{-\frac{\omega^2}{a^2}}, \quad (-\infty < t < +\infty), \quad (2.3)$$

em que

$$a = \left(\frac{2\omega_o}{t_o}\right)^{1/2}, \quad t_o = \frac{x}{v}, \quad \omega_o = 3\frac{\rho v}{4\eta}. \quad (2.4)$$

onde:  $x$  é a posição da observação;  $v$  é a velocidade da onda;  $\rho$  é a densidade do meio;  $\eta$  é a medida de viscosidade interna do meio;  $\omega_o = 2\pi f_o$  é a velocidade angular. (Leite 1998).

O terceiro pulso-teste é a função seno-cardinal,  $S(t)$ , não causal [Figura 2.3 (c)], controlada pelos parâmetros  $(A, f_c)$ , e definida por

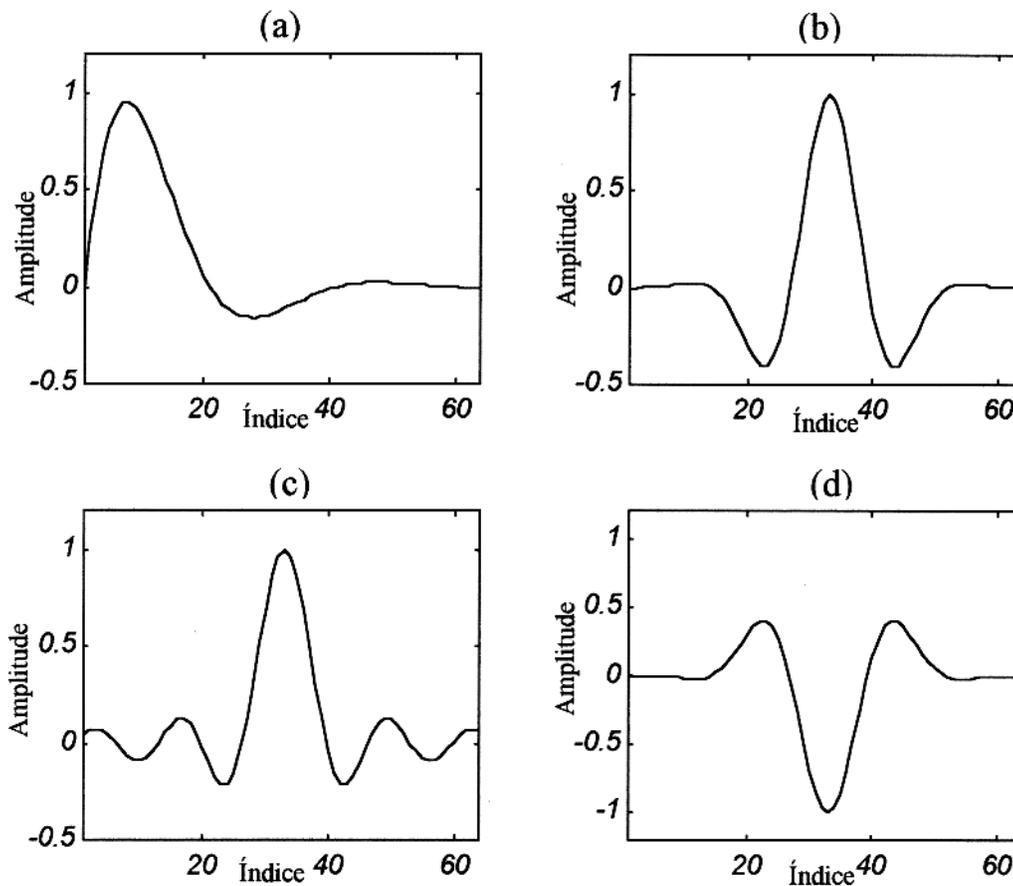
$$S(t) = 2f_c A \frac{\text{sen}(2\pi f_c t)}{2\pi f_c t} = 2f_c A \text{senc}(2\pi f_c t), \quad (-\infty < t < +\infty), \quad (2.5)$$

onde:  $A$  é o fator de amplitude;  $f_c$  é a frequência de corte. (Bracewell 1986).

Um quarto pulso-teste é ilustrado na Figura 2.3, e corresponde a função Gabor,  $G(t)$ , não causal, controlada por quatro parâmetros  $(A, f_M, \sigma, \nu)$ , sendo definida por

$$G(t) = A e^{-\left(\frac{2\pi f_M}{\sigma}\right)^2 t^2} \cos(2\pi f_M t + \nu), \quad (-\infty < t < +\infty), \quad (2.6)$$

onde:  $A$  é o fator de amplitude;  $f_M$  é a frequência de Nyquist;  $\sigma$  é o coeficiente de espalhamento do pulso;  $\nu$  é o deslocamento de fase para dar a forma desejada ao pulso. (Leite 1998).



**Figura 2.3** – Pulsos-fonte: (a) Função Berlage; (b) Função Ricker; (c) Função Seno-cardinal; (d) Função Gabor.

### 2.2.1 - Propriedades dos pulsos fonte

A principal propriedade do pulso fonte, no que concerne aos algoritmos utilizados para a compressão e deconvolução do traço sísmico, é a fase espectral. Uma técnica conveniente para o estudo dessa propriedade em sinais discretizados é a transformada  $Z$ . (Sadi 1979).

A transformada  $Z$  de Laplace de um sinal discreto,  $g_t$ , na forma bilateral, é definida por

$$Z\{g_t\} = G(z) = \sum_{t=-\infty}^{\infty} g_t z^t, \quad (2.7)$$

onde  $z$  é a variável no plano complexo, sendo  $z = x + iy$ ,  $g_t = (\dots, g_{-2}, g_{-1}, g_0, g_1, g_2, \dots)$  e  $t$  é um índice temporal, e consideremos aqui o caso de intervalo de amostra  $\Delta t$  uniforme. Em muitos

casos, o sinal é causal, isto é,  $g_t = 0$  para  $t < 0$ , e, a transformada  $Z$  unilateral infinita, tem a forma

$$Z\{g_t\} = G(z) = \sum_{t=0}^{\infty} g_t z^t. \quad (2.8)$$

Para a realização  $(g_0, g_1, g_2, \dots, g_{N-1})$ , a transformada  $Z$  simplifica à forma polinomial unilateral finita

$$Z\{g_t\} = G(z) = \sum_{t=0}^{N-1} g_t z^t = g_0 + g_1 z + g_2 z^2 + \dots + g_{N-1} z^{N-1} \quad (2.9)$$

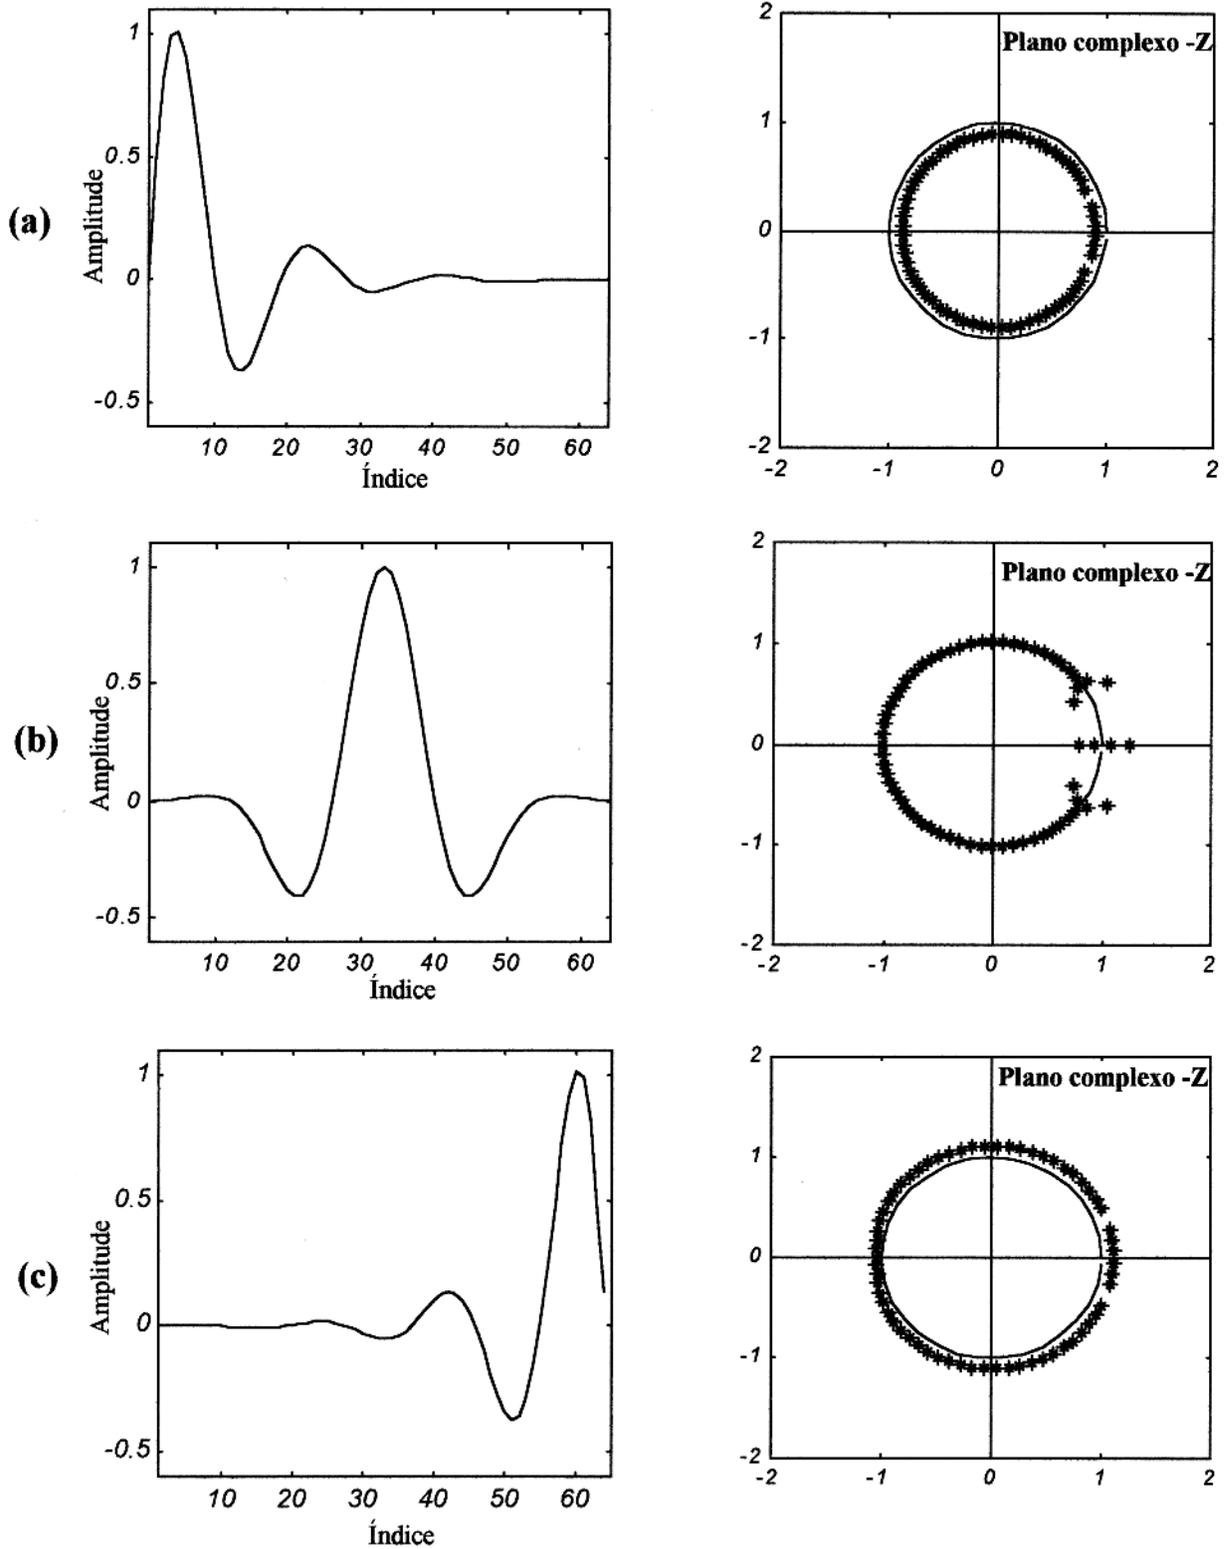
Este polinômio pode ser expresso, através do teorema fundamental da álgebra, em fatores binomiais, na forma

$$Z\{g_t\} = G(z) = \sum_{t=0}^{N-1} g_t z^t = (z - z_0)(z - z_1)(z - z_2) \dots (z - z_{N-1}) = \prod_{n=0}^{N-1} (z - z_n), \quad (2.10)$$

onde  $z_n$  representa as raízes do polinômio.

A aplicação da transformada  $Z$ , para analisar o comportamento de fase de um pulso, é feita através das raízes,  $z_n$  com relação ao círculo unitário no plano complexo  $Z$ . Quando todas as raízes do polinômio são menores que a unidade,  $|z_n| < 1$ , ou seja, as mesmas se encontram dentro do círculo unitário, o pulso é chamado de fase-mínima ou de retardo-mínimo. Se todas as raízes do polinômio são maiores do que a unidade,  $|z_n| > 1$ , ou seja, as mesmas encontram-se localizadas fora do círculo unitário, o pulso é chamado de fase-máxima ou de retardo-máximo. No pulso de fase-mista ou de retardo-misto, as raízes do polinômio são distribuídas dentro e fora do círculo unitário.

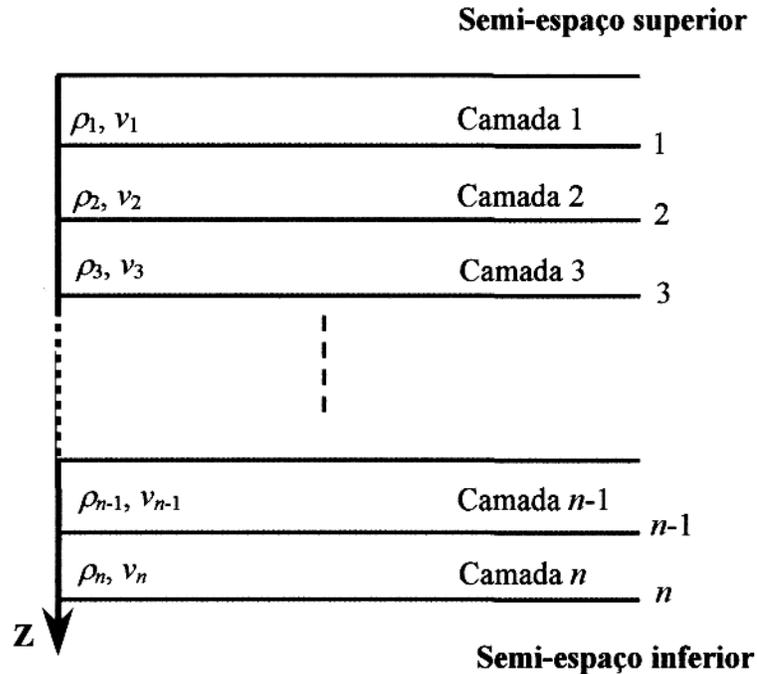
A Figura 2.4 mostra três aplicações da identificação de fase dos pulsos usando a transformada  $Z$ . As raízes do polinômio estão representadas por asteriscos (\*). O exemplo (a) ilustra um pulso de fase-mínima, no caso o Berlage, onde as raízes polinomiais encontram-se fora do círculo unitário complexo. O exemplo (b) ilustra um pulso de fase-mista, no caso o Ricker, onde as raízes são internas e externas ao círculo unitário. O exemplo (c) ilustra um pulso de fase-máxima, onde as raízes do polinômio encontram-se no interior do círculo unitário.



**Figura 2.4** – Comportamento de fase de três pulsos com relação ao círculo unitário. (a) Função Berlage; (b) Função Ricker; (c) Reverso da Função Berlage.

### 2.3 – FUNÇÃO REFLETIVIDADE SIMPLES

A função refletividade é definida como sendo a resposta refletiva do meio ao impulso. Ela revela discontinuidades elásticas das formações geológicas, caracterizando assim as interfaces. Nos modelos sísmicos, uma feição bastante utilizada é a de considerar a subsuperfície como sendo um semiespaço contendo camadas homogêneas e isotrópicas plano-paralelas, caracterizada pela velocidade  $v$  e densidade  $\rho$ , conforme é ilustrado na Figura 2.5.



**Figura 2.5** - Modelo geofísico de camadas homogêneas, isotrópicas, plano-paralelas, mostrando a numeração das camadas e interfaces, bem como os parâmetros densidade,  $\rho_n$ , e velocidade,  $v_n$ .

Para incidências normais, o coeficiente de reflexão para a pressão numa interface separando os meios  $i$  e  $i+1$ , sob condições de ondas planas descendentes, é expresso por

$$K_i = \frac{v_{i+1}\rho_{i+1} - v_i\rho_i}{v_{i+1}\rho_{i+1} + v_i\rho_i}, \quad K_i \leq |1| \quad (2.11)$$

A impedância acústica para cada camada é definida por

$$I_i = v_i\rho_i \quad (2.12)$$

Para o caso de valores de densidade das camadas aproximadamente iguais ( $\rho_i \cong \rho_{i+1}$ ), a expressão (2.11) se reduz a

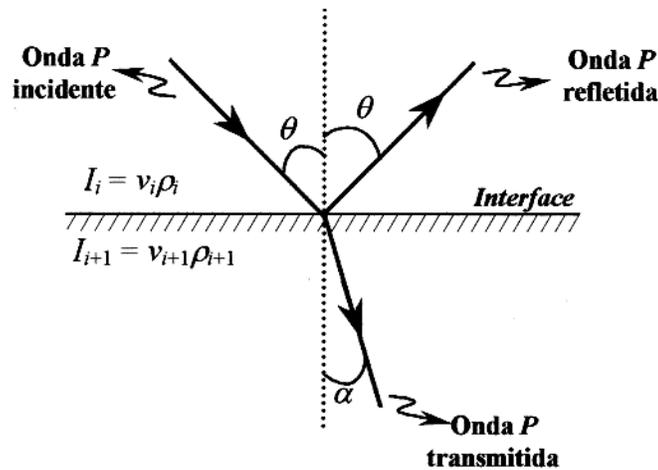
$$K_i \cong \frac{v_{i+1} - v_i}{v_{i+1} + v_i}, \quad K_i \leq |1| \quad (2.13)$$

Para incidências oblíquas, a expressão do coeficiente de reflexão tem a forma

$$K_i = \frac{v_{i+1}\rho_{i+1} \cos\theta - v_i\rho_i \cos\alpha}{v_{i+1}\rho_{i+1} \cos\theta + v_i\rho_i \cos\alpha} = \frac{I_{i+1} \cos\theta - I_i \cos\alpha}{I_{i+1} \cos\theta + I_i \cos\alpha}, \quad K_i \leq |1| \quad (2.14)$$

onde  $\alpha$  representa o ângulo de incidência do raio transmitido, conforme é mostrado na Figura 2.6. Pela lei de Snell, tem-se que

$$\frac{\text{sen } \theta}{\text{sen } \alpha} = \frac{v_i}{v_{i+1}} \quad (2.15)$$



**Figura 2.6** – Geometria das ondas incidente, refletida e transmitida em uma interface onde ocorre descontinuidades de impedância entre dois meios. A conversão P-SV não é considerada porque o problema é simplificado para  $\theta=0$ .

O tempo de percurso duplo da onda para cada interface é dado por

$$T_i = 2 \sum_{k=1}^i \frac{e_k}{v_k} \quad (2.16)$$

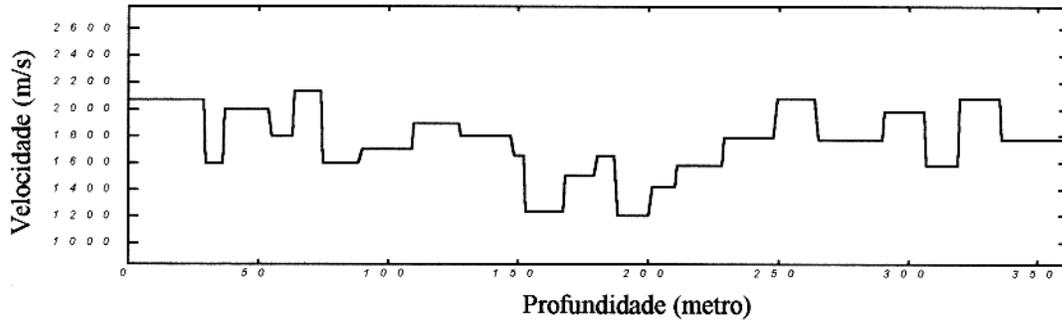
$e_k$  e  $v_k$  representam, respectivamente, as espessuras e velocidades das camadas até a camada  $i$ . A expressão (2.16) é desenvolvida para uma fonte posicionada na superfície do modelo de camadas horizontais plano-horizontais estratificadas.  $T_i$  serve para distribuir os coeficientes  $K_i$  ao longo do eixo dos tempos na forma  $(K_i, T_i)$ .

As Figuras 2.7 e 2.8 exemplificam, respectivamente, o perfil de velocidades intervalares e a distribuição dos coeficientes de reflexão de pressão.

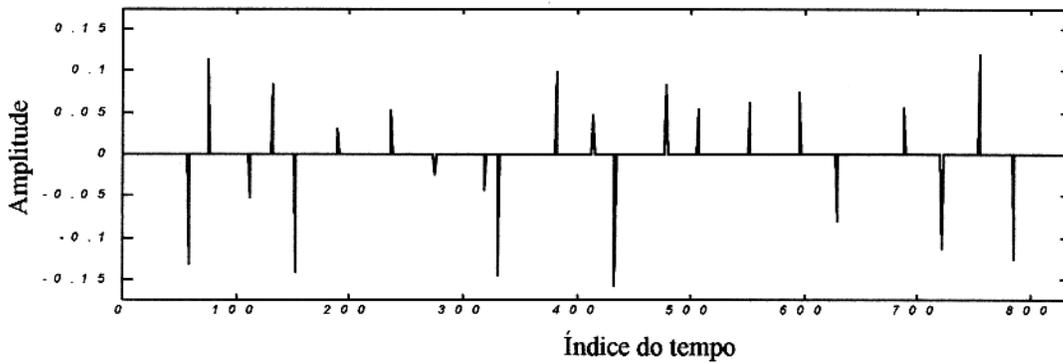
A forma contínua da função definida como refletividade simples é expressa utilizando o delta de Dirac,  $\delta(t)$ , segundo

$$V(t) = \sum_{i=0}^{\infty} K_i \delta(t - t_i), \quad (2.17)$$

onde  $i$  representa a seqüência de interfaces.



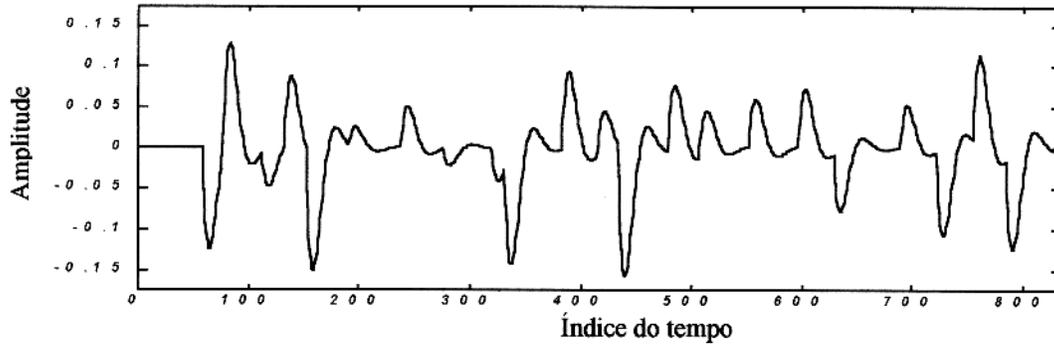
**Figura 2.7** - Perfil de velocidades intervalares.



**Figura 2.8**- Distribuição dos coeficientes de reflexão definida com a refletividade simples.

## 2.4 - CÁLCULO DO SISMOGRAMA SINTÉTICO

O sismograma sintético, ilustrado na Figura 2.9, é considerado de forma intuitiva como sendo o resultado da convolução linear entre a função fonte e a função distribuição dos coeficientes de reflexão exemplificadas nas Figuras 2.3 (a) e 2.8, respectivamente.



**Figura 2.9-** Sismograma sintético sem ruído. A função fonte é Berlage, e a função refletividade simples é a da Figura 2.8. Este sismograma corresponde ao caso ideal de controle de ganho dinâmico para equilíbrio do traço sísmico.

O sismograma sintético sem ruído, pode ser representado matematicamente pela convolução unilateral finita (Leite, 1998), dada por

$$g(t) = f(t) * h(t) = \int_0^t f(\tau) h(t - \tau) d\tau = \int_0^t h(\tau) f(t - \tau) d\tau, \quad (0 < t < +\infty), \quad (2.18)$$

que possui a propriedade de comutatividade. A forma discretizada finita é escrita na forma

$$g_k = \Delta t \sum_{i=0}^{N-1} f_i h_{k-i} = \Delta t \sum_{i=0}^{N-1} h_i f_{k-i}, \quad (N = P + Q - 1; k = 0, 1, 2, \dots, N - 1), \quad (2.19)$$

onde:  $P$  é o número de amostras da função pulso;  $Q$  é o número de amostras da função refletividade simples;  $N$  é o número de amostras do sismograma sintético. Neste caso, o efeito da transmissividade não é considerado, e ele é considerado como compensado pelo controle de ganho automático. Isto significa imitar dados sísmicos apresentados em seções de trabalho.

## 2.5- RUÍDOS SÍSMICOS

Na interpretação de dados da prospecção sísmica há sempre de se conviver com a presença inevitável de ruídos que prejudicam a interpretação. Filosoficamente, o ruído sísmico é considerado como qualquer evento presente no sismograma que não tenha uma relação com os alvos da prospecção (refletores ou refratores sísmicos). Assim, é comum considerar o sismograma como uma associação de processos determinísticos e não determinísticos das informações dos alvos (sinal) e do ruído.

Diversas técnicas são utilizadas na tentativa de diminuir o efeito do ruído no processamento de sismogramas. Por exemplo as refrações de camadas rasas num sismograma de

reflexão podem prejudicar a identificação de reflexões das camadas mais profundas, sendo um ruído com características determinísticas. Analogamente, reflexões de camadas situadas acima de um refrator podem interferir com os tempos de chegada coincidentes, de modo a prejudicar o reconhecimento das trajetórias refratadas em alguns canais do registro, constituindo-se também numa forma semelhante de ruído. Vale ressaltar que entre os vários tipos de ondas que retornam à superfície a partir de uma explosão sísmica e observados no sismograma, apenas um número bastante reduzido de eventos são utilizadas na prospecção sísmica. Deste modo, diversas formas de ondas presentes no sismograma são classificadas como ruído por não ser simples a sua interpretação.

Existem outras fontes de ruídos, tais como o movimento de ondas no litoral, vento, cachoeiras e água corrente em rios situados nas proximidades das linhas sísmicas nos trabalhos de prospecção terrestre e oscilações do mar em trabalhos marinhos, dentre outros.

A razão sinal/ruído é um parâmetro qualificador do ruído presente no sismograma, definido pela razão entre a variância da mensagem pela variância do ruído. Este parâmetro tem o seu sentido restrito às análises realizadas sobre o sismograma sintético, para o qual se conhece a priori as propriedades estatísticas do ruído presente. Deste modo, uma expressão simples da razão sinal/ruído (Leite, 1998) é dada por

$$S/R = \frac{\frac{1}{N} \sum_{n=1}^N \Delta s_n^2}{\frac{1}{N} \sum_{n=1}^N \Delta r_n^2} = \frac{\sum_{n=1}^N (s_n - \bar{s})^2}{\sum_{n=1}^N (r_n - \bar{r})^2}, \quad (2.20)$$

onde as médias amostrais são

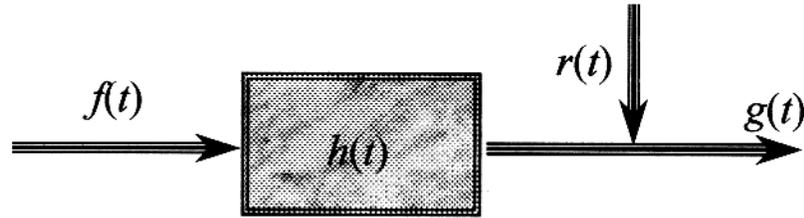
$$\bar{s} = \frac{1}{N} \sum_{n=1}^N s_n \quad \text{e} \quad \bar{r} = \frac{1}{N} \sum_{n=1}^N r_n. \quad (2.21)$$

$s_n$  = sinal sintético sem ruído;  $r_n$  = ruído empregado;  $\bar{s}$  = valor médio da mensagem;  $\bar{r}$  = valor médio do ruído aditivo;  $N$  = número de amostras.

A expressão (2.18) da convolução linear é redefinida por

$$g(t) = f(t) * h(t) + r(t) = \int_0^t f(\tau) h(t - \tau) d\tau + r(t), \quad (2.22)$$

incluindo o termo  $r(t)$  que representa o ruído aditivo, e participa da forma canônica do diagrama de blocos na Figura 2.10.

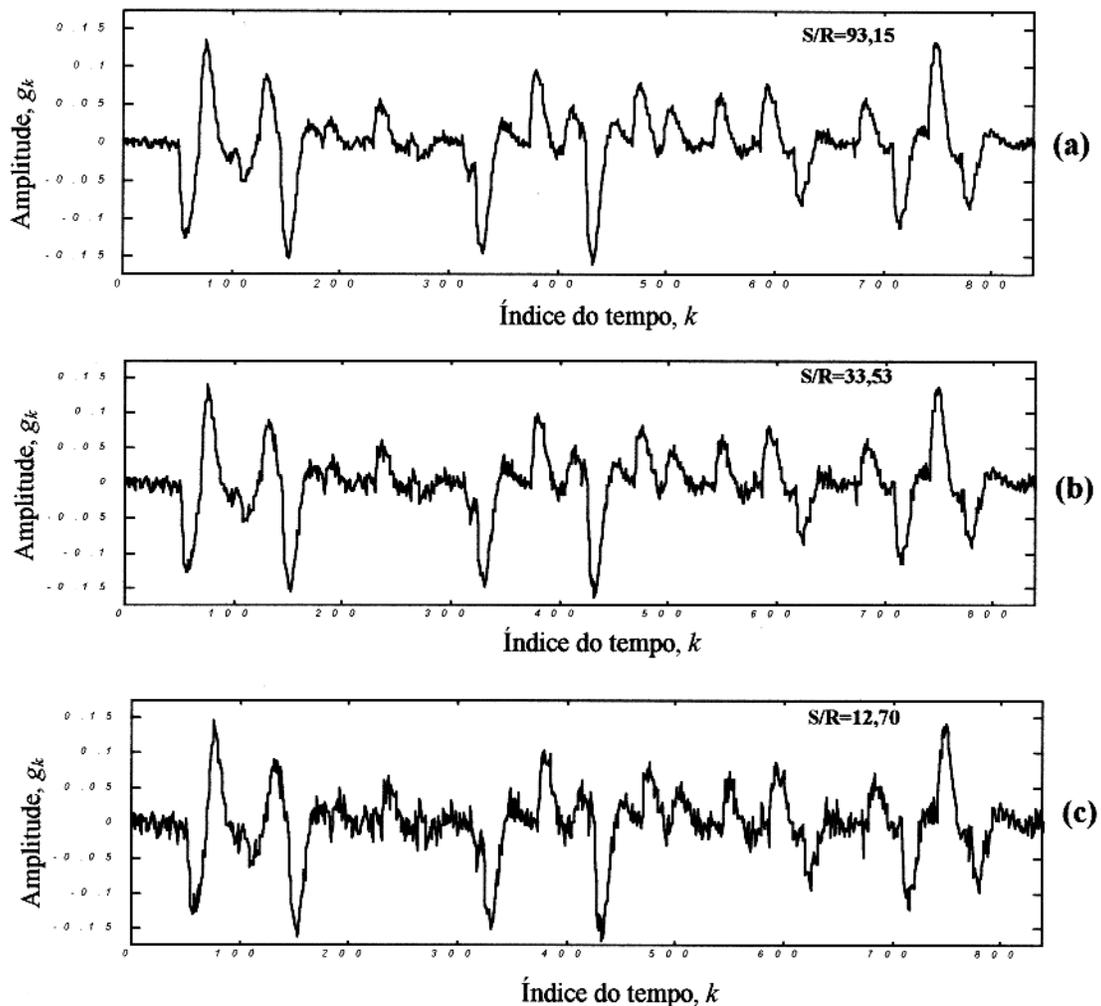


**Figura 2.10-** Diagrama de blocos do modelo convolucional simples com ruído aditivo.

Na forma discretizada, a equação da convolução simples pode ser reescrita na forma

$$g_k = \sum_{i=0}^{N-1} f_i h_{k-i} + r_k, \quad \Delta t = 1. \quad (2.23)$$

A Figura 2.11 descreve a situação de sismogramas, onde o decréscimo da razão sinal/ruído ocasiona um aumento da perturbação do sinal.



**Figura 2.11** – Exemplos de sismogramas com variações da razão sinal/ruído. (a) S/R=93,2; (b) S/R=33,5; (c) S/R=12,7. O ruído não é filtrado no processo de propagação e de registro.

## 2.6 - DECONVOLUÇÃO SÍSMICA CLÁSSICA

A deconvolução tem como objetivo a recuperação da sequência refletiva, a partir do sismograma registrado. As técnicas clássicas no tratamento de sinais são os filtros ótimos, desenhados através de métodos dos mínimos-quadrados.

A resolução dos filtros lineares deconvolutivos no tratamento dos dados sísmicos depende do grau em que eles se ajustem às considerações e premissas da modelagem matemática do meio geológico.

### 2.6.1- Filtro ótimo de Wiener-Hopf

O filtro de Wiener-Hopf, que baseia-se no princípio dos mínimos-quadrados, entendido como a minimização da variância entre a saída real,  $y_t$ , e a desejada,  $d_t$ , do filtro, conforme o esquema da Figura 2.12.

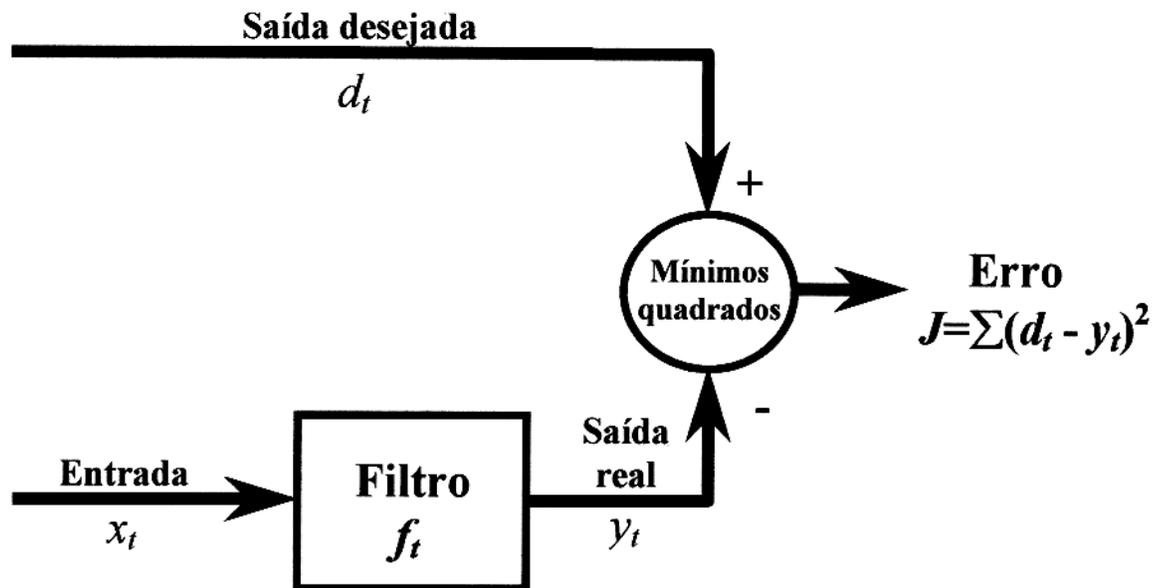


Figura 2.12 – Diagrama do filtro de mínimos-quadrados de Wiener-Hopf.

O filtro  $f_t = (f_0, f_1, \dots, f_{m-1})$ , de comprimento  $m$ , é expresso em termos do sinal de entrada conhecido,  $x_t$ , e do sinal de saída desejado (Robinson & Treitel, 1967 e Yilmaz, 1989).

A função objeto de minimização, é o valor esperado erro quadrático dado por

$$e(f_t) = E\{(d_t - y_t)^2\}, \quad (t = 0, 1, \dots, P-1). \quad (2.24)$$

$P$  representa o número de pontos no traço observado;  $d_t$  e  $y_t$  são realizações estocásticas estacionárias. A saída real do filtro,  $y_t$ , é representada pela convolução linear da entrada,  $x_t$ , com os coeficientes do filtro,  $f_t$ ,

$$y_t = x_t * f_t = \sum_{\tau=0}^{M-1} f_{\tau} x_{t-\tau}, \quad (t = 0, 1, \dots, P-1). \quad (2.25)$$

$M$  representa o número de coeficientes do filtro.  $x_t$  é dado a partir do modelo convolucional simples

$$x_t = s_t + r_t = \sum_{j=0}^{L-1} w_j v_{t-j} + r_t; \quad (t = 0, 1, \dots, N-1 \text{ e } N = L + Q - 1), \quad (2.26)$$

onde:  $L$  é o número de amostras do pulso-fonte  $w$ ;  $Q$  é o número de amostras da função refletividade simples;  $N$  é o número de amostras do sismograma sintético;  $v_t$  é a distribuição dos coeficientes de reflexão;  $r_t$  é o ruído aditivo;  $s_t$  é o sinal não ruidoso.

Substituindo a expressão 2.25 na expressão 2.24, tem-se as etapas:

$$e(f_t) = E\left\{\left(d_t - \sum_{\tau=0}^M f_{\tau} x_{t-\tau}\right)^2\right\}, \quad (2.27)$$

$$e(f_t) = E\left\{d_t^2 - 2d_t \sum_{\tau=0}^M f_{\tau} x_{t-\tau} + \left(\sum_{\tau=0}^M f_{\tau} x_{t-\tau}\right)^2\right\}, \quad (2.28)$$

$$e(f_t) = E\{d_t^2\} - E\left\{2d_t \sum_{\tau=0}^M f_{\tau} x_{t-\tau}\right\} + E\left\{\left(\sum_{\tau=0}^M f_{\tau} x_{t-\tau}\right)^2\right\}. \quad (2.29)$$

Os termos da expressão (2.29) são analisados separadamente. Para o primeiro termo

$$E\{d_t^2\} = \phi_{dd}(0), \quad (2.30)$$

cujo resultado é obtido utilizando a definição de autocorrelação estocástica teórica da série  $d_t$ , dada por

$$\phi_{dd}(j) = E\{d_{\tau} d_{\tau-j}\}. \quad (2.31)$$

Para o segundo termo

$$E \left\{ d_t \sum_{\tau=0}^M f_{\tau} x_{t-\tau} \right\} = \sum_{\tau=0}^M f_{\tau} E \{ d_t x_{t-\tau} \} = \sum_{\tau=0}^M f_{\tau} \phi_{dx}(\tau), \quad (2.32)$$

cujo resultado é obtido utilizando a definição da correlação cruzada estocástica teórica dada por

$$\phi_{dx}(j) = E \{ d_t x_{t-j} \}. \quad (2.33)$$

Para o terceiro termo

$$\begin{aligned} E \left\{ \left( \sum_{\tau=0}^M f_{\tau} x_{t-\tau} \right)^2 \right\} &= E \left\{ \left( \sum_{\tau=0}^M f_{\tau} x_{t-\tau} \right) \left( \sum_{\eta=0}^M f_{\eta} x_{t-\eta} \right) \right\} = \\ &= \sum_{\tau=0}^M \sum_{\eta=0}^M f_{\tau} f_{\eta} E \{ x_{t-\tau} x_{t-\eta} \} = \sum_{\tau=0}^M \sum_{\eta=0}^M f_{\tau} f_{\eta} \phi_{xx}(\eta - \tau). \end{aligned} \quad (2.34)$$

Substituindo as expressões (2.30), (2.32) e (3.34) na expressão (2.29), tem-se a expressão

$$e(f_t) = \phi_{dd}(0) - 2 \sum_{\tau=0}^M f_{\tau} \phi_{dx}(\tau) + \sum_{\tau=0}^M \sum_{\eta=0}^M f_{\tau} f_{\eta} \phi_{xx}(\eta - \tau). \quad (2.35)$$

O erro mínimo,  $e$ , é obtido sob a condição de que suas derivadas parciais, com relação aos coeficientes do filtro,  $f_i$ , sejam nulas:

$$\frac{\partial e(f_t)}{\partial f_i} = -2\phi_{dx}(i) + \sum_{\tau=0}^M f_{\tau} \phi_{xx}(i - \tau) + \sum_{\eta=0}^M f_{\eta} \phi_{xx}(\eta - i) = 0. \quad (2.36)$$

Ou melhor

$$\frac{\partial e(f_t)}{\partial f_i} = -2\phi_{dx}(i) + 2 \sum_{\tau=0}^M f_{\tau} \phi_{xx}(i - \tau) = 0, \quad (2.37)$$

visto que a autocorrelação é uma função par. Como resultado, chega-se às equações normais Wiener-Hopf, na forma discretizada, dada por

$$\sum_{\tau=0}^M f_{\tau} \phi_{xx}(i - \tau) = \phi_{dx}(i), \quad (j = 0, 1, \dots, M-1). \quad (2.38)$$

A solução de (2.38) determina os coeficientes  $f_i$  que minimiza a função erro  $e(f_i)$ . Na expressão (2.38),  $\phi_{dx}(i)$  representa a parte positiva unilateral da correlação cruzada teórica do sinal de entrada com o sinal desejado.

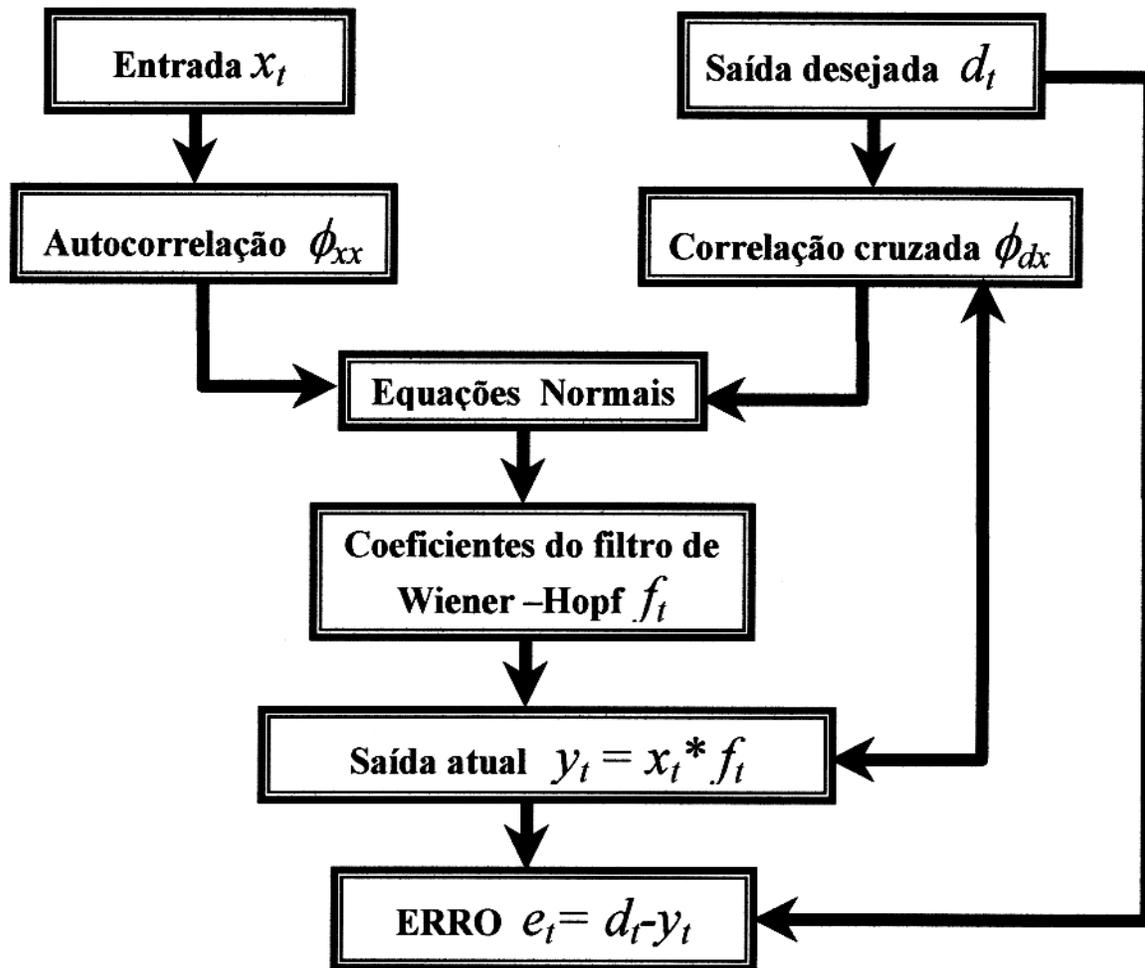
Na forma exponencial expandida, a equação (2.38), é escrita como:

$$\begin{bmatrix} \phi_{xx}(0) & \phi_{xx}(-1) & \phi_{xx}(-2) & \cdots & \phi_{xx}(-M+1) \\ \phi_{xx}(1) & \phi_{xx}(0) & \phi_{xx}(-1) & \cdots & \phi_{xx}(-M+2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \phi_{xx}(M) & \phi_{xx}(M-1) & \phi_{xx}(M-2) & \cdots & \phi_{xx}(0) \end{bmatrix} \begin{bmatrix} f(0) \\ f(1) \\ \vdots \\ f(M) \end{bmatrix} = \begin{bmatrix} \phi_{dx}(0) \\ \phi_{dx}(1) \\ \vdots \\ \phi_{dx}(M) \end{bmatrix} \quad (2.39)$$

Fazendo uso da propriedade de que  $\phi_{xx}(j) = \phi_{xx}(-j)$  para todo  $j$ , tem-se:

$$\begin{bmatrix} \phi_{xx}(0) & \phi_{xx}(1) & \phi_{xx}(2) & \cdots & \phi_{xx}(M+1) \\ \phi_{xx}(1) & \phi_{xx}(0) & \phi_{xx}(1) & \cdots & \phi_{xx}(M+2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \phi_{xx}(M) & \phi_{xx}(M-1) & \phi_{xx}(M-2) & \cdots & \phi_{xx}(0) \end{bmatrix} \begin{bmatrix} f(0) \\ f(1) \\ \vdots \\ f(M) \end{bmatrix} = \begin{bmatrix} \phi_{dx}(0) \\ \phi_{dx}(1) \\ \vdots \\ \phi_{dx}(M) \end{bmatrix} \quad (2.40)$$

A matriz acima é do tipo Toeplitz, cuja propriedade principal é a simetria,  $A_{ij} = A_{ji}$ . A Figura 2.13 ilustra o diagrama de blocos do algoritmo utilizado no cálculo dos coeficientes,  $f_i$ , do filtro de Wiener.



**Figura 2.13** – Diagrama de blocos para o cálculo dos coeficientes,  $f_i$ , do filtro de Wiener-Hopf na forma geral.

### **3 - DECONVOLUÇÃO COM REDE NEURAL ARTIFICIAL**

Neste capítulo é realizada uma abordagem geral das redes neurais, com ênfase na rede neural de Hopfield. Avalia-se ainda o comportamento da deconvolução com a rede de Hopfield segundo o método apresentado por Wang & Mendel (1992).

#### **3.1- REDE NEURAL ARTIFICIAL**

A rede neural pertence a uma ampla classe de sistemas dinâmicos denominados de “conexionistas”, nos quais cada elemento processador não controla individualmente o processo computacional que está sendo realizado pelo sistema. O controle do processo é realizado por uma matriz de pesos, que define as interrelações entre os diversos neurônios ou elementos processadores, por isto, o nome de conexcionista. Esse tipo de computação realizada por esse sistema recebe o nome de computação coletiva.

Os elementos processadores são constituídos pelos neurônios e pelas conexões existentes entre eles, as quais recebem o nome de “sinapses”, codificando as informações que descrevem o problema que está sendo resolvido, bem como, caracterizando as qualidades que a solução deve ter. Uma rede neural não executa uma série de instruções, ela responde em paralelo às entradas que lhe são apresentadas em que o resultado não é armazenado em um endereço específico de memória, mas consiste do estado global da rede depois de ter alcançado alguma situação de equilíbrio. O conhecimento, dentro de uma rede neural, é mais uma função da arquitetura ou estrutura da rede do que o conteúdo de um elemento particular.

O processo de aprendizagem da rede neural é realizado sobre um conjunto de exemplos, onde cada exemplo é formado pelo par de dados de entrada (informação usada para tomar uma decisão) e de saída (decisão ou resposta). A rede processa cada exemplo usando as entradas para calcular as respostas que são comparadas com o padrão de saída fornecido. Quando a resposta encontrada está errada, a rede é ajustada fazendo mudanças em suas conexões internas. Esse processo de tentativa e erro continua até que a resposta fornecida pela rede seja igual ao padrão desejado, dentro do nível de precisão imposto, e, uma vez atingido esse objetivo, a rede neural é considerada treinada.

### 3.1.1 - Neurônio artificial

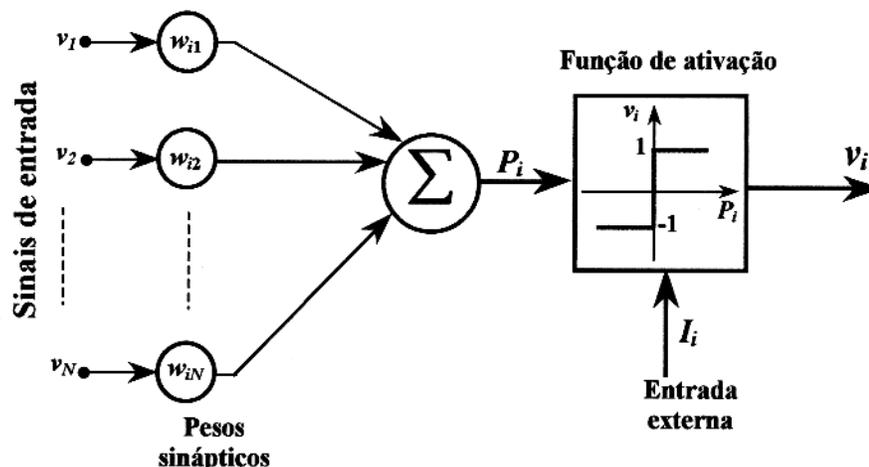
Um neurônio é uma unidade processadora de informação, e fundamental para a operação de uma rede neural. Pode-se observar três elementos básicos que constituem um modelo neural.

1- Um conjunto de pesos sinápticos ou conexões, cada um dos quais caracteriza a interrelação entre um dado neurônio e todos os demais que compõe a rede. Especificamente, se a componente da matriz de peso sináptico for dado por  $w_{ij}$ , esse valor traduz a força de ligação entre o neurônio  $i$  e o neurônio  $j$ .

2- Um acumulador que realiza a soma algébrica dos sinais de entrada de cada neurônio ponderado pelos respectivos pesos sinápticos. Essa operação pode ser traduzida na forma de uma combinação linear dos sinais de entrada.

3- Uma função de ativação que limita a faixa de amplitude do sinal de saída em um intervalo fechado onde, normalmente, são definidos os intervalos  $[0,1]$  ou  $[-1,1]$ .

O modelo para um neurônio está na Figura 3.1. Ele inclui uma entrada externa,  $I_i$ , que tem o objetivo de modular o sinal de entrada da função de ativação com informações oriundas do ambiente externo.



**Figura 3.1** - Modelo de um neurônio.  $v_i$  representa o estado dos neurônios;  $w_{ij}$  representa os pesos sinápticos;  $P_i$  representa o potencial de entrada;  $I_i$  representa a entrada externa.

### 3.1.2 - Classificação geral das redes

De acordo com a arquitetura das rede neurais, pode-se identificar quatro tipos diferentes de classes, discriminadas a seguir. O objetivo é empregar a rede de Hopfield dentro da classificação segundo Haykin (1998).

**1- Redes diretas (*feedforward*) de uma camada** - Este tipo apresenta apenas uma camada de entrada a qual é projetada para uma camada de saída de neurônios, sem ocorrer a recíproca, uma vez que a palavra realimentação (*feedforward*) é justamente a não existência de recorrências (*loops*) entre as conexões. Os sinais seguem em uma única direção, caracterizando assim o tipo mais comum. Este tipo de rede é ilustrado na Figura 3.2 para o caso de três nós, na camada de entrada e na camada de saída. Vale ressaltar que o termo “redes de uma camada” deve-se ao fato de não se contar a camada de entrada, por não existir função computacional nesta.

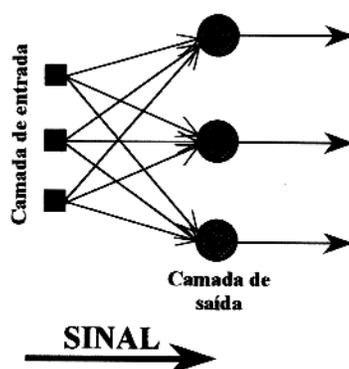
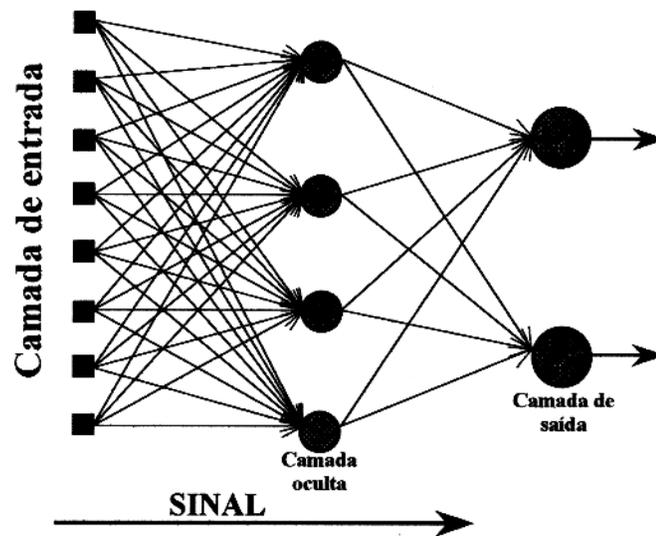


Figura 3.2 - Rede direta (*feedforward*) com uma única camada de neurônios.

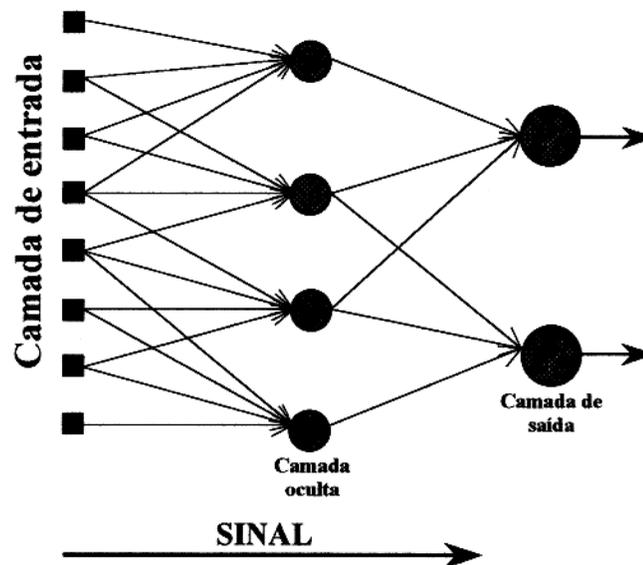
**2- Redes diretas multi-camada** – Este tipo é diferenciada pela presença de uma ou mais camadas ocultas, cujo objetivo é intervir entre a entrada e a saída da rede. As fontes na camada de entrada fornecem elementos (vetores de entrada) que são os sinais que são aplicados aos neurônios da segunda camada, denominada de primeira camada oculta. Os sinais de saída da segunda camada são entradas à terceira camada, e assim sucessivamente para o restante da rede. Pode-se ter dois tipos de redes multi-camadas, denominadas de completamente conectadas e parcialmente conectadas. No primeiro tipo, todos os neurônios de cada camada são conectados a todos os outros da camada posterior, conforme a Figura 3.3. De outra forma, se alguma das comunicações (conexões sinápticas) são perdidas, pode-se dizer que a rede está parcialmente conectada. Uma forma de rede direta multi-camada conectada parcialmente, de particular interesse, é a rede localmente conectada mostrada na Figura 3.4, onde cada neurônio localizado

na camada oculta está conectado a um grupo local (parcial) dos nós-fonte localizados na camada de entrada.



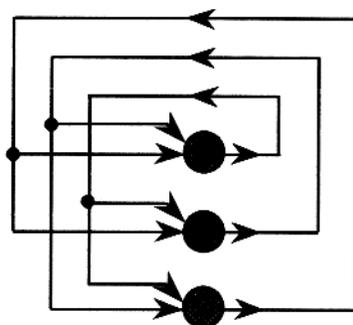
**Figura 3.3** - Rede direta completamente conectada com uma camada oculta e uma camada de saída.

Analisando as Figuras 3.4 e 3.3, verifica-se que ambas apresentam o mesmo número de nós-fonte (camada de entrada), neurônios ocultos (camada oculta) e neurônios de saída (camada de saída). Comparando as duas redes, nota-se que a rede localmente conectada apresenta uma estrutura especializada.



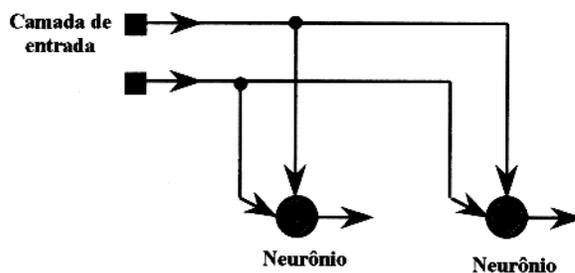
**Figura 3.4** - Rede direta parcialmente conectada.

**3- Redes recorrentes** – Esta rede distingue-se das redes diretas por apresentar pelo menos uma recorrência entre as conexões, sendo elas mais utilizadas em sistemas dinâmicos. Uma rede recorrente pode possuir uma única camada de neurônios onde cada neurônio alimenta os outros neurônios através de seu sinal de saída. Isto está ilustrado na arquitetura da rede da Figura 3.5, que mostra um diagrama recorrente onde não se verifica a existência de auto-alimentação (*self-feedback loops*) nas mesmas; ou seja, um mesmo neurônio não pode receber sua própria saída como entrada. Ainda pela Figura 3.5, tem-se a ausência de neurônios ocultos, porém esse tipo de rede pode vir apresentar esses neurônios.



**Figura 3.5** – Exemplo de rede recorrente sem realimentação (*self-feedback loops*) e sem neurônios ocultos.

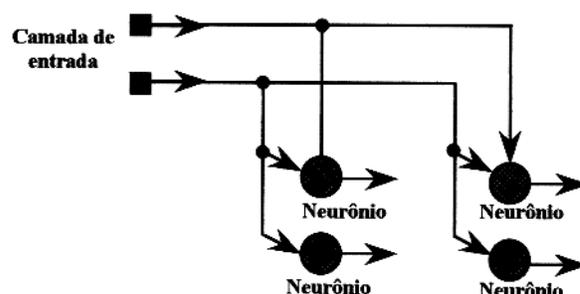
**4- Estruturas reticulada (*Lattice*)** – Ela consiste em uma matriz  $n$ -dimensional de neurônios, com um conjunto correspondente de nós-fonte, localizados na camada de entrada, que fornecem os sinais para a matriz. A Figura 3.6 mostra um exemplo uni-dimensional de dois neurônios alimentados por uma camada de dois nós-fonte.



**Figura 3.6** – Estrutura reticulada uni-dimensional de 2 neurônios.

Na Figura 3.7 apresenta-se um diagrama bidimensional 2X2 neurônios que também são alimentados por uma camada de dois nós-fonte. Nos dois diagramas cada nó-fonte encontra-se

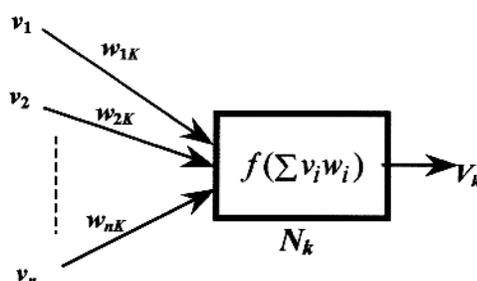
conectado a todos os neurônios. Verifica-se também que uma rede reticulada nada mais é do que uma rede do tipo direta, em que os neurônios de saída se encontram arranjados em linhas e colunas.



**Figura 3.7** – Estrutura reticulada bi-dimensional 2X2.

### 3.2- REDE NEURAL DE HOPFIELD

A rede neural de Hopfield é composta por  $n$  neurônios;  $N_1, N_2, \dots, N_n$ , onde, cada neurônio é um elemento processador composto por várias entradas e apenas uma saída, conforme o diagrama da Figura 3.8.



**Figura 3.8** - Neurônio de Hopfield.

O modelo de Hopfield utiliza o neurônio artificial de McCulloch & Pitts (1943) como sua unidade básica de processamento. Para uma rede neural artificial composta por  $N$  neurônios, o estado dessa rede é definido de acordo com o vetor  $v = [v_1, v_2, \dots, v_N]^T$ , onde o índice  $T$  e  $N$  representam, respectivamente, o transposto da matriz e quantidade de neurônios da rede. Com  $v_i$  sendo 0 ou 1, o estado do neurônio  $i$  representa um *bit* de informação, e o estado do vetor binário  $v$  ( $N \times 1$ ) representa uma palavra binária de  $N$  *bits* de informação.

A rede recorrente de Hopfield apresenta duas propriedades fundamentais:

- 1- A dinâmica da rede, quando o tempo tende ao infinito, possibilita que ela se estabilize para um dado vetor de estado  $\mathbf{v}$ , denominado estado de equilíbrio.
- 2- A inclinação da função de ativação na origem é feita infinitamente grande, de forma que uma função de ativação tipo sigmóide assume a forma de uma função degrau-simples, de acordo com o modelo de McCulloch & Pitts (1943).

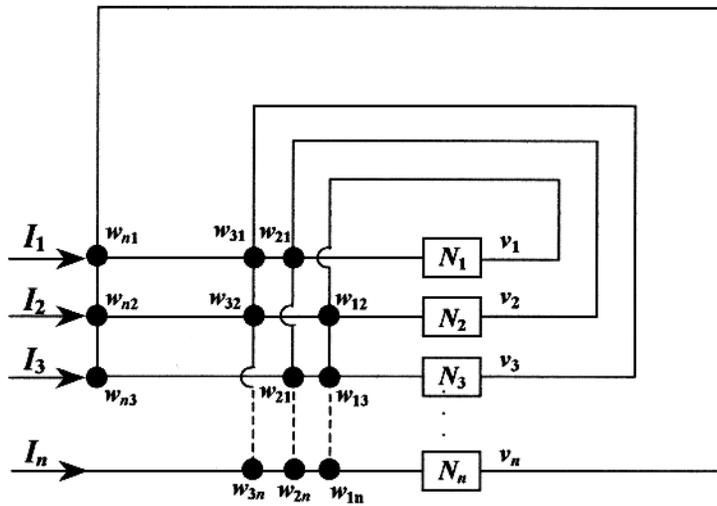


Figura 3.9 - Arquitetura da rede neural de Hopfield para “ $n$ ” neurônios.

### 3.2.1 – Neurônio binário

O estado (saída) de um neurônio binário  $N_i$  é denotado por  $v_i$ , assim sendo, ele tem um valor no intervalo fechado em  $[0,1]$ . A cada instante  $t$ , o estado do neurônio binário  $N_i$  é determinado pelo seu potencial de entrada denotado por  $P_i$ . A função degrau-simples (Figura 3.10) representa a função de ativação (*threshold function*), que tem como objetivo limitar a amplitude da saída de um neurônio. A dinâmica da rede neural de Hopfield pode ser expressa de acordo com a seguinte regra determinística:

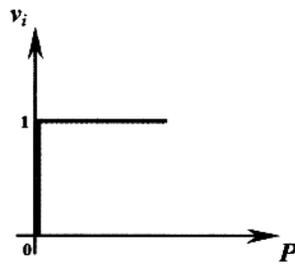


Figura 3.10 - Resposta do neurônio binário pela função degrau-simples.

$$v_i(t) = f[P_i(t-1)] = \begin{cases} 0, & \text{se } P_i(t-1) \leq 0 \\ 1, & \text{se } P_i(t-1) > 0 \end{cases} \quad (3.1)$$

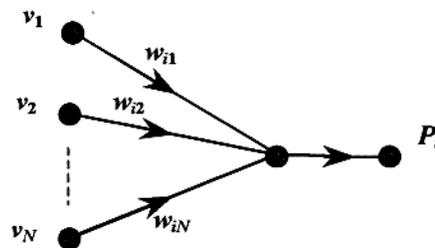
Para uma rede formada por  $N$  neurônios, o estado é definido pelo vetor

$$V = [v_1, v_2, \dots, v_N]^T. \quad (3.2)$$

Na expressão (3.1),  $t$  é o índice temporal discreto,  $t = 0, 1, 2, \dots, T$ , e  $i = 1, 2, \dots, N$ , onde  $N$  é a quantidade de neurônios que compõem a rede. O valor de  $P_i$  depende do estado dos demais neurônios a que  $N_i$  está conectado, e de uma entrada,  $I_i$ , fornecida externamente para esse neurônio, de modo que

$$P_i(t) = \sum_{j=1}^N w_{ij} v_j(t) + I_i. \quad (3.3)$$

$w_{ij}$  é o peso sináptico da ligação existente entre  $N_i$  e  $N_j$ , e ele especifica a contribuição do sinal de saída  $v_i$  do neurônio  $N_i$  para o potencial atuante no neurônio  $N_j$ , chamado de excitatório, ou inibitório, para  $w_{ij} > 0$  e  $w_{ij} < 0$ , respectivamente. A conexão ponderada existente entre os neurônios  $N_i$  e  $N_j$  é denotada por  $w_{ij}$ . A expressão (3.3) é ilustrada através do diagrama da Figura 3.11.



**Figura 3.11** - Gráfico do fluxo de sinal do potencial de entrada  $P_i$  do neurônio  $i$ .

A expressão (3.3) é considerada como sendo a versão discretizada no tempo da rede neural de Hopfield, e requer as seguintes observações:

- 1- A saída de cada neurônio retorna para todos os outros.
- 2- Não existe auto-retorno, ou seja,  $w_{ii} = 0$ .
- 3- A matriz de peso sináptico  $W$  é simétrica,  $w_{ij} = w_{ji}$ ; o efeito do neurônio  $i$  sobre o neurônio  $j$  é igual à do neurônio  $j$  sobre o neurônio  $i$ . Esta condição de simetria equivale a escrever  $W = W^T$ .

As duas primeiras condições são ilustradas na rede neural de Hopfield da Figura 3.9.

O interesse pelas redes neurais na solução de problemas de otimização combinatória se deve ao princípio de atualização dos estados dos neurônios, de acordo com as regras da expressão (3.1), a partir de um estado inicial qualquer, de tal modo que apenas um único neurônio seja atualizado por vez. Isto é expresso pela minimização sobre da função energia de Liapunov, definida por

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i v_j - \sum_{i=1}^N I_i v_i, \quad (3.4)$$

sob as condições:  $w_{ij} = w_{ji}$  e  $w_{ii} = 0$ , para todo  $1 \leq i, j \leq n$ , onde  $n$  representa o número de neurônios. Sendo a matriz de peso sináptico  $W$  uma matriz simétrica, é demonstrado que a função nunca é crescente quando o estado dos neurônios mudar. Trata-se de uma minimização local da função de Liapunov,  $E$ , que leva a um estado da rede estabilizado por meio do decréscimo permanente de  $E$ . O método não garante a obtenção do mínimo global (Hopfield 1982), uma vez que avançar em direção a um estado de menor energia do que o anterior pode levar apenas a um mínimo local da rede.

### 3.2.2 – Neurônio contínuo

As redes neurais podem também possuir neurônios que tem uma característica de resposta contínua (Hopfield 1982). Neste caso, existe um outro tipo de função de ativação, conforme a Figura 3.12.

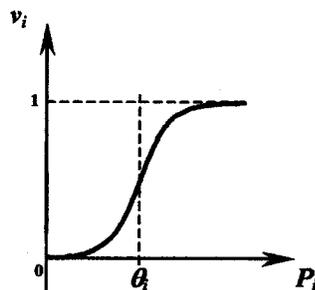


Figura 3.12 - Resposta do neurônio contínuo.

A vantagem do modelo contínuo sobre o modelo binário está na possível eficiência. O funcionamento da rede com neurônios binários requer que apenas um neurônio seja atualizado

por vez. A rede contendo neurônios contínuos permite o processamento paralelo dos vários neurônios.

De acordo com a Figura 3.12, a curva expressa o potencial de entrada  $P_i$ , utilizado para determinar o estado  $v_i$  de um neurônio contínuo  $N_i$ , cuja fórmula é dada por

$$v_i = [1 + e^{-\gamma(P_i - \theta_i)}]^{-1}. \quad (3.5)$$

$\theta_i$  é o potencial limiar de  $N_i$ . O parâmetro  $\gamma > 0$  representa o ganho da curva na vizinhança de  $P_i = \theta_i$ . Para o caso dos neurônios contínuos, o potencial de  $N_i$  é relacionado com os estados dos demais neurônios através da equação diferencial

$$C_i \frac{dP_i}{dt} = \sum_{j \neq i} w_{ij} v_j + I_i - \frac{P_i}{R_i}. \quad (3.6)$$

$C_i$  e  $R_i$  representam, respectivamente, a capacitância e a resistência do neurônio. Esta equação corresponde a uma modelagem segundo um circuito elétrico, onde o produto  $C_i R_i$  determina a constante de tempo na rede. Este produto está diretamente relacionado com a rapidez de estabilização da rede em um mínimo local da função  $E$ .

Caso exista um alto ganho, em que,  $\gamma \gg 1$ , mostra-se que a evolução dos neurônios no tempo conforme a equação (3.6), resulta numa minimização local da função  $E$ . Isto, desde que seja satisfeita a condição de simetria da matriz  $W$ , ou seja,  $w_{ij} = w_{ji}$  para todo  $1 \leq i, j \leq n$ , onde  $n$  representa o número de neurônios. Desta forma, a função energia  $E$  é dada aproximadamente por

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i v_j - \sum_{i=1}^N I_i v_i + \sum_{i=1}^N \frac{\theta_i}{R_i} v_i. \quad (3.7)$$

### 3.2.3 - Função de Liapunov

De acordo com Cohen & Grossberg (1983), para as redes neurais artificiais, a função de Liapunov é definida por

$$E = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N w_{ij} f(P_i) f(P_j) - \sum_{i=1}^N \int_0^{P_i} I_i f'(\tau) d\tau, \quad (3.8)$$

onde

$$v' = f'(\tau) = \frac{d}{d\tau} f(\tau) .$$

Para que a expressão (3.8) seja válida, é necessário que se estabeleça algumas condições, tais como:

1-As matrizes de peso sináptico das redes são simétricas,  $w_{ij} = w_{ji}$  ;

2-A função não-linear de entrada e saída  $f(P_i)$  deve satisfazer a condição de

$$\text{monotonicidade, } f'(P_i) = \frac{d}{dP_i} f(P_i) \geq 0.$$

Assim sendo, a função  $E$  de Liapunov para um sistema dinâmico definido pela expressão (3.8), satisfaz a condição  $\frac{dE}{dt} \leq 0$ , para  $P_i \neq 0$ , e o sistema é, portanto, teoricamente global e assintoticamente estável.

Considerando que  $I_i$  não depende de  $\tau$ , o segundo termo da expressão (3.8) se reduz a

$$\sum_{i=1}^N I_i \int_0^{P_i} f'(\tau) d\tau = \sum_{i=1}^N I_i [f(P_i) - f(0)] = \sum_{i=1}^N I_i f(P_i). \quad (3.9)$$

A expressão (3.9) pode ser escrita na forma da expressão (3.4).

Quando  $E$  representa uma função objeto a ser minimizada,  $\Delta E_i(t)$  é especificado como sendo a variação da função energia devido a diferença entre  $v_i(t-1)$  e  $v_i(t)$ . Neste caso, tem-se que:

$$\Delta v_i(t) = v_i(t) - v_i(t-1), \quad (3.10)$$

e

$$\Delta E_i(t) = E_i(t) - E_i(t-1). \quad (3.11)$$

Utilizando a expressão (3.4), a expressão acima é desenvolvida de acordo com as seguintes etapas:

$$\Delta E_i(t) = \left[ -\frac{1}{2} \sum_{i=1}^N \sum_{i \neq j=1}^N w_{ij} v_i(t) v_j(t) - \sum_{i=1}^N I_i v_i(t) \right] - \left[ -\frac{1}{2} \sum_{i=1}^N \sum_{i \neq j=1}^N w_{ij} v_i(t-1) v_j(t-1) - \sum_{i=1}^N I_i v_i(t-1) \right],$$

$$\Delta E_i(t) = - \sum_{i \neq j=1}^N w_{ij} v_i(t) v_j(t) - I_i v_i(t) + \sum_{i \neq j=1}^N w_{ij} v_i(t-1) v_j(t-1) + I_i v_i(t-1).$$

Colocando  $w_{ij}$  em evidência, tem-se que

$$\Delta E_i(t) = - \sum_{i \neq j=1}^N w_{ij} [v_i(t) - v_i(t-1)] v_j(t) - I_i [v_i(t) - v_i(t-1)]. \quad (3.12)$$

Substituindo a equação (3.10) na equação (3.12), se obtém:

$$\begin{aligned} \Delta E_i(t) &= - \sum_{i \neq j=1}^N w_{ij} \Delta v_i(t) v_j(t) - I_i \Delta v_i(t), \\ \Delta E_i(t) &= - \left[ \sum_{i \neq j=1}^N w_{ij} \Delta v_i(t) v_j(t) + I_i \Delta v_i(t) \right], \\ \Delta E_i(t) &= - \left[ \sum_{i \neq j=1}^N w_{ij} v_j(t) + I_i \right] \Delta v_i(t). \end{aligned} \quad (3.13)$$

Utilizando a expressão (3.3) pode-se ainda escrever que

$$\Delta E_i(t) = -P_i(t) \Delta v_i(t). \quad (3.14)$$

Analisando a expressão (3.10) e (3.1) conclui-se que:

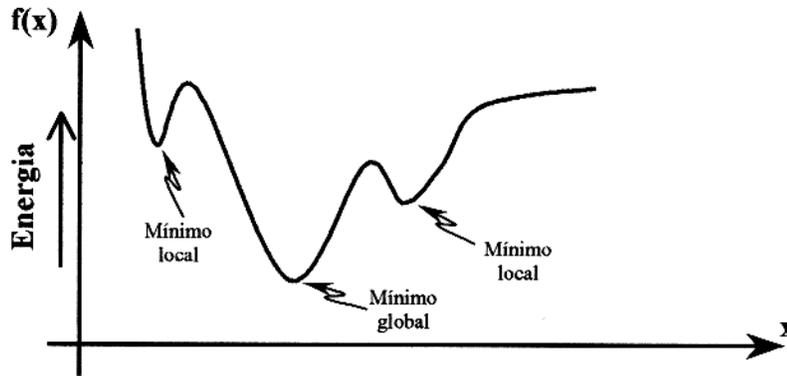
(a) Se  $\Delta v_i(t) = v_i(t) - v_i(t-1) < 0$

$$\begin{cases} v_i(t-1) = 1; \\ v_i(t) = 0; \\ P_i(t) \leq 0; \\ \Delta E_i(t) = -P_i(t) \Delta v_i(t) \leq 0. \end{cases} \quad (3.15)$$

(b) Se  $\Delta v_i(t) = v_i(t) - v_i(t-1) > 0$

$$\begin{cases} v_i(t-1) = 0; \\ v_i(t) = 1; \\ P_i(t) > 0; \\ \Delta E_i(t) = -P_i(t) \Delta v_i(t) < 0. \end{cases} \quad (3.16)$$

A partir das expressões (3.15) e (3.16) conclui-se que sempre ocorre  $\Delta E_i(t) \leq 0$ , qualquer que seja a condição de  $\Delta v_i(t)$ , significando que a rede sempre converge para um estado em que a função energia  $E$  é localmente minimizada.



**Figura 3.13** – Ilustração de uma função com mínimos locais e o mínimo global.

### 3.3 - MÉTODO DE DECONVOLUÇÃO DE WANG E MENDEL

Alguns métodos clássicos para a definição de filtros deconvolucionais são baseados na suposição de que o traço sísmico é parte de um processo estacionário, e em que a distribuição dos coeficientes de reflexão é aleatória. Essas suposições são admitidas para produzir resultados razoáveis, e elas são construídas na prática com dados sísmicos.

Filtros podem também ser projetados em um modo adaptativo. Isto é feito através da divisão do traço sísmico em janelas temporais aplicando um operador tempo-variante de deconvolução para cada janela isoladamente.

Um outro formalismo que não depende do princípio da estacionariedade do traço a ser filtrado, ou da aleatoriedade da seqüência dos coeficientes de reflexão, é fornecido através da aplicação das redes neurais.

Uma aplicação da rede de Hopfield para o problema da deconvolução do traço sísmico foi apresentado por Wang & Mendel (1992), analisado aqui com o objetivo de introduzir os fundamentos matemáticos para a rede neural de Hopfield desenvolvida nesta dissertação.

#### 3.3.2 - O problema de deconvolução com a rede de Hopfield

##### 3.3.2.1 - A rede neural para a recuperação da refletividade

Considerando o modelo convolucional simples,  $g_k$ , para um traço sísmico observado,  $z_k$ , de forma semelhante a equação (2.26), tem-se

$$g_k = \sum_{i=0}^N U_{k-i} \mu_i + n_k, \quad (k = 0, 1, 2, 3, \dots, N), \quad (3.17)$$

onde:  $\mu_i$  é a seqüência refletiva correspondendo à distribuição dos coeficientes de reflexão;  $U_k$  é o pulso fonte (*wavelet*), causal,  $U_k = 0$  para  $k < 0$ ;  $n_k$  é o ruído aditivo;  $N$  é a quantidade de pontos do sismograma.

O erro médio-quadrático do traço sísmico é definido por

$$E = \frac{1}{2} \sum_{k=1}^N (z_k - g_k)^2, \quad (3.18)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k - \sum_{i=1}^N U_{k-i} \mu_i \right)^2. \quad (3.19)$$

A minimização da função  $E$  permite estimar a refletividade simples e o pulso fonte de forma separada.

O valor da seqüência,  $\mu_i$ , é dado na forma do produto

$$\mu_i = v_i r_i, \quad (3.20)$$

onde  $v_i$  é uma seqüência  $[0,1]$  que pode ser gerada por forma aleatória ou determinística e indica as posições da seqüência  $\mu_i$ , e  $r_i$  é uma seqüência determinística ou aleatória, e representa a magnitude da seqüência  $\mu_i$ .

São determinados  $v_i$  e  $r_i$  separadamente, cada qual pela sua própria rede neural de Hopfield. Em primeiro lugar, ajusta-se  $r_i$  na expressão (3.20) como sendo igual a uma constante  $\alpha$ , substitui-se então  $\mu_i = v_i \alpha$  na expressão (3.19) e constroe-se uma rede neural de Hopfield para o resultado da função erro. Esta rede fornece estimativas de  $v_i$  que indica as localizações dos coeficientes de reflexão que tem uma grandeza correspondente à  $\alpha$ . Em segundo lugar, ajusta-se  $v_i$  na expressão (3.20) igual apenas para o  $v_i$  estimado, substitui-se  $\mu_i = v_i r_i$  na expressão (3.19), e monta-se uma rede neural de Hopfield para a função erro correspondente. Esta rede neural nos fornece os valores estimados de  $r_i$ . Em terceiro lugar, as reflexões correspondentes a  $\alpha$  são detectadas, e seus valores estimados são removidos do traço. Este traço atualizado é usado para formar um novo erro que é usado para detectar as reflexões correspondentes ao próximo  $\alpha$ . Pela variação da constante  $\alpha$ , as localizações e valores de todas as reflexões são determinadas.

Fazendo  $r_i$  igual a  $\alpha$  na equação (3.20), ou seja,  $\mu_i = v_i \alpha$ , e substituindo o resultado na expressão (3.19), então,

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k - \sum_{i=1}^N U_{k-i} v_i \alpha \right)^2. \quad (3.21)$$

Desenvolvendo a expressão acima tem-se as seguinte etapas:

$$E = \frac{\alpha^2}{2} \sum_{k=1}^N \left( \frac{z_k}{\alpha} - \sum_{i=1}^N U_{k-i} v_i \right)^2, \quad (3.22)$$

$$E = \frac{\alpha^2}{2} \sum_{k=1}^N \left[ \left( \frac{z_k}{\alpha} \right)^2 - 2 \frac{z_k}{\alpha} \sum_{i=1}^N U_{k-i} v_i + \left( \sum_{i=1}^N U_{k-i} v_i \right)^2 \right], \quad (3.23)$$

$$E = \frac{\alpha^2}{2} \sum_{k=1}^N \left( \frac{z_k^2}{\alpha^2} - 2 \frac{z_k}{\alpha} \sum_{i=1}^N U_{k-i} v_i + \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i \right), \quad (3.24)$$

$$E = \frac{\alpha^2}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} - 2 \frac{\alpha^2}{2} \sum_{k=1}^N \frac{z_k}{\alpha} \sum_{i=1}^N U_{k-i} v_i + \frac{\alpha^2}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i. \quad (3.25)$$

Dividindo a equação (3.25) por  $\alpha^2$ , o que não altera a relação desejada para a função energia, tem-se que

$$E = \frac{1}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} - \sum_{k=1}^N \sum_{i=1}^N \frac{z_k}{\alpha} U_{k-i} v_i + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i. \quad (3.26)$$

Comparando as expressões (3.26) e (3.4), observa-se que o primeiro termo na expressão (3.4) não possui o termo  $w_{ii}$ , e a expressão (3.26) possui o termo para  $i = j$ . Por ser a função de

Liapunov [expressão (3.4)], equivalente a  $E = -\frac{1}{2} \sum_{i=1}^N \sum_{i \neq j=1}^N w_{ij} v_i v_j - \sum_{i=1}^N I_i v_i$ , onde  $w_{ii} \equiv 0$  para

$i = 1, 2, \dots, N$ , o termo  $A = -\frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N U_{k-i}^2 v_i (v_i - 1)$  pode se acrescentado na expressão (3.26), e

não afetar a mesma. Sendo  $v_i$  um valor igual a 0 ou 1, o termo adicional resulta num valor igual a zero, não influenciando o valor de  $E$ . Desenvolvendo o termo adicional  $A$  encontra-se que

$$A = -\frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N U_{k-i}^2 v_i v_i + \frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N U_{k-i}^2 v_i. \quad (3.27)$$

Com isto, a expressão (3.26) passa para a forma:

$$E = \frac{1}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} - \sum_{k=1}^N \sum_{i=1}^N \frac{z_k}{\alpha} U_{k-i} v_i + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i + A \quad (3.28)$$

A expressão (3.28) tem o seguinte desenvolvimento:

$$E = \frac{1}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} - \sum_{k=1}^N \sum_{i=1}^N \frac{z_k}{\alpha} U_{k-i} v_i + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i - \frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N U_{k-i} U_{k-i} v_i v_i + \frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N U_{k-i}^2 v_i \quad (3.29)$$

Agrupando os termos da expressão acima, tem-se que:

$$E = \frac{1}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} - \sum_{k=1}^N \sum_{i=1}^N \frac{z_k}{\alpha} U_{k-i} v_i + \frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N U_{k-i}^2 v_i + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i - \frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N U_{k-i} U_{k-i} v_i v_i \quad (3.30)$$

Esta expressão pode ser escrita na seguinte forma:

$$E = \frac{1}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} - \sum_{i=1}^N \left( \sum_{k=1}^N U_{k-i} v_i \frac{z_k}{\alpha} - \frac{1}{2} \sum_{k=1}^N U_{k-i}^2 v_i \right) + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i \quad (3.31)$$

Ou ainda:

$$E = \frac{1}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} - \sum_{i=1}^N \left( \sum_{k=1}^N U_{k-i} \frac{z_k}{\alpha} - \frac{1}{2} \sum_{k=1}^N U_{k-i}^2 \right) v_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \left( \sum_{k=1}^N U_{k-i} U_{k-j} \right) v_i v_j, \quad (3.32)$$

onde

$$\frac{1}{2} \sum_{k=1}^N \frac{z_k^2}{\alpha^2} = \text{Constante.}$$

A expressão (3.32) é a função  $E$  que é usada na construção da rede neural de Hopfield para detectar a seqüência dos coeficientes de reflexão.

Comparando a expressão (3.32) com a expressão (3.4), e desprezando o termo constante, verifica-se que

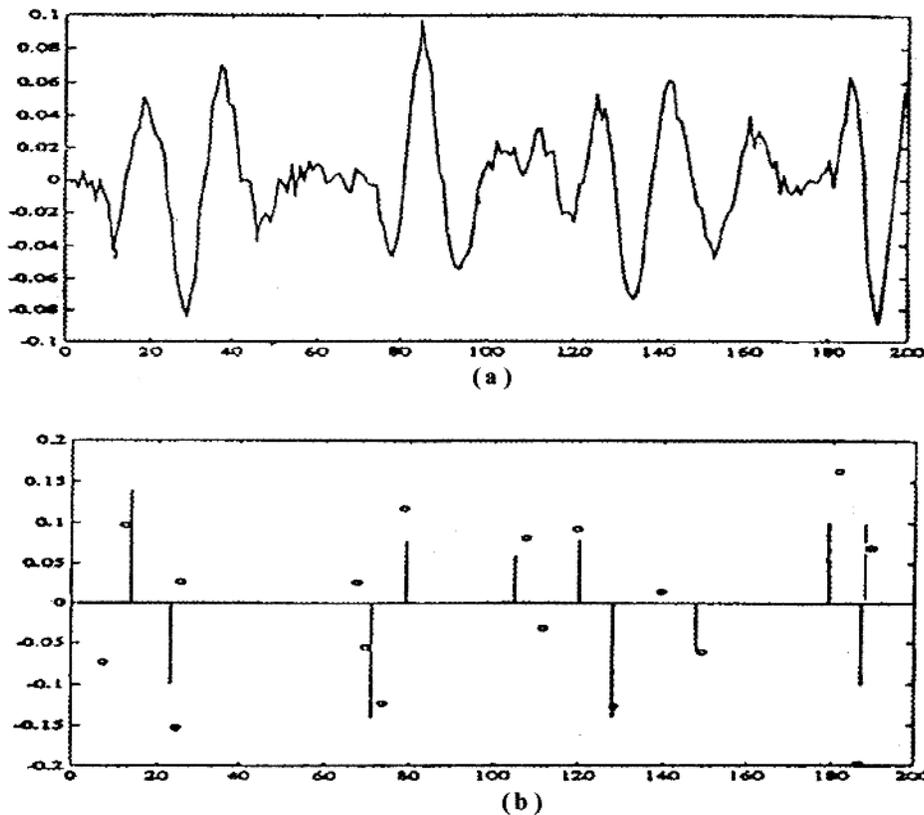
$$w_{ij} = - \sum_{k=1}^N U_{k-i} U_{k-j} \quad (3.33)$$

e

$$I_i = \sum_{k=1}^N U_{k-i} \frac{z_k}{\alpha} - \frac{1}{2} \sum_{k=1}^N U_{k-i}^2 \quad (3.34)$$

para  $i \neq j$ , em que  $1 \leq i, j \leq N$ ; e  $w_{ii} = 0$  para  $i = 1, 2, \dots, N$ .

A rede neural, com os conectivos ponderados determinados pela expressão (3.33) e as entradas determinada pela expressão (3.34), pode ser vista como um detetor de reflexões que tem uma magnitude que corresponde a  $\alpha$  (Figura 3.14). Os valores verdadeiros desses coeficientes não são iguais a  $\alpha$ .



**Figura 3.14** – Deconvolução segundo Wang & Mendel (1992). (a) Traço sísmico sintético; (b) Resultado de Wang & Mendel: Os coeficientes de reflexão verdadeiros são representados por círculos (o), e os coeficientes de reflexão recuperados estão mostrados em linha contínua (—).

### 3.3.2.2 - A rede neural para a extração do pulso-fonte

Supondo  $U_0 = 0$  e  $\mu_i = 0$  para  $i \leq 0$ , a expressão (3.19) pode ser reescrita na forma

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k - \sum_{i=1}^N \mu_{k-i} U_i \right)^2. \quad (3.35)$$

Em seguida  $U_i$  é normalizado de tal modo a satisfazer  $|U_i| \leq 1$ . Assim sendo,  $U_i$  pode ser expresso de forma aproximada de acordo com a seguinte expressão

$$U_i = \left( \sum_{j=1}^M \frac{1}{2^{j-1}} x_{ij} \right) - 1, \quad (3.36)$$

onde  $x_{ij}$  representa a saída dos neurônios,  $i=1,2,3,\dots,N$  e  $j=1,2,3,\dots,M$ .

Deste modo, substituindo a expressão (3.36) na expressão (3.35), tem-se as seguintes etapas:

$$E = \frac{1}{2} \sum_{k=1}^N \left\{ z_k - \sum_{i=1}^N \mu_{k-i} \left[ \left( \sum_{j=1}^M \frac{1}{2^{j-1}} x_{ij} \right) - 1 \right] \right\}^2, \quad (3.37)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left[ z_k + \sum_{i=1}^N \mu_{k-i} - \sum_{i=1}^N \sum_{j=1}^M \mu_{k-i} \frac{1}{2^{j-1}} x_{ij} \right]^2, \quad (3.38)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left[ \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) - \left( \sum_{i=1}^N \sum_{j=1}^M \mu_{k-i} \frac{1}{2^{j-1}} x_{ij} \right) \right]^2, \quad (3.39)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left[ \left( z_k + \sum_{i=1}^N \mu_{k-i} \right)^2 - 2 \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) \left( \sum_{i=1}^N \sum_{j=1}^M \mu_{k-i} \frac{1}{2^{j-1}} x_{ij} \right) + \left( \sum_{i=1}^N \sum_{j=1}^M \mu_{k-i} \frac{1}{2^{j-1}} x_{ij} \right)^2 \right], \quad (3.40)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k + \sum_{i=1}^N \mu_{k-i} \right)^2 - \sum_{k=1}^N \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) \left( \sum_{i=1}^N \sum_{j=1}^M \mu_{k-i} \frac{1}{2^{j-1}} x_{ij} \right) + \frac{1}{2} \sum_{k=1}^N \left( \sum_{i=1}^N \sum_{j=1}^M \mu_{k-i} \frac{1}{2^{j-1}} x_{ij} \right)^2, \quad (3.41)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k + \sum_{i=1}^N \mu_{k-i} \right)^2 - \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{2^{j-1}} \mu_{k-i} x_{ij} \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j_1=1}^M \sum_{j_2=1}^M \mu_{k-i} \frac{1}{2^{j_1-1}} x_{ij_1} \mu_{k-i_2} \frac{1}{2^{j_2-1}} x_{i_2 j_2}. \quad (3.42)$$

Para que os elementos da diagonal principal da matriz de conexão seja igual a zero, adiciona-se o termo  $B = -\frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{4^{j-1}} \mu_{k-i}^2 x_{ij} (x_{ij} - 1)$  na equação (3.42). Uma vez que  $x_{ij} = 0$  ou 1, esse termo é igual a zero e não comprometendo o resultado final. Assim sendo, desenvolvendo o termo adicional  $B$ , encontra-se que

$$B = -\frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{4^{j-1}} \mu_{k-i} \mu_{k-i} x_{ij} x_{ij} + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{4^{j-1}} \mu_{k-i}^2 x_{ij}. \quad (3.43)$$

Substituindo a expressão (3.43) em (3.42), tem-se as seguintes etapas:

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k + \sum_{i \in I_\alpha} \mu_{k-i} \right)^2 - \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{2^{j-1}} \mu_{k-i} x_{ij} \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j_1=1}^M \sum_{i=1}^M \mu_{k-i_1} \frac{1}{2^{j_1-1}} x_{i_1 j_1} \mu_{k-i_2} \frac{1}{2^{j_2-1}} x_{i_2 j_2} + B; \quad (3.44)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k + \sum_{i=1}^N \mu_{k-i} \right)^2 - \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{2^{j-1}} \mu_{k-i} x_{ij} \left( z_k + \sum_{i \in I_\alpha} \mu_{k-i} \right) + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j_1=1}^M \sum_{i=1}^M \mu_{k-i_1} \frac{1}{2^{j_1-1}} x_{i_1 j_1} \mu_{k-i_2} \frac{1}{2^{j_2-1}} x_{i_2 j_2} - \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{4^{j-1}} \mu_{k-i} \mu_{k-i} x_{ij} x_{ij} + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^M \frac{1}{4^{j-1}} \mu_{k-i}^2 x_{ij}; \quad (3.45)$$

$$E = \frac{1}{2} \sum_{k=1}^N \left( z_k + \sum_{i=1}^N \mu_{k-i} \right)^2 - \sum_{i=1}^N \sum_{j=1}^M \sum_{k=1}^N \left[ \frac{1}{2^{j-1}} \mu_{k-i} \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) - \frac{1}{2} \frac{1}{4^{j-1}} \mu_{k-i}^2 \right] x_{ij} + \frac{1}{2} \sum_{i=1}^N \sum_{j_1=1}^M \sum_{i_1 \neq i_2=1}^M \sum_{j_2=1}^M \sum_{k=1}^N \frac{1}{2^{j_1-1}} \mu_{k-i_1} x_{i_1 j_1} \frac{1}{2^{j_2-1}} \mu_{k-i_2} x_{i_2 j_2}. \quad (3.46)$$

O primeiro termo da expressão (3.46),  $\frac{1}{2} \sum_{k=1}^N \left( z_k + \sum_{i=1}^N \mu_{k-i} \right)^2$ , é constante.

Comparando a expressão (3.46) com a expressão (3.4), e não levando em consideração o termo constante, conclui-se que:

$$W_{i_1 j_1, i_2 j_2} = - \sum_{k=1}^N \frac{1}{2^{j_1-1}} \mu_{k-i_1} \frac{1}{2^{j_2-1}} \mu_{k-i_2}, \quad (3.47)$$

$$I_{ij} = \sum_{k=1}^N \left[ \frac{1}{2^{j-1}} \mu_{k-i} \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) - \frac{1}{2} \frac{1}{4^{j-1}} \mu_{k-i}^2 \right], \quad (3.48)$$

para  $i_1 \neq i_2$  e  $j_1 \neq j_2$ , onde  $1 \leq i_1, i_2 \leq N$ ,  $1 \leq j_1, j_2 \leq M$ ; e  $W_{ij,ij} = 0$  para  $i = 1, 2, 3, \dots, N$  e  $j = 1, 2, 3, \dots, M$ .

A representação da função  $E$ , utilizada na extração do pulso fonte, tem a forma :

$$E = -\frac{1}{2} \sum_{i_1=1}^N \sum_{j_1=1}^M \sum_{i_2=1}^N \sum_{j_2=1}^M W_{i_1 j_1, i_2 j_2} x_{i_1 j_1} x_{i_2 j_2} - \sum_{i=1}^N \sum_{j=1}^M I_{ij} x_{ij}. \quad (3.49)$$

O pulso fonte extraído possui  $N \times M$  neurônios, onde  $M$  é o número de neurônios que determina a amplitude pulso fonte  $U_k$  num ponto temporal onde existem  $N$  pontos temporais.

Pode haver ainda uma simplificação desta rede. Para isto é necessário considerar que  $U_k \approx 0$  para  $k > L$  em que  $L \ll N$ , desta forma, a rede tem  $L \times M$  neurônios. A equação (3.48), que corresponde às entradas externas, assume uma nova forma representada pela seguinte expressão:

$$I_{ij} = \sum_{k=1}^N \left[ \frac{1}{2^{j-1}} \mu_{k-i} \left( z_k + \sum_{i=1}^N \mu_{k-i} \right) - \frac{1}{2} \frac{1}{4^{j-1}} \mu_{k-i}^2 \right] + \sum_{p=L+1}^N W_{i j_1, i_2 j_2}. \quad (3.50)$$

onde  $1 \leq i, p \leq L$  e  $1 \leq j, q \leq M$ .

Embora tenha sido usado dois índices para o neurônio  $x_{ij}$ , pode-se também representá-lo usando apenas um único índice

$$s = (i-1)M + j, \quad (3.51)$$

onde  $i = 1, 2, \dots, N$  e  $j = 1, 2, \dots, M$ , de modo que  $s = 1, 2, \dots, N \times M$ . Desta maneira os  $N \times M$  neurônios são totalmente conectados entre si. Assim sendo, a expressão (3.47) pode ser representada por apenas dois índices, que são:

$$s_1 = (i_1 - 1)M + j_1 \quad (3.52)$$

e

$$s_2 = (i_2 - 1)M + j_2. \quad (3.53)$$

Na expressão (3.48),  $I_{ij}$  pode da mesma forma ser representado por apenas um índice dado por

$$s = (i-1)M + j, \quad (3.54)$$

onde  $1 \leq i_1, i_2, i \leq N$  e  $1 \leq j_1, j_2, j \leq M$ , assim como  $1 \leq s_1, s_2, s \leq N \times M$ .

## 4 - A DECONVOLUÇÃO COM A REDE NEURAL DISCRETA (RND)

A rede tradicional de Hopfield mostra uma deficiência na detecção das verdadeiras polaridades dos coeficientes de reflexão. No modelo da sua função de ativação ocorre apenas uma detecção unipolar desses coeficientes, não revelando as suas amplitudes verdadeiras, Wang & Mendel (1992). Com o objetivo de suprir esta deficiência, é apresentado neste capítulo uma rede neural que pode ser tratada como uma forma variante da rede tipo recorrente, designada aqui como rede neural discreta (RND). Os seus parâmetros, tais como potencial de entrada, função de ativação e função de Liapunov, são redefinidos para transformá-la em uma rede neural especializada para a solução do problema de posicionamento em profundidade, (ou no tempo) dos refletores “verdadeiros” no traço sísmico, através da introdução de uma outra dinâmica de operação para a rede de Hopfield, como descrita detalhadamente.

### 4.1- POTENCIAL DE ENTRADA OU ATIVAÇÃO

O potencial de entrada  $[P_k(t)]$  definido para a rede discreta é dado por

$$P_k(t) = \sum_{i=1}^N w_{ki} v_i(t). \quad (4.1)$$

$W=[w_{ij}]$  representa a matriz de pesos sinápticos, e por definição tem as seguintes propriedades:  $w_{ki} = w_{ik}$  e  $w_{kk} \geq 0$ .  $v_k$  representa o estado dos neurônios e assume valores discretos no conjunto  $\{-1,0,1\}$ , a depender de um parâmetro externo  $I_k$ , definido através da função de Liapunov. Esta descreve o comportamento dinâmico da rede com a variação dos estados  $v_k$  dados pela função de ativação característica desse tipo de rede, e o problema específico a ser tratado.

O potencial de entrada traduz a influência de todos os outros neurônios da rede sobre a saída de um neurônio particular  $k$ . Sob esse ponto de vista, a expressão potencial se refere exclusivamente à capacidade do neurônio produzir um sinal de saída.

### 4.2 - FUNÇÃO DE ATIVAÇÃO

A função de ativação, utilizada no desenvolvimento da rede neural discreta, se caracteriza pela possibilidade dos estados dos seus neurônios pertencerem ao conjunto  $\{-1,0,1\}$ . Isto a torna efetivamente diferente da função de ativação original de Hopfield descrita no Capítulo 3, por meio da equação (3.1).

A função de ativação da RND, mostrada na Figura 4.1, indica uma nova dinâmica para a variação dos estados dos neurônios no tempo por meio da expressão (4.2). Nesta expressão, o parâmetro controlador dos novos estados dos neurônios  $[v_k(t)]$  no tempo  $t$  é representado pelo parâmetro livre  $I_k$ , chamado aqui de entrada externa. De forma diferente do conceito natural de entrada externa desenvolvido nas bases da formulação das redes neurais artificiais, no caso da RND, o parâmetro externo é característico da função de Liapunov  $E$ , e, conseqüentemente, sua natureza é inerente ao problema a ser tratado.

$$v_k(t) = f[P_k(t-1)] = \begin{cases} 1, & \text{se } P_k(t-1) \geq I_k \\ 0, & \text{se } -I_k < P_k(t-1) < I_k \\ -1, & \text{se } P_k(t-1) \leq -I_k \end{cases} \quad (4.2)$$

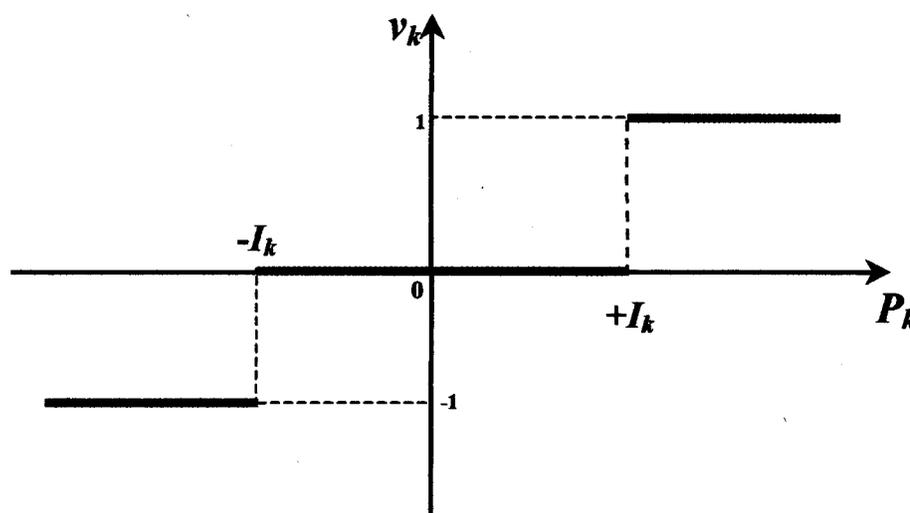


Figura 4.1 – Função de ativação  $v_k$  versus  $P_k$ .

### 4.3 - FUNÇÃO DE LIAPUNOV

Para completar a conceituação teórica da rede neural discreta, é considerado uma forma variante da função de Liapunov das redes recorrentes clássicas, escrita na forma

$$E = -\sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i v_j + 2 \sum_{i=1}^N I_i v_i, \quad (4.3)$$

para  $v_k$  dado por

$$v_k = f\left(\sum_{i=1}^N w_{ki} v_i\right) = f(P_k), \quad (4.4)$$

onde  $f$  representa a função de ativação definida na expressão (4.2).

A variação  $\Delta E$  associada à dinâmica de toda a rede, devido à mudança do estado de um neurônio  $k$  é escrita na forma

$$\Delta E_k(t) = E_k(t) - E_k(t-1). \quad (4.5)$$

Substituindo a expressão (4.3) na equação (4.5), tem-se que:

$$\Delta E_i(t) = -\sum_{j=1}^N \sum_{i=1}^N w_{ij} v_i(t) v_j(t-1) + 2 \sum_{i=1}^N I_i v_i(t) - \left[ -\sum_{j=1}^N \sum_{i=1}^N w_{ij} v_i(t-1) v_j(t-1) + 2 \sum_{i=1}^N I_i v_i(t-1) \right]. \quad (4.6)$$

Para a variação de um neurônio  $k$ , tem-se o seguinte desenvolvimento:

$$\begin{aligned} \Delta E_k(t) = & -\sum_{j=1}^N w_{kj} v_k(t) v_j(t-1) - \sum_{i \neq k=1}^N \sum_{j=1}^N w_{ij} v_i(t-1) v_j(t-1) + 2I_k v_k(t) + 2 \sum_{i \neq k=1}^N I_i v_i(t-1) + \\ & + \sum_{j=1}^N w_{kj} v_k(t-1) v_j(t-1) + \sum_{i \neq k=1}^N \sum_{j=1}^N w_{ij} v_i(t-1) v_j(t-1) - 2I_k v_k(t-1) - 2 \sum_{i \neq k=1}^N I_i v_i(t-1), \end{aligned} \quad (4.7)$$

que simplifica para

$$\Delta E_k(t) = -\sum_{j=1}^N w_{kj} v_k(t) v_j(t-1) + \sum_{j=1}^N w_{kj} v_k(t-1) v_j(t-1) + 2I_k [v_k(t) - v_k(t-1)]. \quad (4.8)$$

Considerando os termos simétricos da matriz de peso sináptico  $W$ , introduz-se uma constante multiplicativa no 1º e no 2º termo da expressão (4.8), de modo que

$$\Delta E_k(t) = -2v_k(t) \sum_{j=1}^N w_{kj} v_j(t-1) + 2v_k(t-1) \sum_{j=1}^N w_{kj} v_j(t-1) + 2I_k [v_k(t) - v_k(t-1)], \quad (4.9)$$

e que resume para

$$\Delta E_k(t) = 2[v_k(t-1) - v_k(t)] \left[ \sum_{j=1}^N w_{kj} v_j(t-1) - I_k \right]. \quad (4.10)$$

Utilizando a expressão (4.1), pode-se escrever que

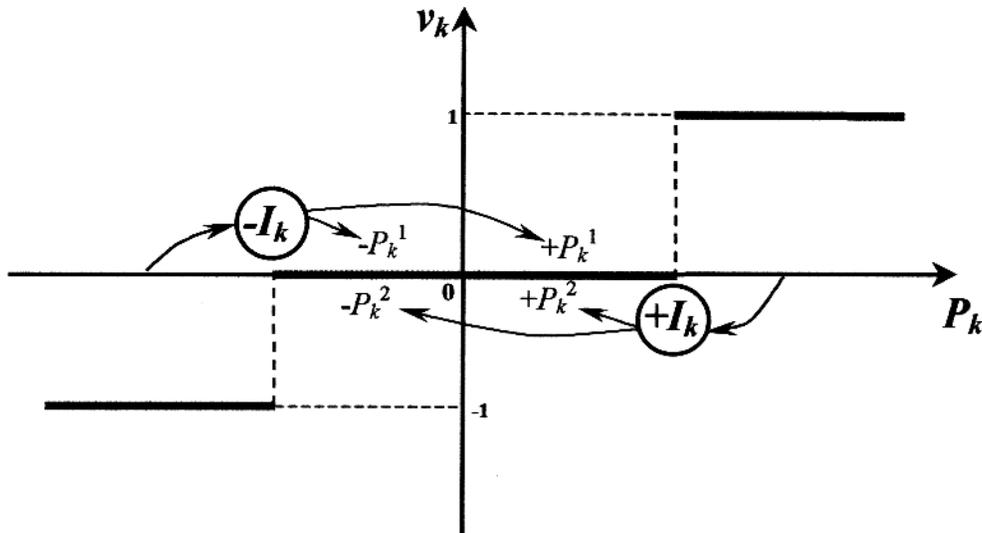
$$\Delta E_k(t) = 2[v_k(t-1) - v_k(t)] [P_k(t-1) - I_k], \quad (4.11)$$

ou ainda que

$$\Delta E_k(t) = -2\Delta v_k [P_k(t-1) - I_k] , \quad (4.12)$$

onde  $\Delta v_k$  representa a variação do estado do neurônio  $v_k$ .

#### 4.4 - VARIAÇÃO DA FUNÇÃO DE LIAPUNOV



**Figura 4.2** – Transição dos estados de um neurônio  $k$ .

Analisando as expressões (4.2) e (4.11) chega-se às propriedades descritas a seguir:

**(a)** Para  $v_k(t-1) = -1$  e  $v_k(t) = 0$ , a variação de  $P_k$  ocorre na vizinhança de  $-I_k$ , conforme representado na Figura 4.2, ocasionando a seguinte variação para a função de Liapunov:

$$\Delta E_k(t) = 2[v_k(t-1) - v_k(t)] [P_k(t-1) - I_k] ,$$

$$\Delta E_k(t) = 2(-1-0) \begin{cases} -P_k^1(t-1) - (-I_k) \\ +P_k^1(t-1) - (-I_k) \end{cases} ,$$

$$\Delta E_k(t) = 2[\text{valor}(-)] \begin{cases} \text{valor}(+) \\ \text{valor}(+) \end{cases} \Rightarrow \Delta E_k(t) < 0 . \quad (4.13)$$

**(b)** Para  $v_k(t-1) = 1$  e  $v_k(t) = 0$ , a variação de  $P_k$  ocorre na vizinhança de  $+I_k$ , conforme representado na Figura 4.2, ocasionando a seguinte variação para a função de Liapunov:

$$\begin{aligned}\Delta E_k(t) &= 2[v_k(t-1) - v_k(t)][P_k(t-1) - I_k] , \\ \Delta E_k(t) &= 2(1-0) \begin{cases} -P_k^2(t-1) - I_k \\ +P_k^2(t-1) - I_k \end{cases} , \\ \Delta E_k(t) &= 2[\text{valor}(+)] \begin{cases} \text{valor}(-) \\ \text{valor}(-) \end{cases} \Rightarrow \Delta E_k(t) < 0 .\end{aligned}\quad (4.14)$$

(c) Para  $v_k(t-1)=0$  e  $v_k(t)=1$ , a variação de  $P_k$  ocorre na vizinhança de  $+I_k$ , conforme representado na Figura 4.2, ocasionando a seguinte variação para a função de Liapunov:

$$\begin{aligned}\Delta E_k(t) &= 2[v_k(t-1) - v_k(t)][P_k(t-1) - I_k] , \\ \Delta E_k(t) &= 2(0-1)[P_k(t-1) - I_k] , \\ \Delta E_k(t) &= 2[\text{valor}(-)][\text{valor}(+)] \Rightarrow \Delta E_k(t) < 0 .\end{aligned}\quad (4.15)$$

(d) Para  $v_k(t-1)=1$  e  $v_k(t)=-1$ , a variação de  $P_k$  ocorre na vizinhança de  $+I_k$ , conforme representado na Figura 4.2, ocasionando a seguinte variação para a função de Liapunov:

$$\begin{aligned}\Delta E_k(t) &= 2[v_k(t-1) - v_k(t)][P_k(t-1) - I_k] , \\ \Delta E_k(t) &= 2(1+1)[P_k(t-1) - I_k] , \\ \Delta E_k(t) &= 2[\text{valor}(+)][\text{valor}(-)] \Rightarrow \Delta E_k(t) < 0 .\end{aligned}\quad (4.16)$$

(e) Para  $v_k(t-1)=-1$  e  $v_k(t)=1$ , a variação de  $P_k$  ocorre na vizinhança de  $-I_k$ , conforme representado na Figura 4.2, ocasionando a seguinte variação para a função de Liapunov:

$$\begin{aligned}\Delta E_k(t) &= 2[v_k(t-1) - v_k(t)][P_k(t-1) - I_k] , \\ \Delta E_k(t) &= 2(-1-1)[P_k(t-1) - (-I_k)] , \\ \Delta E_k(t) &= 2[\text{valor}(-)][\text{valor}(+)] \Rightarrow \Delta E_k(t) < 0 .\end{aligned}\quad (4.17)$$

(f) Para  $v_k(t-1)=0$  e  $v_k(t)=-1$ , a variação de  $P_k$  ocorre na vizinhança de  $-I_k$ , conforme representado na Figura 4.2, ocasionando a seguinte variação para a função de Liapunov:

$$\begin{aligned}\Delta E_k(t) &= 2[v_k(t-1) - v_k(t)][P_k(t-1) - I_k] , \\ \Delta E_k(t) &= 2(0+1)[P_k(t-1) - (-I_k)] , \\ \Delta E_k(t) &= 2[\text{valor}(+)][\text{valor}(-)] \Rightarrow \Delta E_k(t) < 0 .\end{aligned}\quad (4.18)$$

Observa-se, a partir das expressões (4.13), (4.14), (4.15), (4.16), (4.17) e (4.18), que sempre ocorre um decréscimo da função de Liapunov  $E$ , uma vez que  $\Delta E_k(t)$  é sempre negativo, qualquer que seja a condição de  $v(t)$  e  $v(t-1)$ . Neste caso, comprova-se que a rede sempre converge para um estado onde a função de Liapunov é localmente minimizada.

## 5 - RND PARA A RECUPERAÇÃO DA DISTRIBUIÇÃO DOS COEFICIENTES DE REFLEXÃO

Nesta seção é desenvolvida a arquitetura, definidos os parâmetros livres e a função de Liapunov característicos da RND, especializada para a recuperação da seqüência dos coeficientes de reflexão a partir do sismograma. Esta rede é construída sem qualquer condição *a priori* sobre a seqüência dos coeficientes, e sem qualquer premissa estatística sobre o ruído presente nos dados. Ruído pode ser um processo tipicamente aleatório ou determinístico. Deste modo, é possível obter toda a informação necessária a partir do conhecimento do pulso fonte para qualquer modelo de reflexão sísmica.

A avaliação operacional desta arquitetura de rede neural é realizada sobre dados sintéticos gerados com o modelo convolucional simples, ondas planas, num meio estratificado formado de camadas homogêneas e isotrópicas, e também usando a teoria assintótica do raio.

### 5.1 – PARÂMETROS LIVRES E A FUNÇÃO DE LIAPUNOV

Para a utilização prática de uma rede neural, principalmente para as redes do tipo recorrente, que é o caso da RND, o passo fundamental é a definição dos parâmetros que descrevem o problema a ser tratado e a sua associação à função de Liapunov que descreve a dinâmica do processamento da rede neural. Deste modo, a solução do problema deve necessariamente estar associada a um estado estável dos neurônios da rede, que correspondem a um mínimo local da função de Liapunov. Assim, utiliza-se o modelo convolucional simples para representar o traço sísmico na determinação da matriz de pesos sinápticos  $W$  e da entrada externa  $I$  da rede neural.

O traço é dado pela convolução do pulso fonte,  $U_k$ , com a refletividade simples do meio,  $v_i$ , escrito na forma

$$g_k = \sum_{i=1}^N U_{k-i} v_i, \quad (k = 1, 2, 3, \dots, N), \quad (5.1)$$

onde:  $U_k = 0$  para  $k < 0$  e  $N =$  número de pontos do sismograma. A função objeto de minimização que caracteriza a função de Liapunov característica do problema é representada pela soma dos quadrados dos desvios erro entre o traço observado  $z_k$  e o traço computado  $g_k$ , interpretada como a estimativa da variância, e ela é dada por

$$E = \sum_{k=1}^N (z_k - g_k)^2. \quad (5.2)$$

Isto equivale a

$$E = \sum_{k=1}^N \left( z_k - \sum_{i=1}^N U_{k-i} v_i \right)^2. \quad (5.3)$$

O objetivo é obter uma estimativa da seqüência dos coeficientes de reflexão a partir da minimização da função objeto  $E$ .

A distribuição  $v_i$  é dada na forma de uma seqüência discreta de valores  $\{-1,0,1\}$  que pode ser aleatória ou determinística. Desenvolvendo a expressão (5.3) tem-se as seguintes etapas:

$$E = \sum_{k=1}^N \left( z_k - \sum_{i=1}^N U_{k-i} v_i \right)^2, \quad (5.4)$$

$$E = \sum_{k=1}^N \left[ (z_k)^2 - 2z_k \sum_{i=1}^N U_{k-i} v_i + \left( \sum_{i=1}^N U_{k-i} v_i \right)^2 \right], \quad (5.5)$$

$$E = \sum_{k=1}^N \left( z_k^2 - 2z_k \sum_{i=1}^N U_{k-i} v_i + \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i \right), \quad (5.6)$$

$$E = \sum_{k=1}^N z_k^2 - 2 \sum_{k=1}^N z_k \sum_{i=1}^N U_{k-i} v_i + \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N U_{k-j} v_j U_{k-i} v_i. \quad (5.7)$$

A expressão (5.7) pode ser comparada com a função de Liapunov correspondente à expressão (4.3), onde  $E = -\sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i v_j + 2 \sum_{i=1}^N I_i v_i$ , em que,  $w_{ii} \geq 0$ , (como mostrado no

apêndice A) e,  $w_{ij} = w_{ji}$ , para  $i = 1, 2, \dots, N$ . Como  $\sum_{k=1}^N z_k^2$  é constante, a expressão (5.7)

representa a função de Liapunov  $E$ , que é usada na construção da RND para detectar a seqüência de coeficientes de reflexão.

Comparando a expressão (5.7) com a expressão (4.3), desprezando o termo constante, verifica-se que

$$w_{ij} = -\sum_{k=1}^N U_{k-i} U_{k-j} \quad (5.8)$$

e

$$I_i = -\sum_{k=1}^N U_{k-i} z_k \quad (5.9)$$

para  $i \neq j$ , em que  $1 \leq i, j \leq N$ ; e  $w_{ii} \geq 0$  para  $i = 1, 2, \dots, N$ .

A rede neural com os pesos conectivos ponderados determinados pela expressão (5.8) e as entradas determinadas pela expressão (5.9), pode ser vista como um detetor de todas as reflexões contidas no traço sísmico. A magnitude dos coeficientes de reflexão são determinadas pelos seus valores no sismograma.

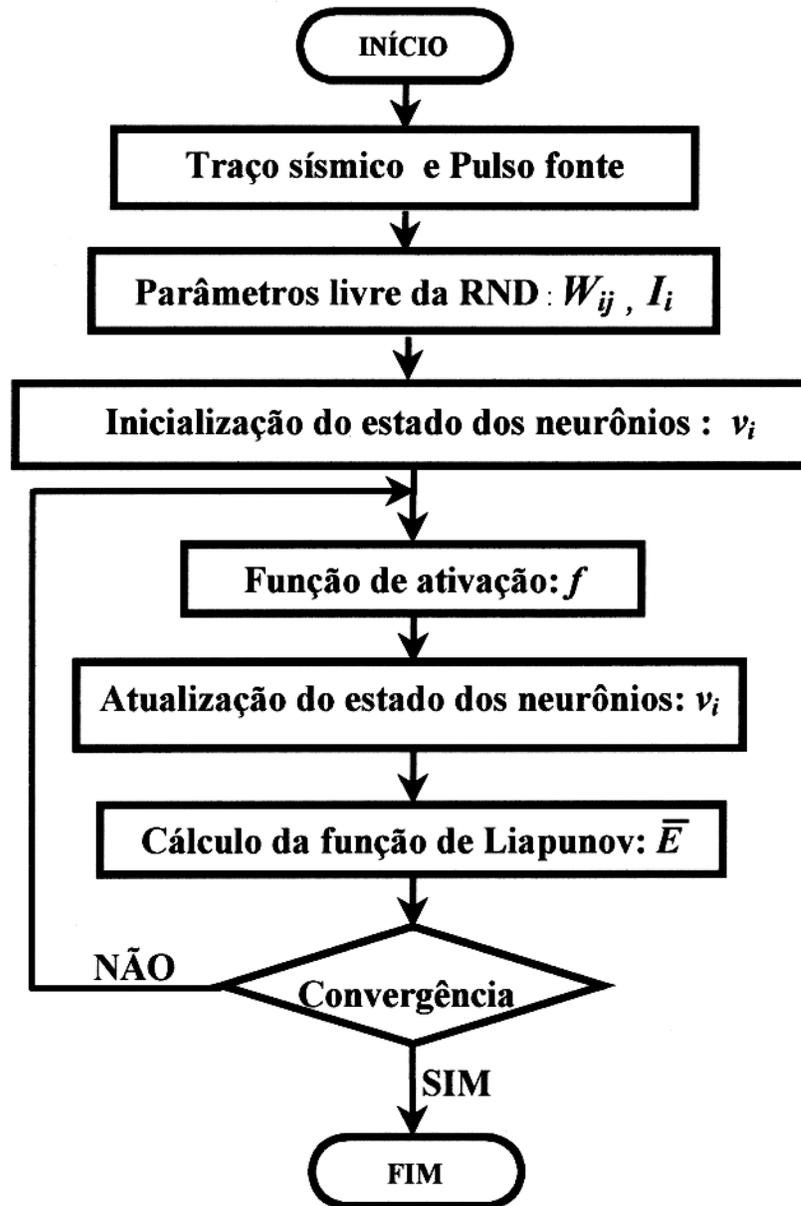


Figura 5.1 – Diagrama de blocos para a RND.

## 5.2 - RESULTADOS

Nesta seção aplica-se a RND para a recuperação da função refletividade simples, com a apresentação e avaliação dos resultados sobre dados obtidos com o modelo teórico convolucional simples, nos casos com ruído aditivo e pulsos fontes variados. É também avaliado a RND sobre dados teóricos obtidos com a teoria do raio na forma de seções sísmicas de afastamento nulo (*zero offset*).

Nos exemplos, busca-se medir a posição e a amplitude dos coeficientes de reflexão. Em todos os casos, é mostrado a função refletividade para efeito de comparação e análise do desempenho da RND.

O segundo aspecto a ser abordado trata da verificação da sensibilidade da RND com dados contaminados com ruído. Vale ressaltar que em todos os exemplos, o ruído é gerado como um evento aleatório, a partir de uma distribuição gaussiana com média amostral igual a zero e variância igual a um. O conteúdo de ruído presente em cada sismograma sintético é mensurado pela razão S/R. Os testes selecionados para apresentação trata da aplicação de pelo menos dois valores diferentes para a razão S/R sobre o mesmo dado sintético.

### 5.2.1 - Pulso fonte de fase-mínima

Neste seção é analisado o comportamento da RND frente um pulso fonte de fase-mínima, do tipo Berlage, descrita no Capítulo 2 e ilustrada na Figura 5.2 (a). Ela é utilizada no cálculo do sismograma sintético, bem como na localização e amplitude dos coeficientes de reflexão, cujos parâmetros são: Número de pontos = 32; ( $2^n$ , onde  $n=5$ ); Frequência angular = 0.5 Hz ; Amplitude,  $A = 2$ ; Decaimento da função  $\gamma = 1.6$ .

A Figura 5.2 (b) indica que a função-fonte é de fase-mínima, visto que todas as raízes do polinômio se encontram dentro do círculo unitário complexo.

A Figura 5.3 é o perfil de velocidades intervalares para sete camadas refletoras, de onde se calcula a função refletividade simples no tempo, (Figura 5.4), desconhecida a priori, utilizada na comparação com a função refletividade recuperada pela RND.

A Figura 5.5 apresenta o sismograma sintético obtido através da convolução da função Berlage (Figura 5.1(a)) com a função refletividade simples teórica da Figura 5.4. Este

sismograma representa o dado de entrada juntamente com a função Berlage. O resultado do processamento da RND está na Figura 5.6, a refletividade simples recuperada é representada por meio de uma linha contínua (—), e a refletividade simples teórica por asterísticos (\*). Este caso, sem ruído, é utilizado para verificar a sensibilidade da RND que mostra uma porcentagem de acerto igual a 100% do número total de refletores.

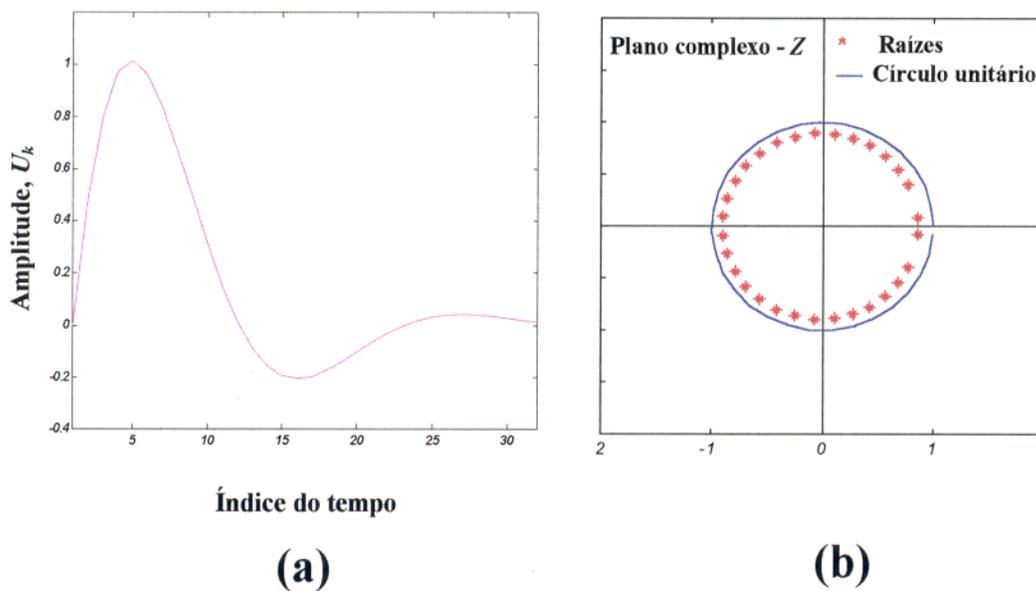
Para se analisar o efeito de ruído nos resultados da RND, o sismograma da Figura 5.5 é contaminado com razão  $S/R = 40,16$  (Figura 5.7), conforme as expressões 2.24 e 2.25. Os coeficientes de reflexão recuperados estão na Figura 5.8, comparados com a distribuição teórica. O acerto é de 100% na localização dos refletores.

O sismograma sintético da Figura 5.9 tem a razão  $S/R = 25,5$ , e a Figura 5.10 é o resultado da RND na recuperação da refletividade, novamente com um acerto de 100%. Finalizando as análises para o modelo de sete camadas, a Figura 5.11 mostra o sismograma com razão  $S/R = 14,7$ , e a refletividade simples recuperada é mostrada na Figura 5.12, com 100% de acerto na localização dos refletores.

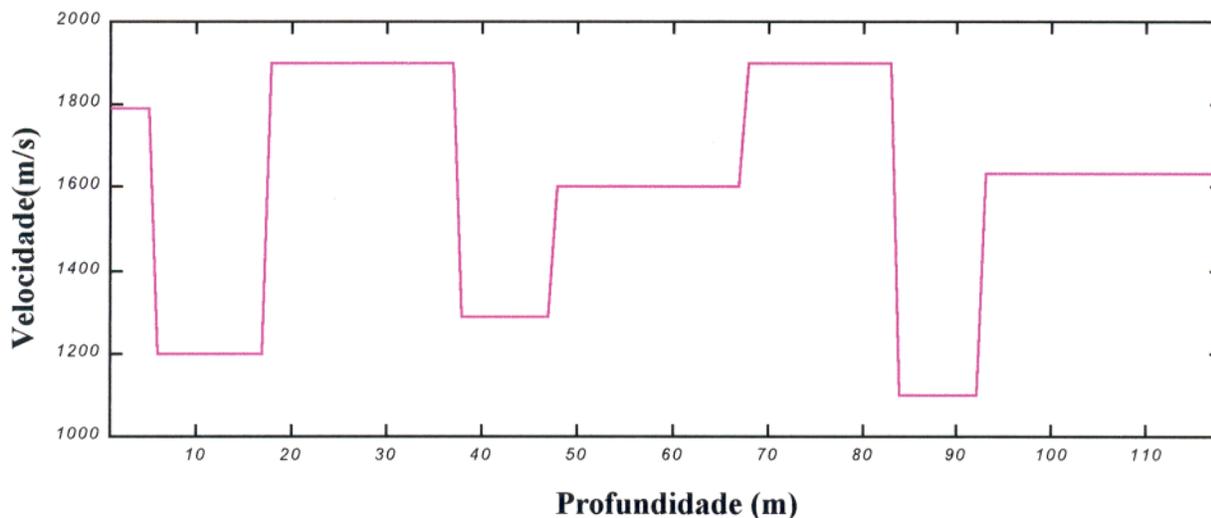
Dando continuidade à análise dos experimentos com a RND, aumentou-se o número de camadas refletoras para 17, gerando a função refletividade simples teórica mostrada na Figura 5.13. Na Figura 5.14 é visto o sismograma sintético não ruidoso. A recuperação da distribuição dos coeficientes de reflexão é vista na Figura 5.15, com um acerto de 88% na detecção dos refletores. A refletividade simples teórica é representada por (—), e a refletividade simples recuperada é representada por (\*). Em seguida, o sismograma da Figura 5.14 é contaminado com uma razão  $S/R = 13,04$ , conforme a Figura 5.16, produzindo como resultado a distribuição dos coeficientes de reflexão da Figura 5.17, onde ocorre também um acerto de 88% na detecção dos refletores. A Figura 5.15 (sismograma sintético sem ruído) diferencia da Figura 5.17 (sismograma sintético com ruído) apenas na amplitude dos coeficientes de reflexão.

Por fim, elevou-se para 34 o número de camadas refletoras, repetindo o mesmo procedimento realizado anteriormente, produzindo respectivamente as Figuras 5.18, 5.19, 5.20, 5.21 e 5.22, cujo acerto é de 82% na posição dos refletores sísmicos, tanto para o sismograma sem ruído (Figura 5.19), quanto para o sismograma ruidoso com razão  $S/R = 16,64$  (Figura 5.21), verificando apenas variações na amplitude detectada pela RND.

Os erros no posicionamento dos refletores ocorrem em função da complexidade do sinal. Assim, nos exemplos sintéticos baseados no modelo convolucional simples, a detecção dos refletores pela RND está relacionado à feição do lóbulo maior da função-fonte no sismograma.



**Figura 5.2** – (a) Pulso fonte (Berlage). (b) Círculo unitário no plano complexo  $Z$  mostrando as raízes internas do polinômio do pulso fonte, indicando a condição de fase-mínima.



**Figura 5.3** – Perfil de velocidades intervalares para o modelo com 7 camadas.

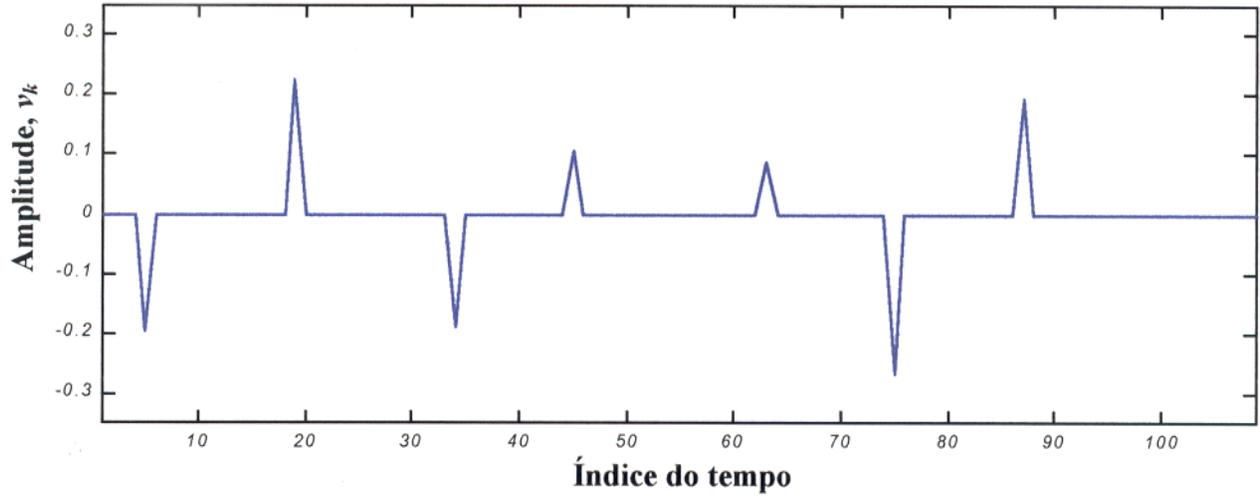


Figura 5.4 – Refletividade simples teórica para o modelo com 7 camadas da Figura 5.3.

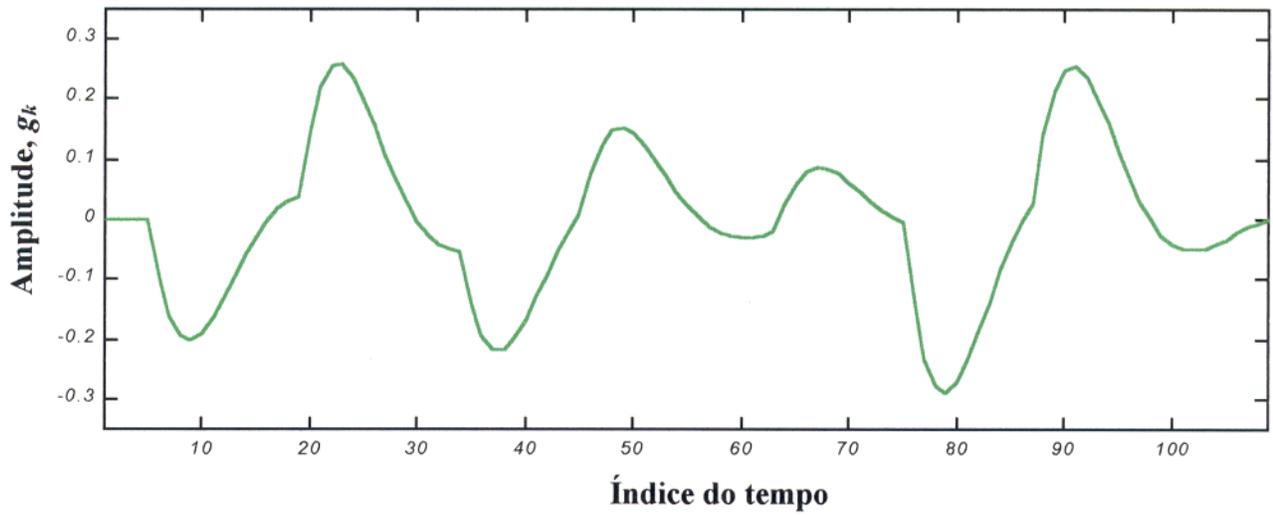
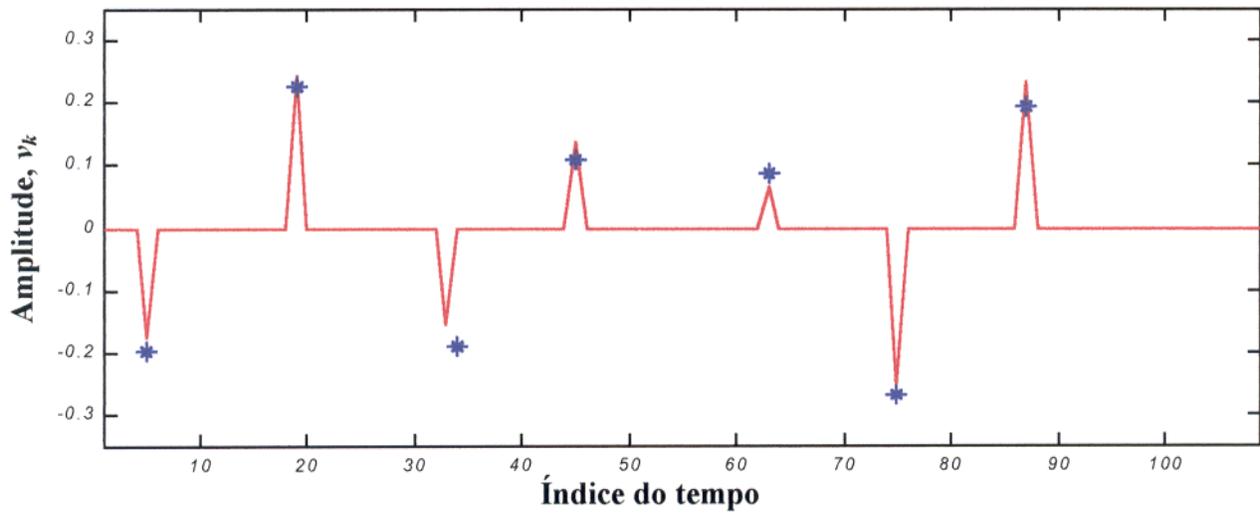
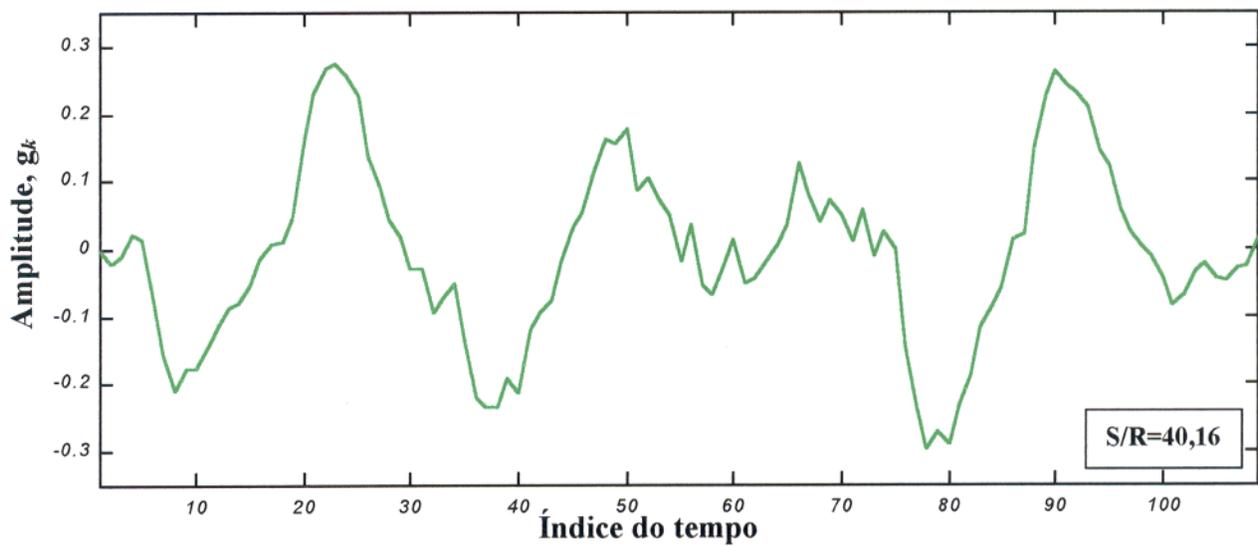


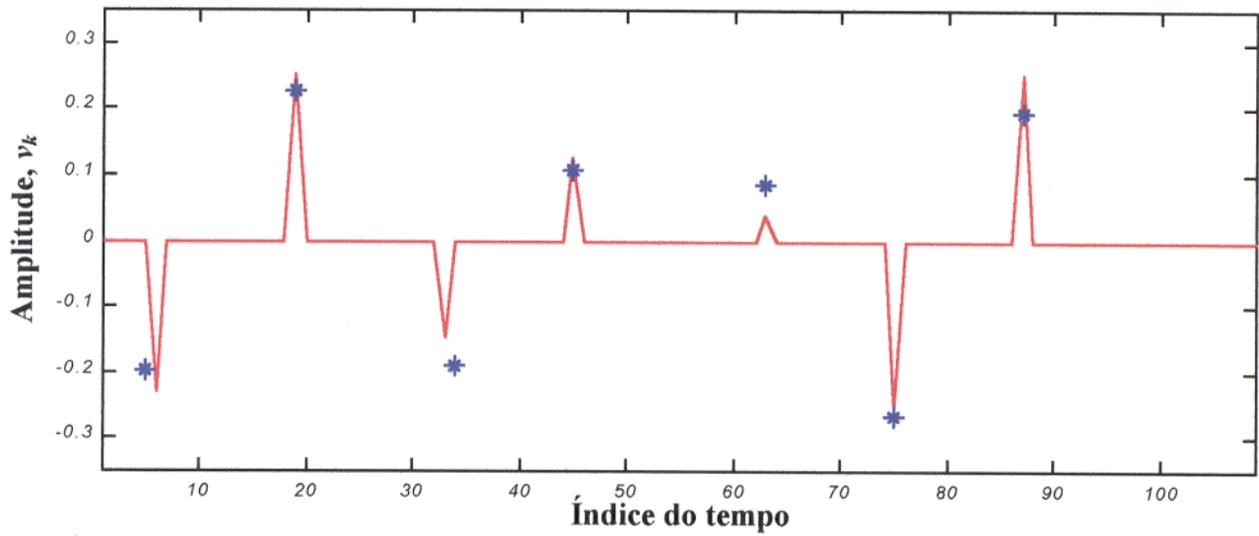
Figura 5.5 – Sismograma sintético sem ruído para o modelo com 7 camadas da Figura 5.4.



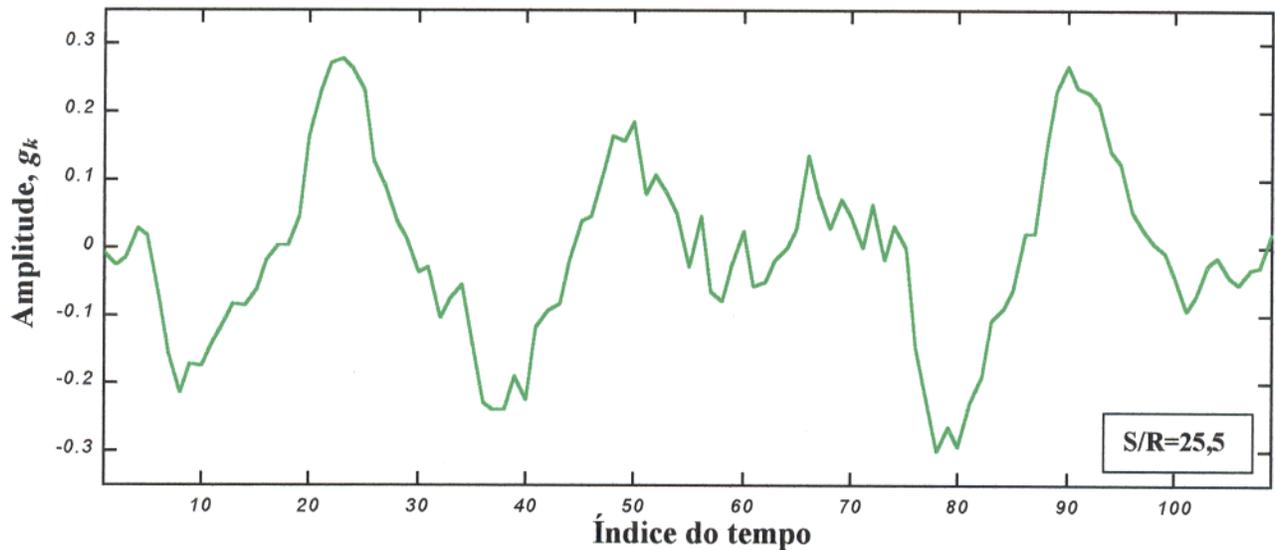
**Figura 5.6** – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 7 camadas sem ruído. A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.



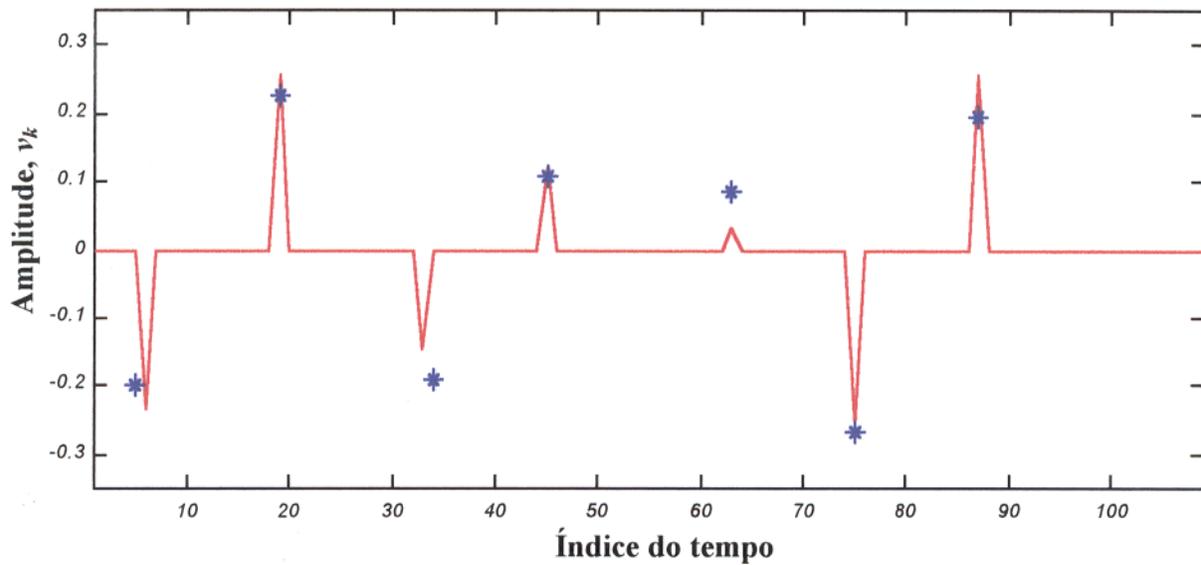
**Figura 5.7** – Sismograma sintético com ruído aditivo para o modelo com 7 camadas.



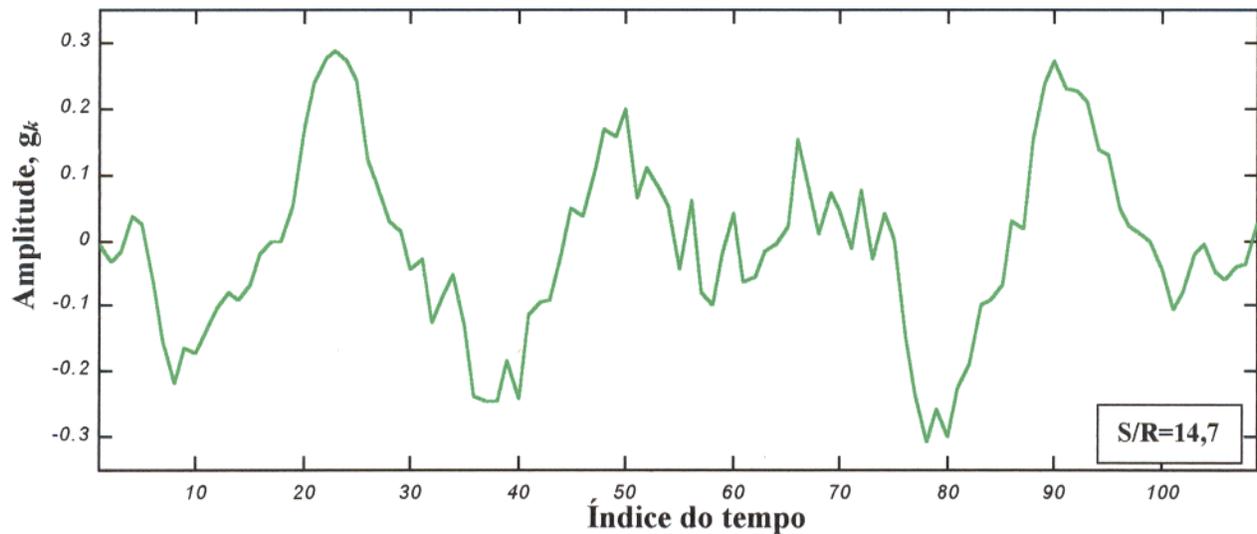
**Figura 5.8** – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 7 camadas com razão  $S/R=40,16$ . A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.



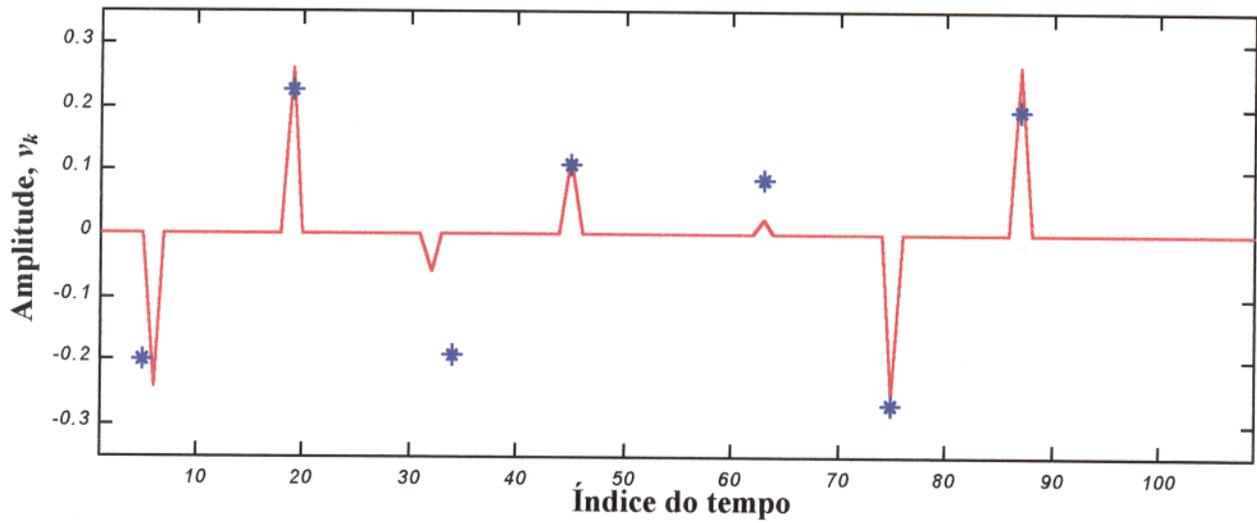
**Figura 5.9** – Sismograma sintético com ruído aditivo para o modelo com 7 camadas.



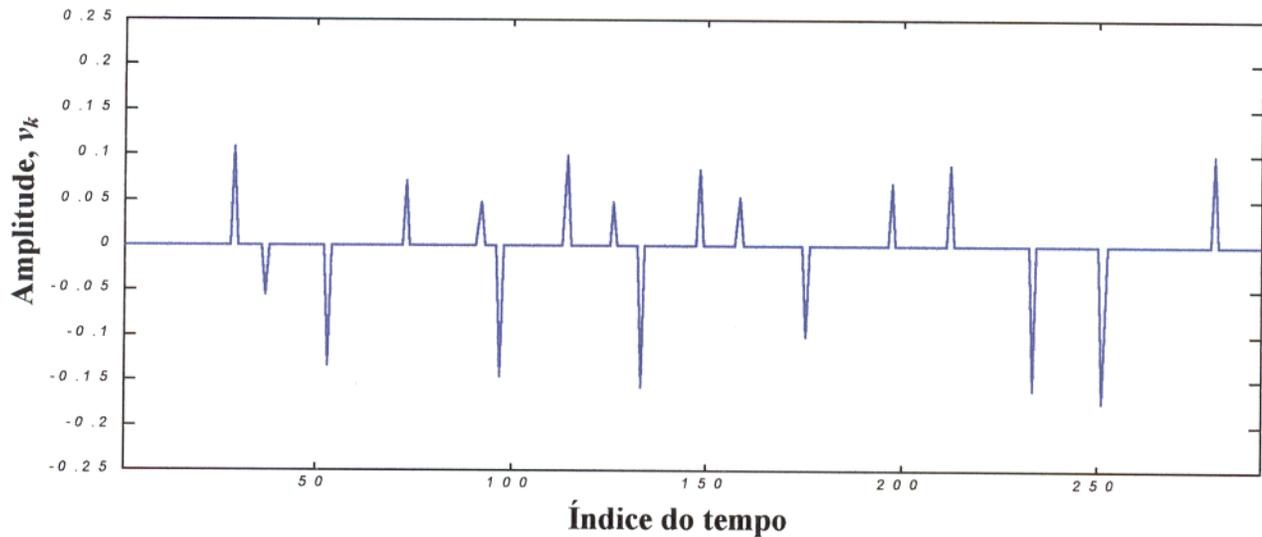
**Figura 5.10** – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 7 camadas com razão S/R=25,5. A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.



**Figura 5.11** – Sismograma sintético com ruído aditivo para o modelo com 7 camadas.



**Figura 5.12** – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 7 camadas com razão  $S/R=14,7$ . A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.



**Figura 5.13** – Refletividade simples teórica para o modelo com 17 camadas.

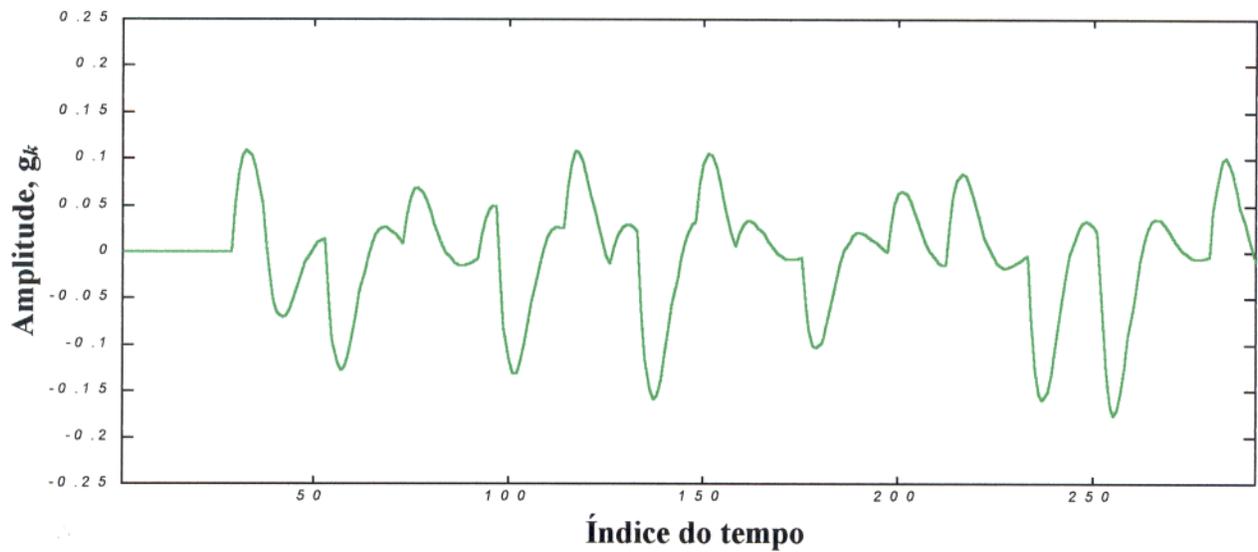


Figura 5.14 – Sismograma sintético sem ruído para o modelo com 17 camadas da Figura 5.13.

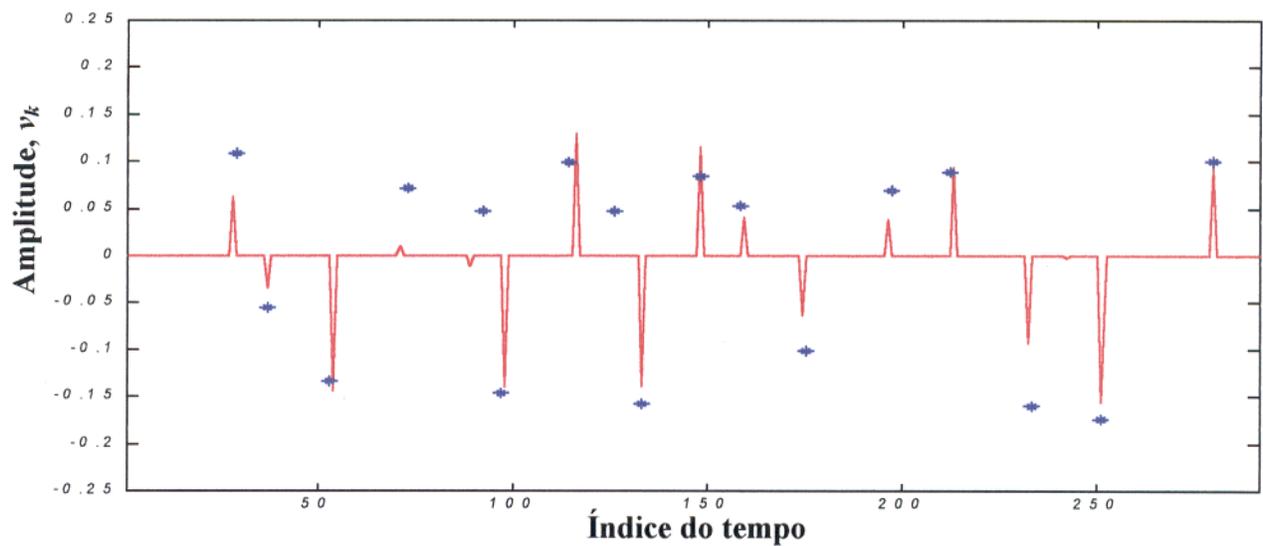


Figura 5.15 – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 17 camadas sem ruído. A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.

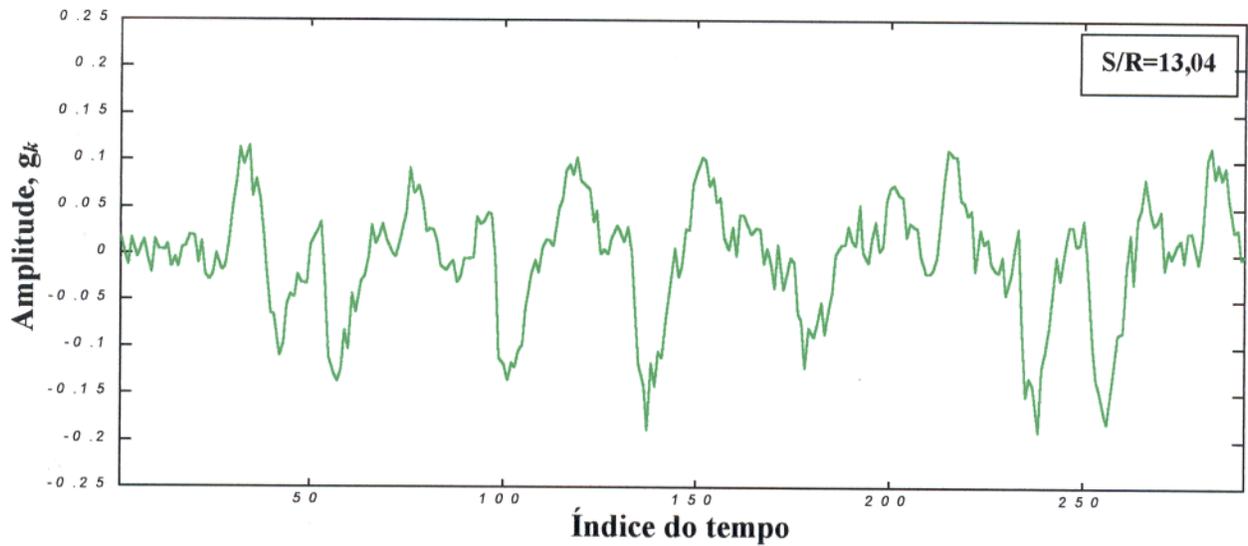


Figura 5.16 – Sismograma sintético com ruído para o modelo com 17 camadas.

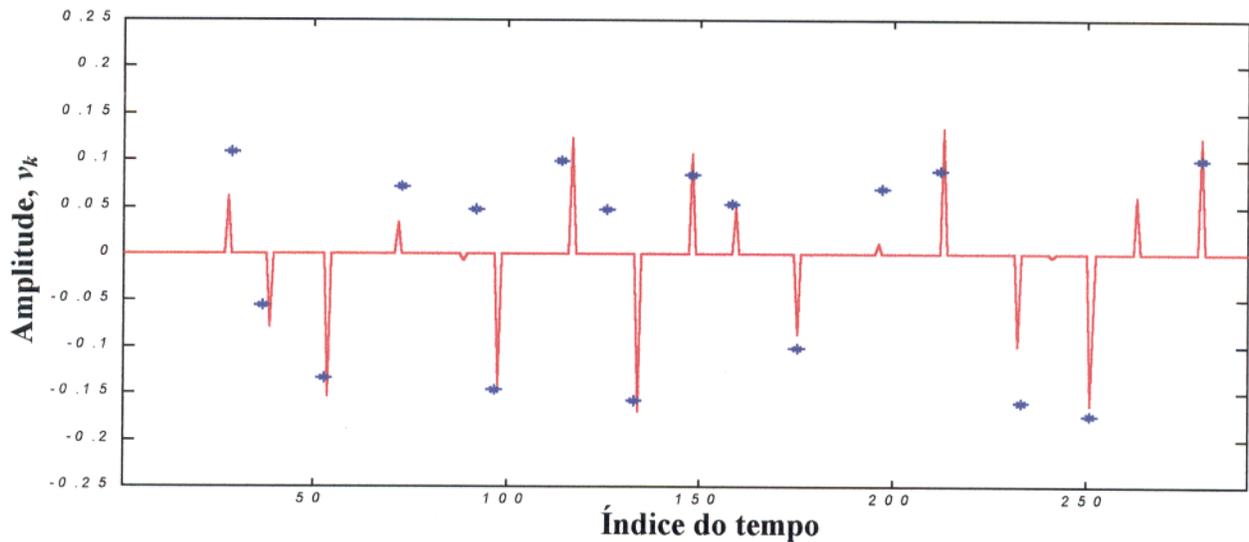


Figura 5.17 – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 17 camadas com razão  $S/R=13,04$ . A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.

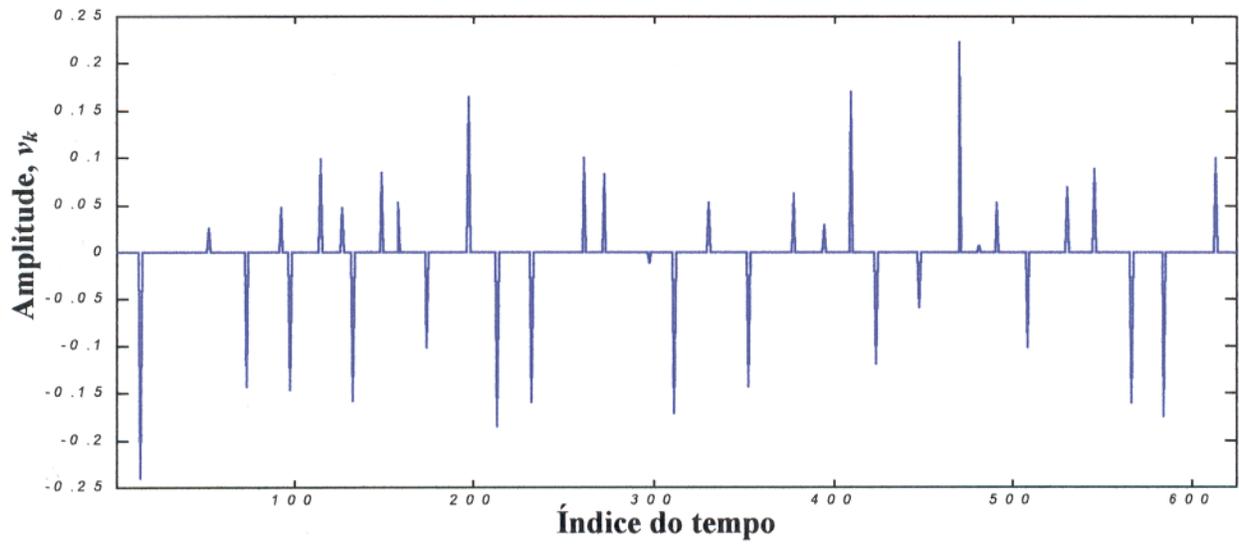


Figura 5.18 – Refletividade simples teórica para o modelo com 34 camadas.

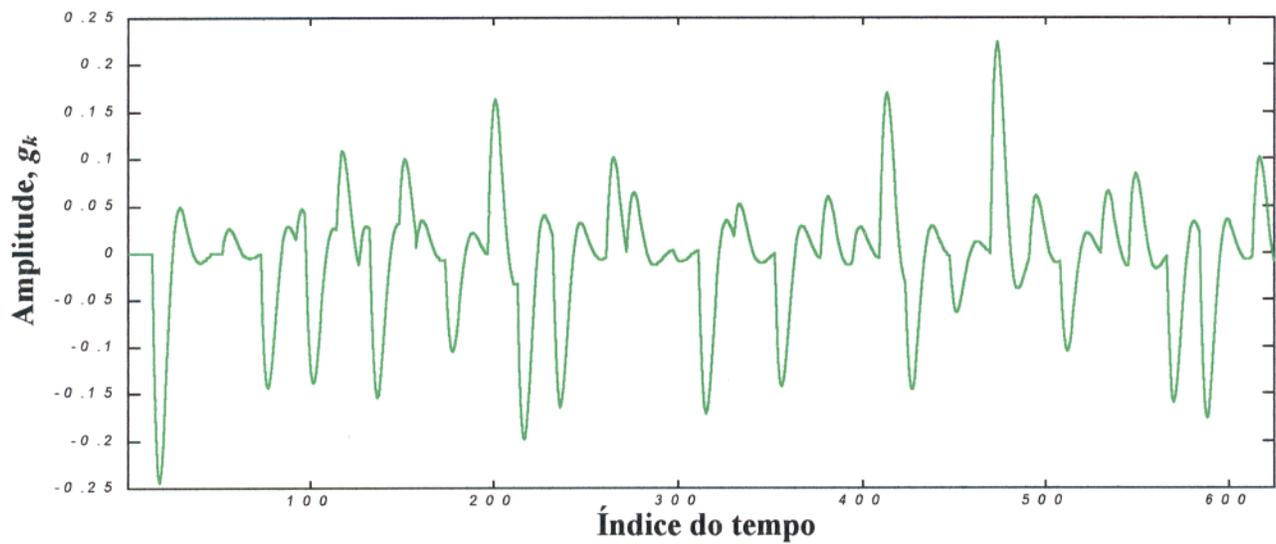
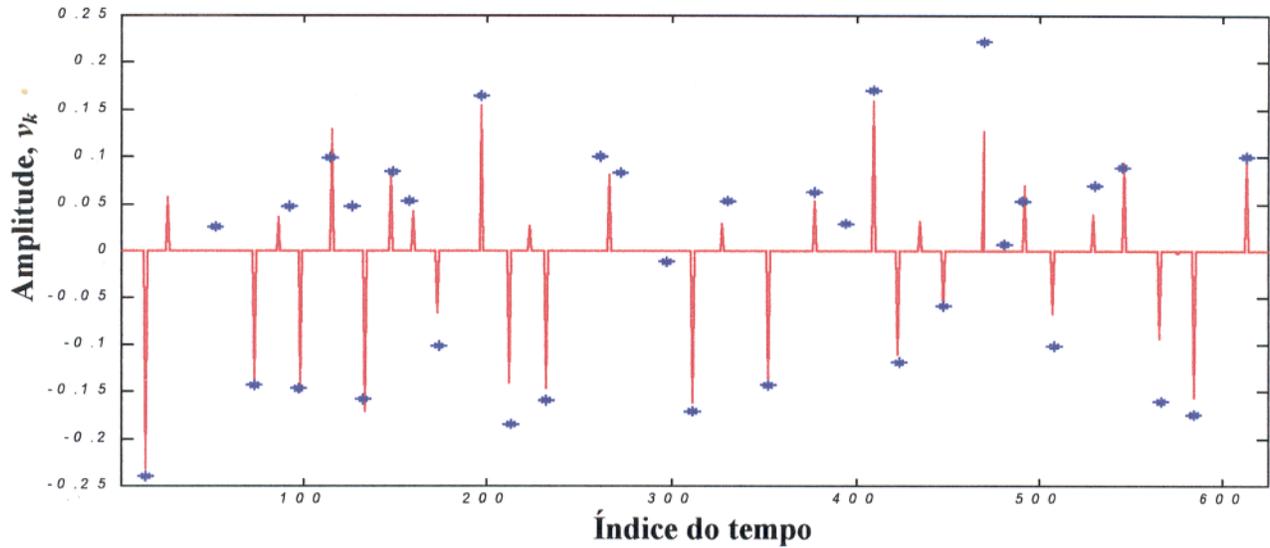
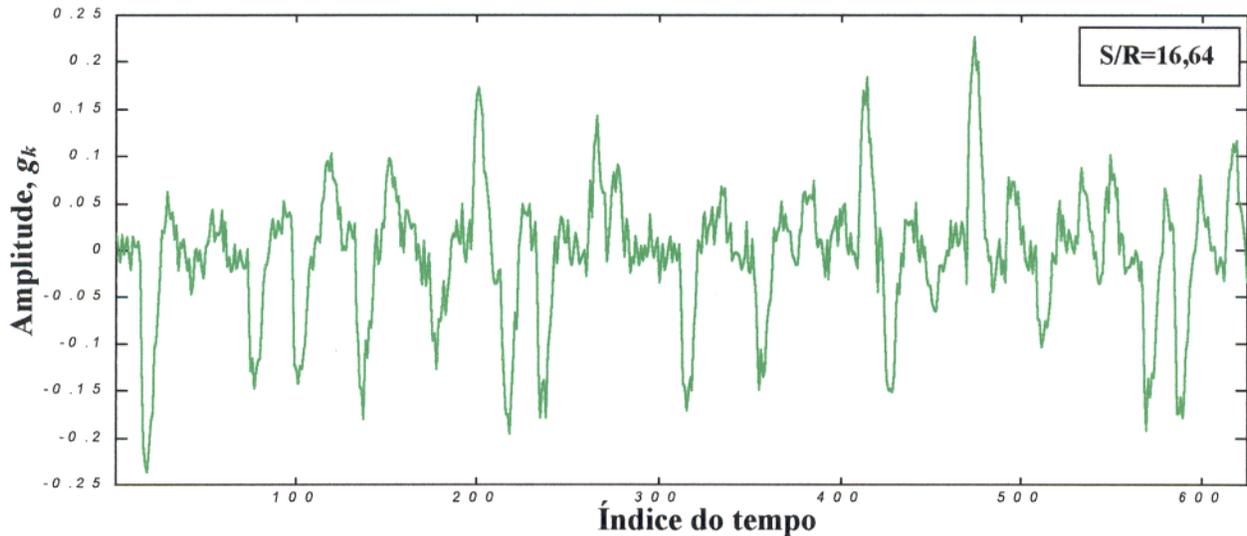


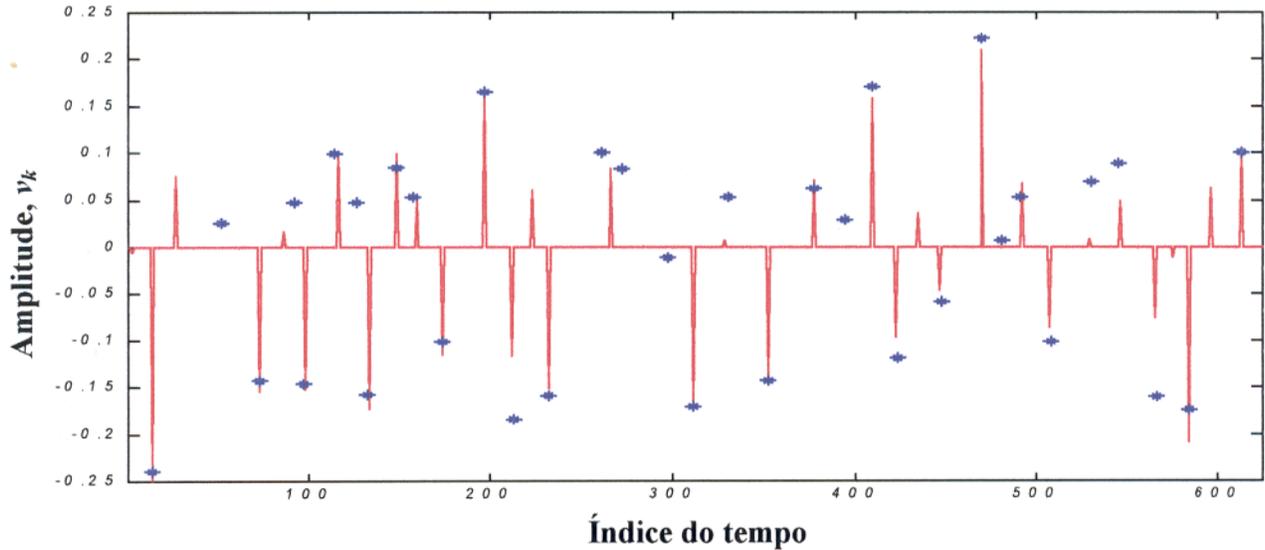
Figura 5.19 – Sismograma sintético sem ruído para o modelo com 34 camadas.



**Figura 5.20** – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 34 camadas sem ruído. A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.



**Figura 5.21** – Sismograma sintético com ruído para o modelo com 34 camadas.



**Figura 5.22** – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 34 camadas com razão  $S/R=16,64$ . A refletividade simples teórica é mostrada em asterísticos (\*) para efeito de comparação.

### 5.2.2 - Pulso fonte de fase-máxima

Nesta seção é analisado a dinâmica da RND utilizando o pulso fonte de fase-máxima na geração do sismograma sintético, para a obtenção do posicionamento e magnitude dos coeficientes de reflexão. Para isto, utilizou-se o reverso da função de fase-mínima do tipo Berlage, descrita anteriormente, preservando seus parâmetros. Desta forma, se  $F(z)$  corresponde a transformada-Z da função Berlage (fase-mínima), então a função fase-máxima correspondente pode ser escrita na forma  $F(-z)$ , sendo a mesma ilustrada na Figura 5.23(a).

A Figura 5.23(b) ilustra as condições de fase do pulso de fase-máxima, onde todas as raízes do polinômio estão localizadas no exterior do círculo unitário no plano complexo  $Z$ .

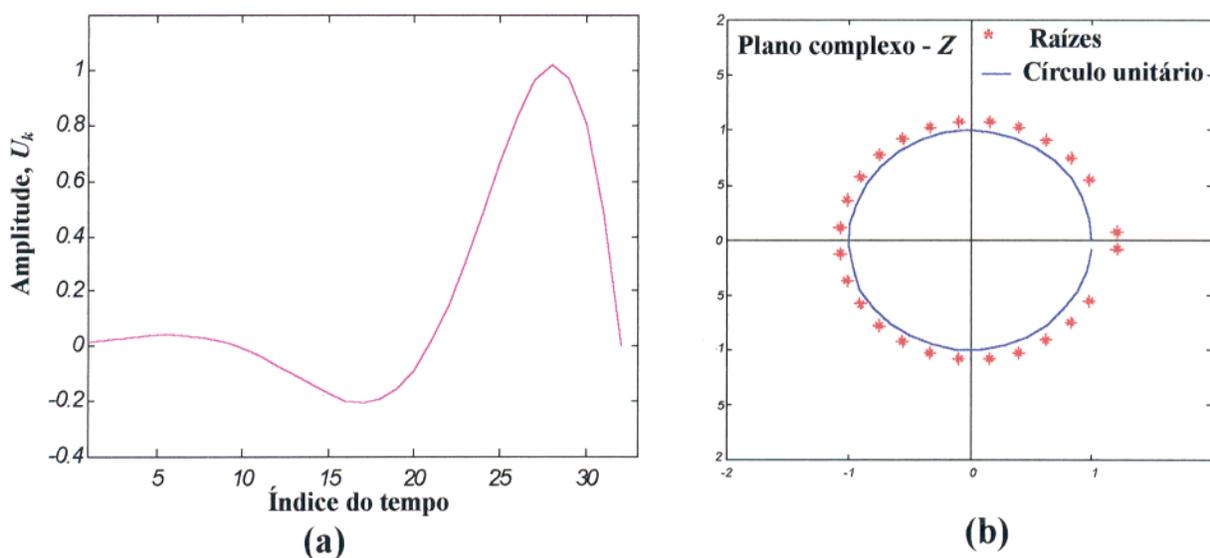
Em seguida, é feita uma análise num sismograma sintético obtido a partir da convolução do pulso de fase-máxima [Figura 5.23(a)] com a refletividade simples teórica para 16 camadas. As Figuras 5.26, 5.28, 5.30 e 5.32 comparam a saída da RND (refletividade simples recuperada), representada por uma linha contínua (—), com a refletividade simples teórica, marcadas em asterísticos (\*).

O sismograma sintético da Figura 5.25 é submetido a três diferentes frações de ruído com objetivo de verificar o efeito do mesmo sobre resolução da rede. Na Figura 5.25, o sismograma encontra-se livre de ruídos, ocasionando numa saída representando a refletividade simples recuperada a qual é vista na Figura 5.26 com um total de 100% de acerto no posicionamento dos coeficientes de reflexão, falhando na estimativa de algumas amplitudes desses coeficientes.

Posteriormente, o sismograma sintético da Figura 5.25 foi contaminado com uma razão S/R na ordem de 45,7, ilustrada na Figura 5.27. O resultado obtido pela RND na recuperação dos coeficientes de reflexão é mostrado na Figura 5.28, onde observa-se mudanças apenas nas amplitudes dos coeficientes.

O procedimento é repetido ao contaminar a sismograma sintético da Figura 5.25 com duas taxas crescentes de ruído, vistos nas Figuras 5.29 e 5.31 onde as razões S/R são respectivamente na ordem de 18,5 e 9,2. Os coeficientes recuperados são apresentados, respectivamente, nas Figuras 5.30 e 5.32.

Verifica-se assim, nos três exemplos de contaminação crescente por ruído, a não existência de perdas em relação ao posicionamento dos coeficientes, havendo apenas pequenas variações nas amplitudes dos mesmos.



**Figura 5.23** – (a) Pulso fonte de fase-máxima. (b) Círculo unitário no plano complexo  $Z$  mostrando as raízes externas do polinômio do pulso fonte, indicando a condição de fase-máxima.

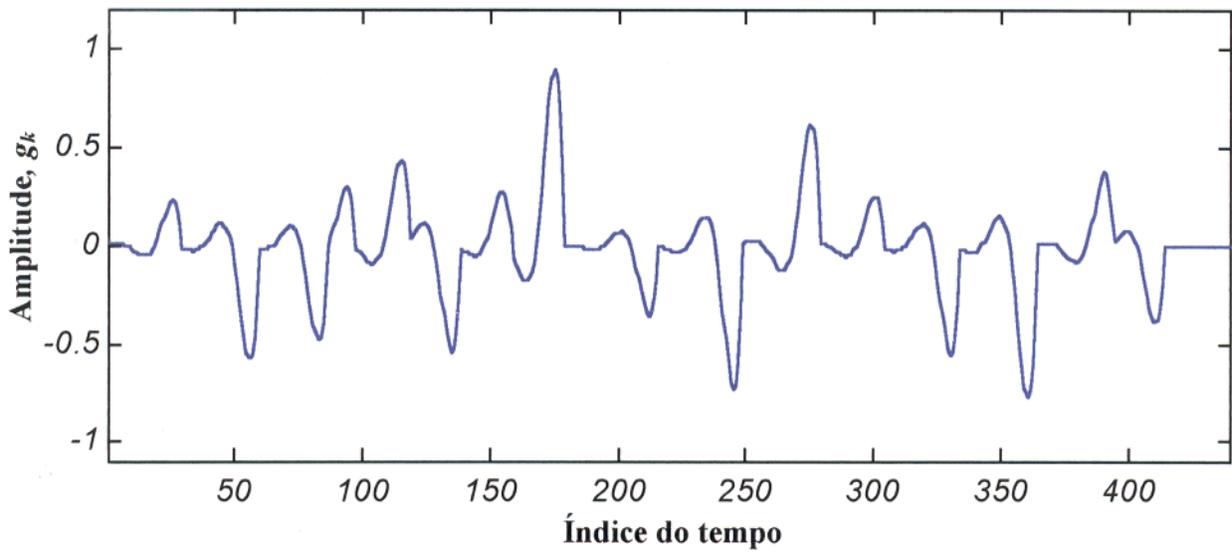


Figura 5.25 - Sismograma sintético sem ruído para o modelo com 16 camadas.

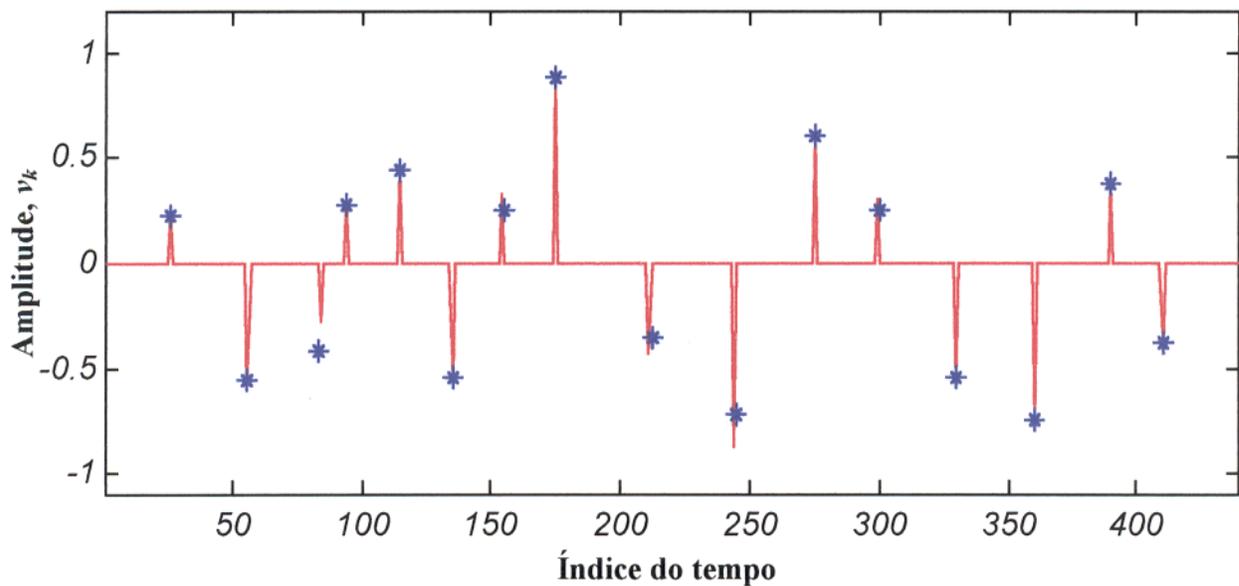


Figura 5.26 - Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético sem ruído para 16 camadas. A refletividade teórica é mostrada em asterísticos (\*) para efeito de comparação.

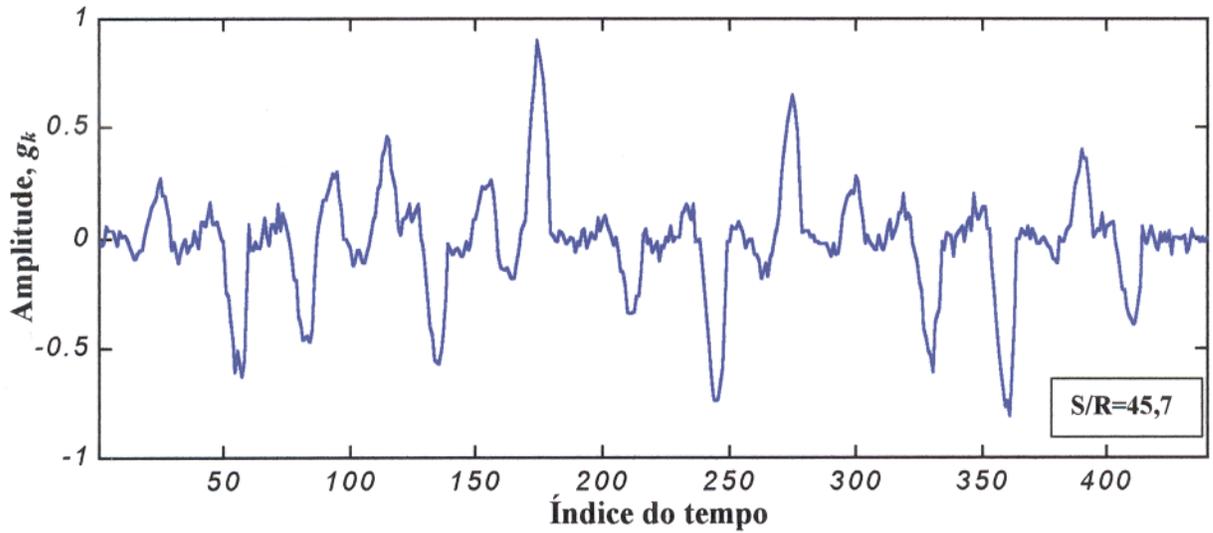


Figura 5.27 - Sismograma sintético com ruído aditivo para o modelo com 16 camadas.

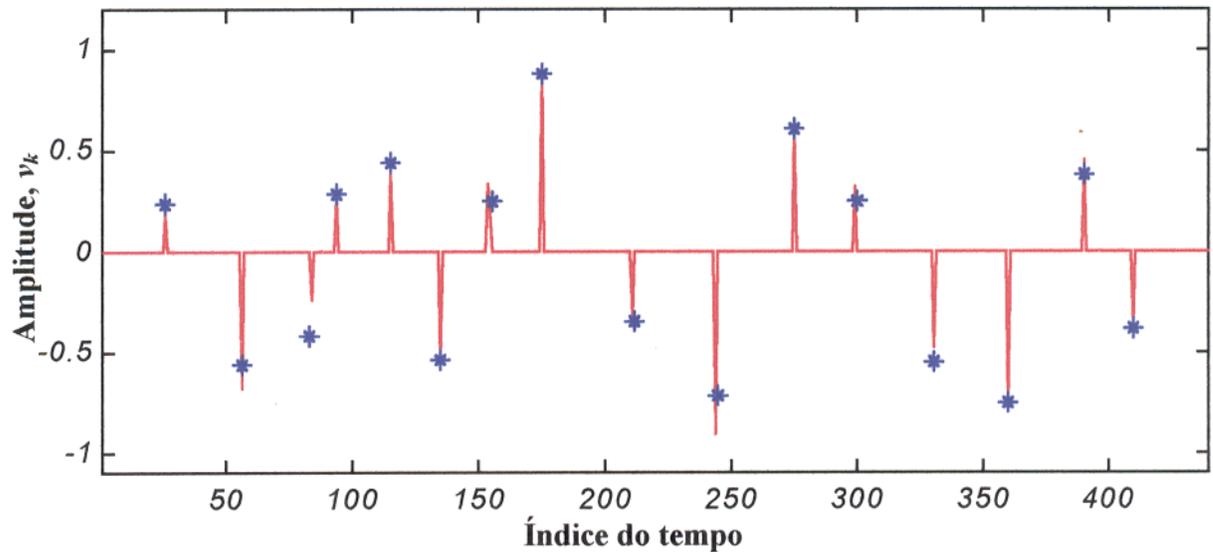


Figura 5.28 - Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 16 camadas com razão  $S/R=45,7$ . A refletividade teórica é mostrada em asterísticos (\*) para efeito de comparação.

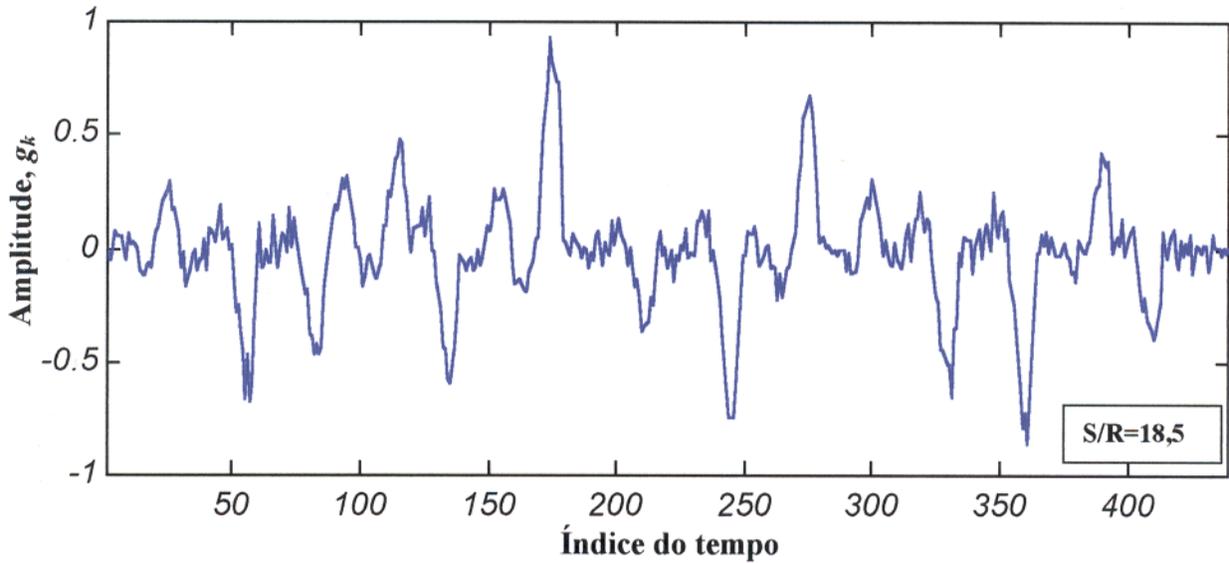


Figura 5.29 - Sismograma sintético com ruído aditivo para o modelo com 16 camadas.

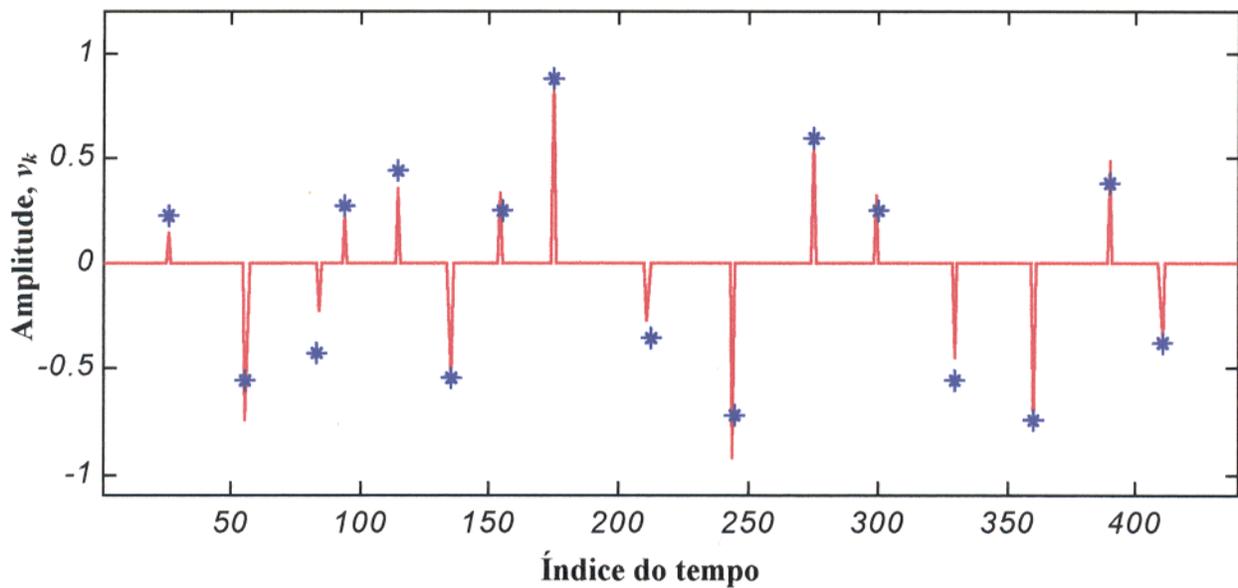


Figura 5.30 - Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 16 camadas com razão  $S/R=18,5$ . A refletividade teórica é mostrada em asterísticos (\*) para efeito de comparação.

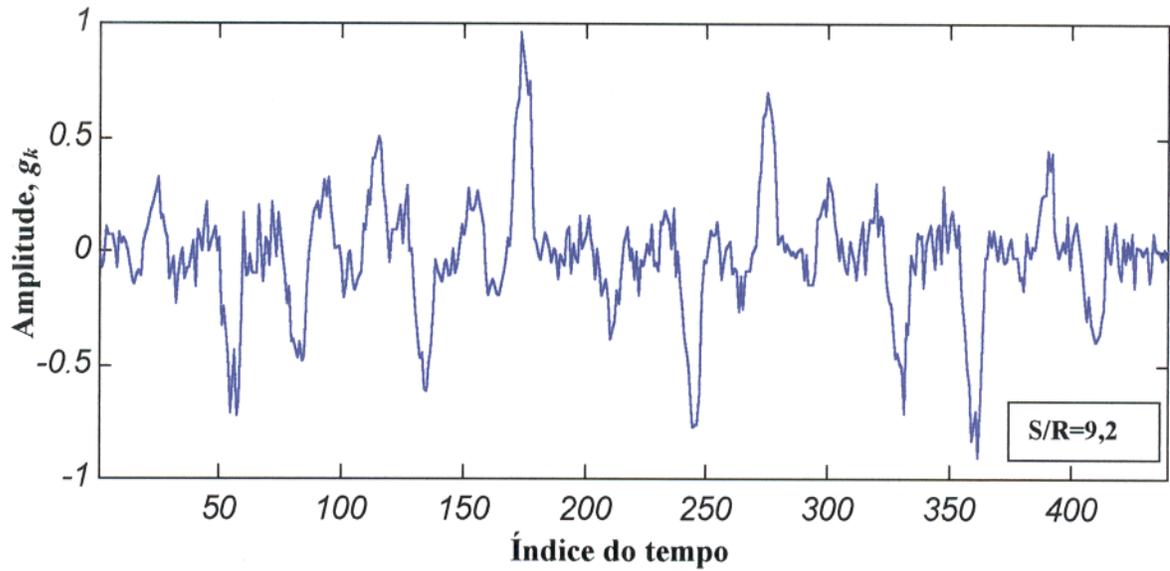


Figura 5.31 - Sismograma sintético com ruído aditivo para o modelo com 16 camadas.

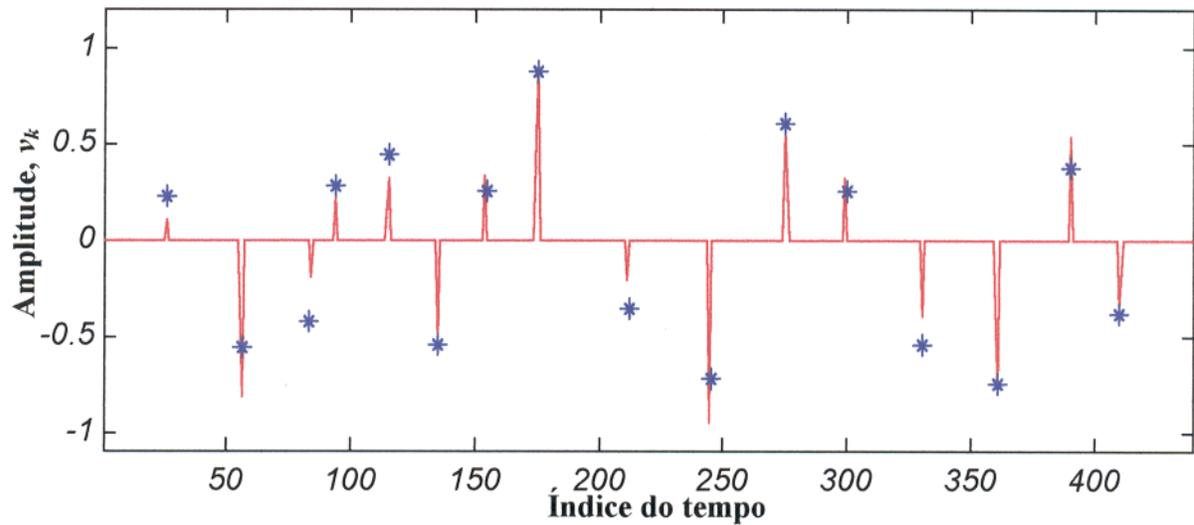


Figura 5.32 – Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 16 camadas com razão  $S/R=9.2$ . A refletividade teórica é mostrada em asteriscos (\*) para efeito de comparação.

### 5.2.3 - Pulso fonte de fase-mista

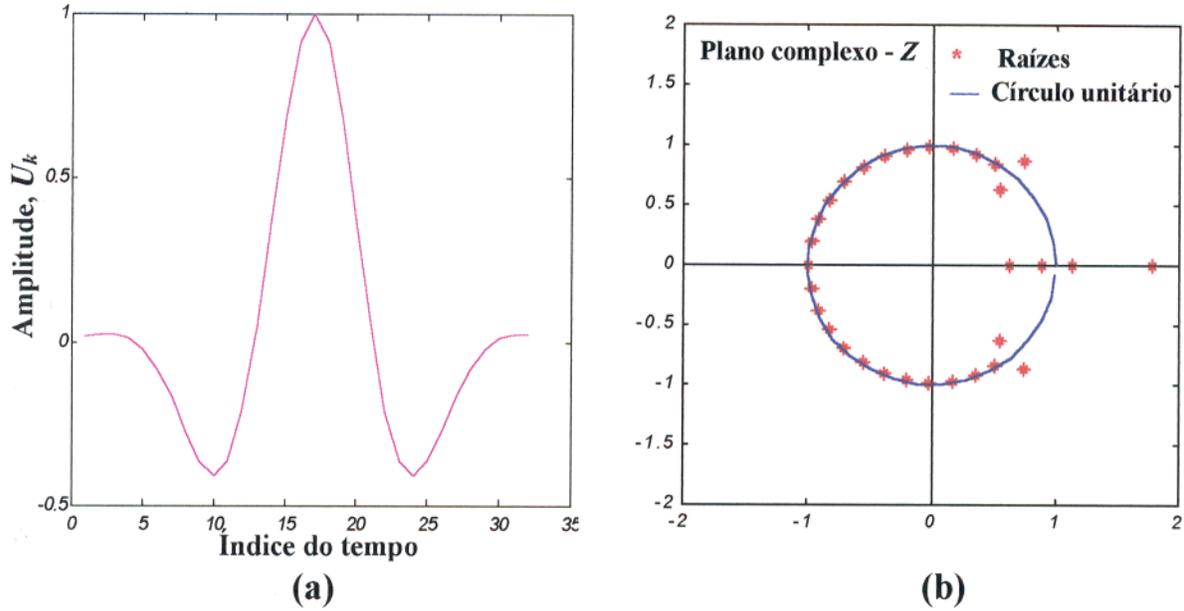
O terceiro tipo de função fonte utilizada para avaliar o comportamento da RND foi o pulso fonte de fase-mista do tipo Gabor, utilizada na geração dos sismogramas sintéticos, o qual é descrito no Capítulo 2 e ilustrado na Figura 5.33(a), cujo parâmetros são: número de amostras = 32; ( $2^n$ , onde  $n=5$ ); frequência = 4 Hz; amplitude = 1; coeficiente de amortecimento = 3.

O gráfico do comportamento de fase desse pulso fonte é a Figura 5.33(b). As raízes polinomiais da transformada  $Z$  são distribuídas no interior e no exterior do círculo unitário, caracterizando-a como uma função de fase-mista.

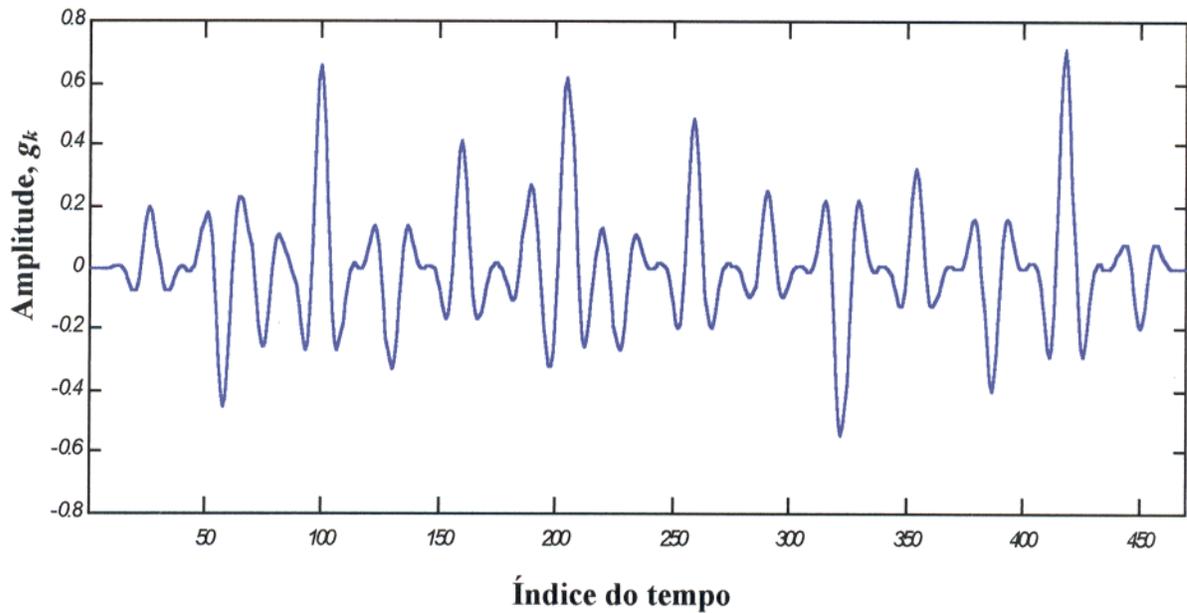
O mesmo procedimento anterior é repetido nesta seção. O sismograma sintético é gerado (Figura 5.35) convolvendo o pulso fonte de fase-mista [Figura 5.33(a)] com a função refletividade simples para 16 camadas. Elas estão representadas em asterísticos (\*) nas Figuras 5.36, 5.38, 5.40 e 5.42, para compara com a função refletividade simples recuperada pela RND, sendo representada por uma linha contínua (—).

O sismograma sintético da Figura 5.35 não apresenta ruído, resultando num acerto total no posicionamento e na amplitude dos coeficientes de reflexão. Em seguida, este mesmo sismograma é submetido a três taxas crescentes de ruído, para verificar o efeito sobre a dinâmica da RND. Na Figura 5.37, a razão é  $S/R=61,47$ ; na Figura 5.39 a razão é  $S/R=24,89$  e finalmente na Figura 5.41 a razão é  $S/R=15,3$ . Os resultados da aplicação da RND sobre esses dados são vistos nas Figuras 5.38, 5.40 e 5.42, respectivamente.

Ao contrário do ocorrido com os pulsos fonte de fase-máxima e mínima, a presença de ruído perturba a RND, interferindo no posicionamento dos refletores e na determinação da amplitude dos coeficientes de reflexão. A RND interpreta este tipo de pulso fonte de forma mais complexa em comparação às outras duas anteriores, merecendo um estudo mais detalhado, que é visto na seção seguinte.



**Figura 5.33** – (a) Pulso fonte (Gabor) de fase-mista. (b) Círculo unitário no plano complexo  $Z$  mostrando as raízes internas e externas do polinômio do pulso fonte (Gabor), indicando a condição de fase mista.



**Figura 5.35** - Sismograma sintético sem ruído para o modelo com 16 camadas.

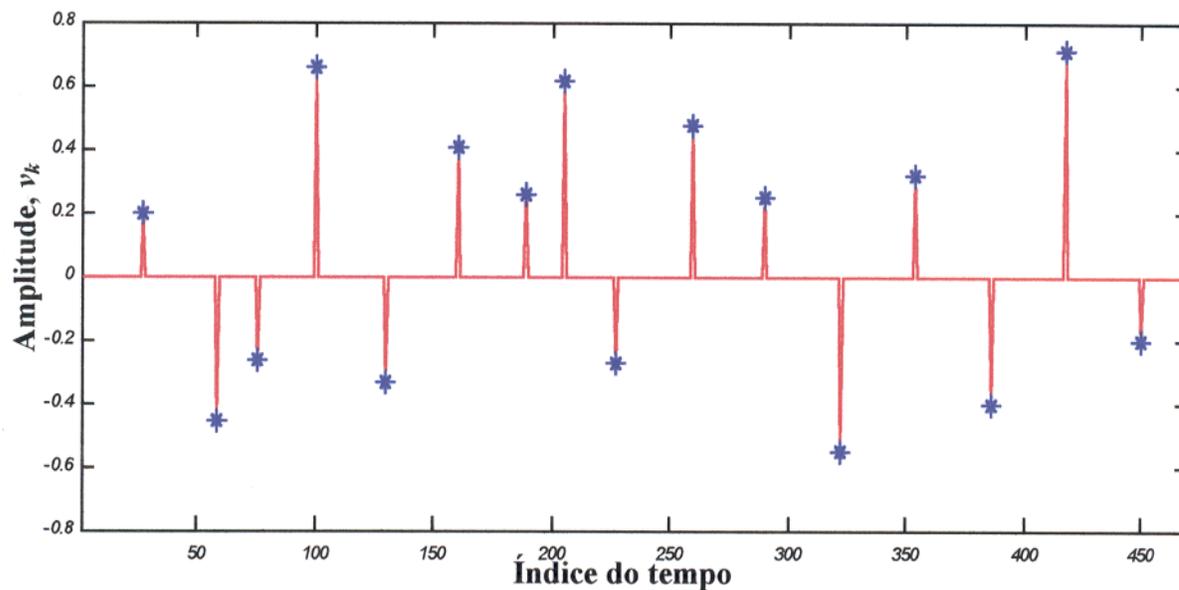


Figura 5.36 - Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 16 camadas sem ruído. A refletividade simples teórica é mostrada em asterísticos (\*).

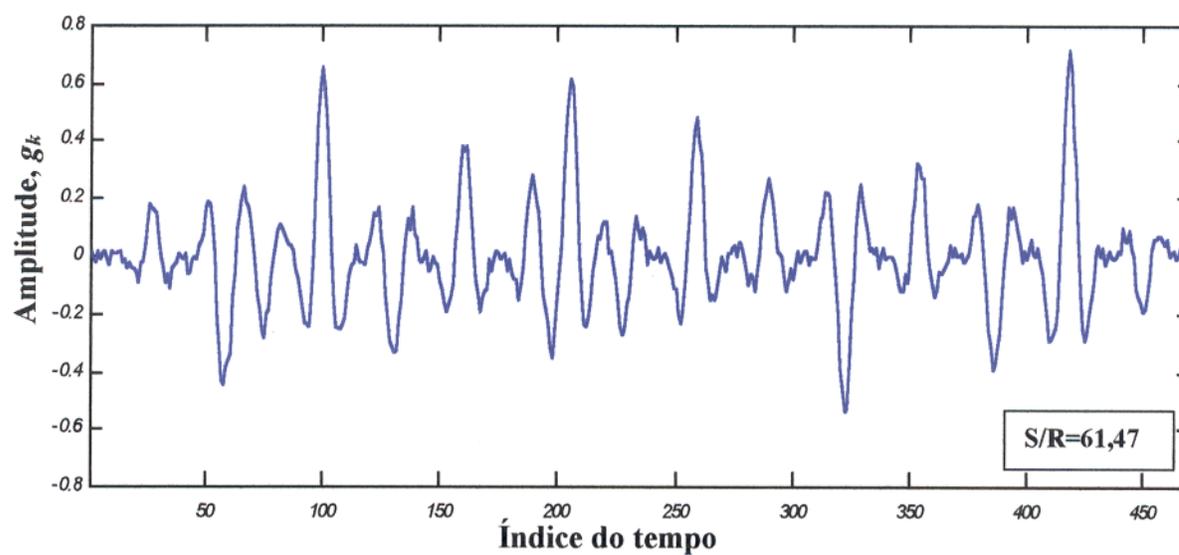
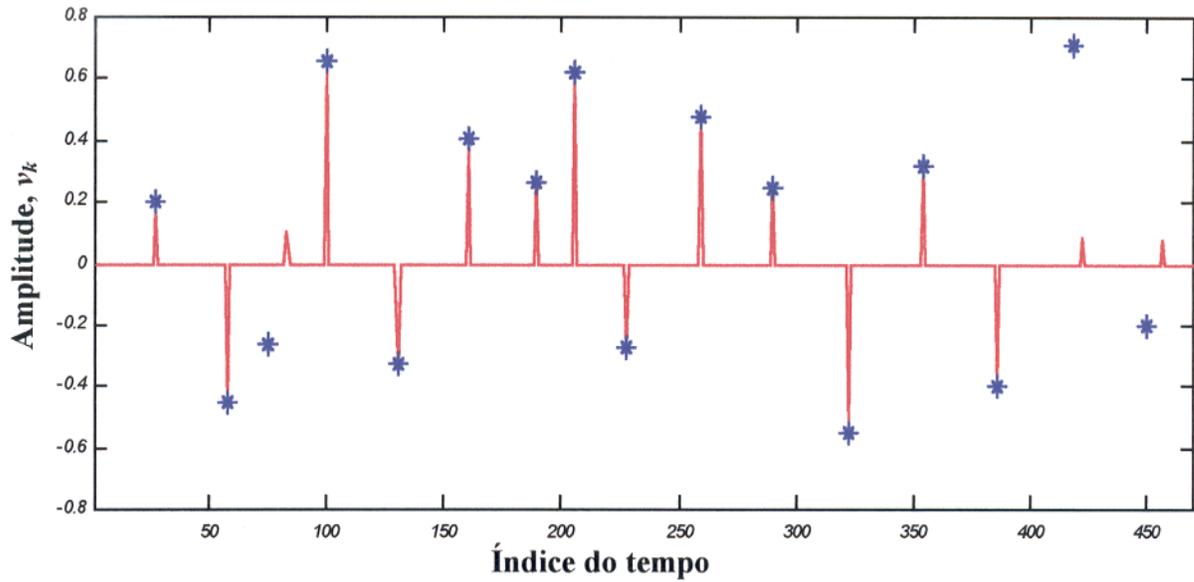
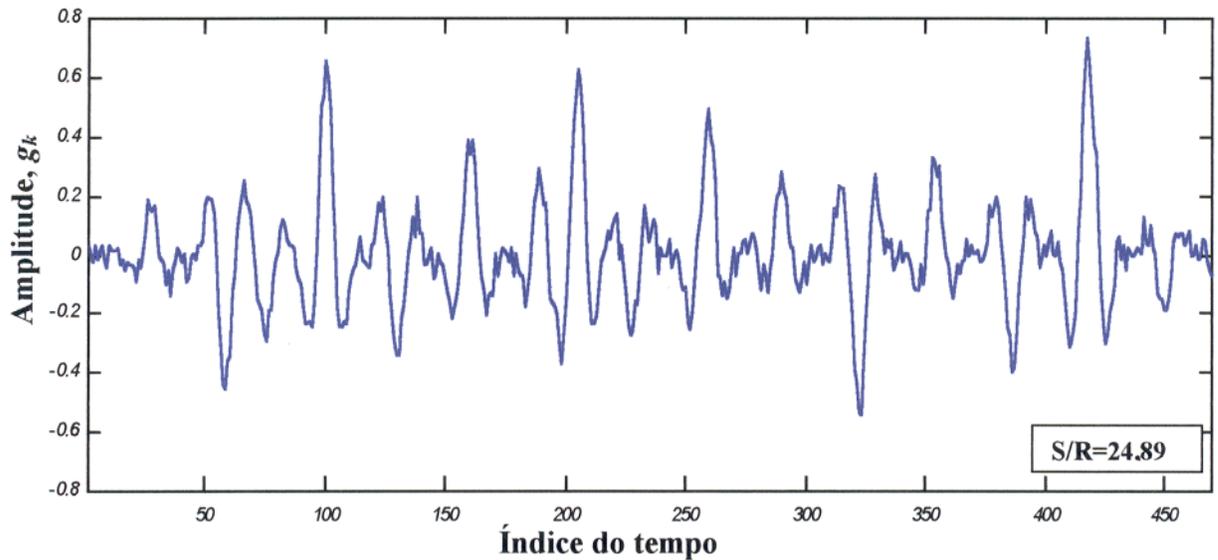


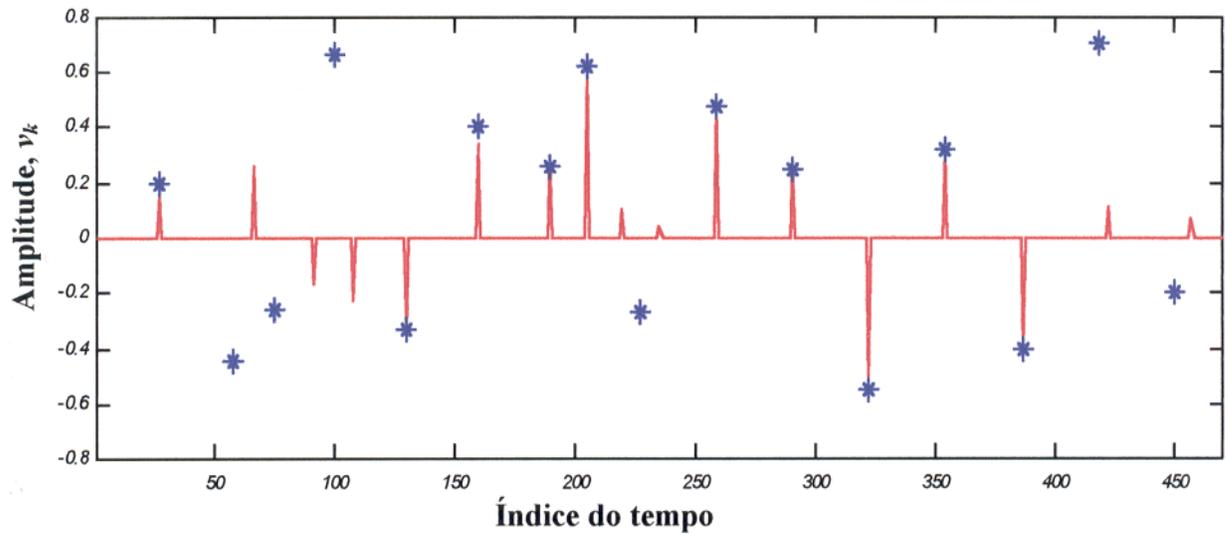
Figura 5.37 - Sismograma sintético com ruído aditivo para o modelo com 16 camadas.



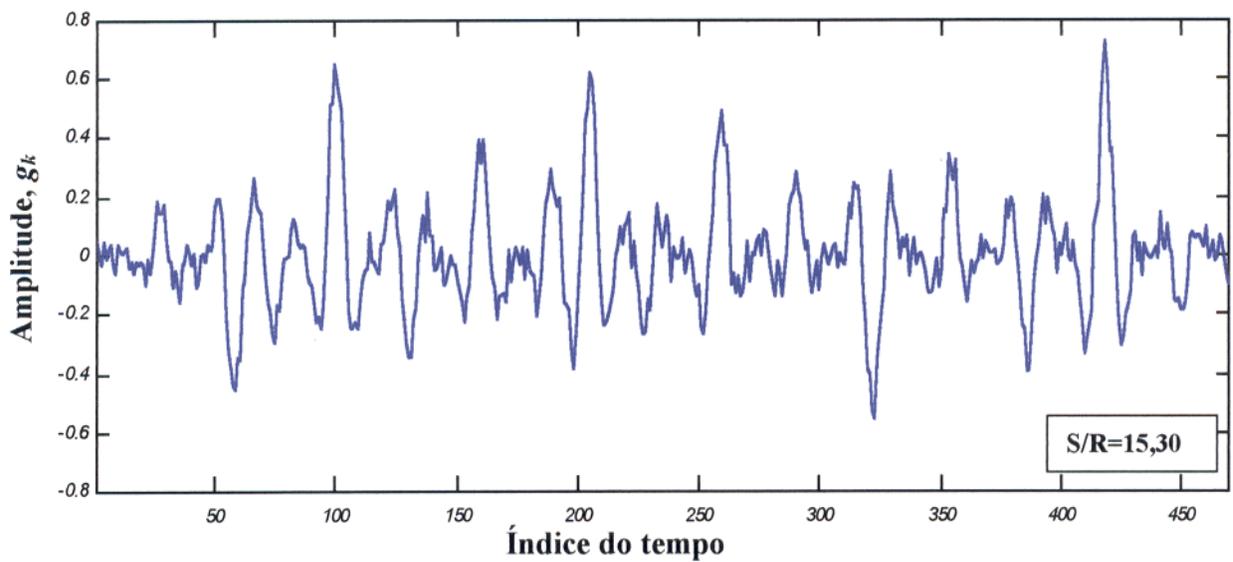
**Figura 5.38** - Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 16 camadas com razão  $S/R=61,47$ . A refletividade simples teórica é mostrada em asterísticos (\*).



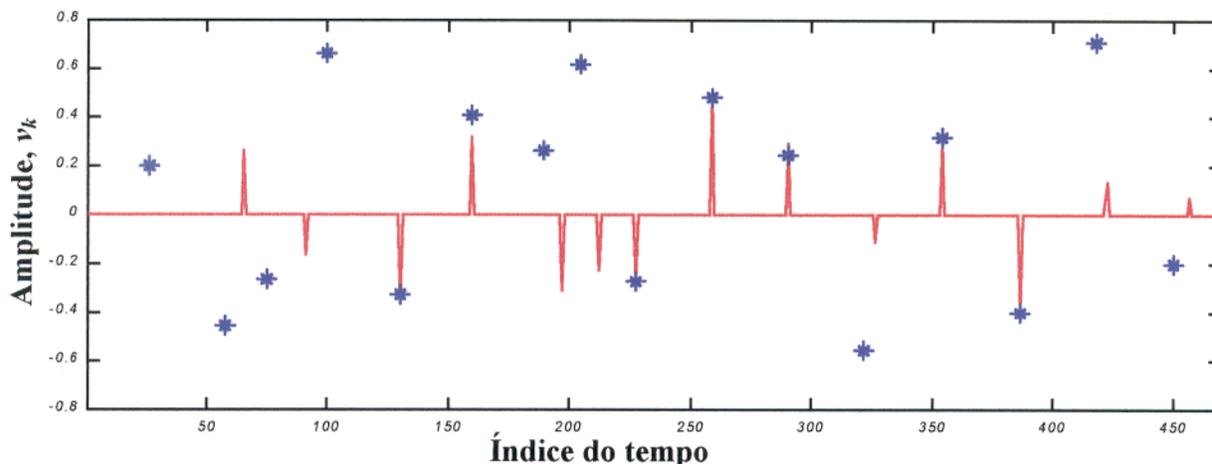
**Figura 5.39** - Sismograma sintético com ruído aditivo para o modelo com 16 camadas.



**Figura 5.40** - Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 16 camadas com razão  $S/R=24,89$ . A refletividade simples teórica é mostrada em asterísticos (\*).



**Figura 5.41** - Sismograma sintético com ruído aditivo para o modelo com 16 camadas.



**Figura 5.42** - Refletividade simples recuperada através do processamento da RND mostrada em linha contínua (—) para o sismograma sintético para 16 camadas com razão  $S/R=15,3$ . A refletividade simples teórica é mostrada em asteriscos (\*).

### 5.2.4 - Avaliação do modelo convolucional simples

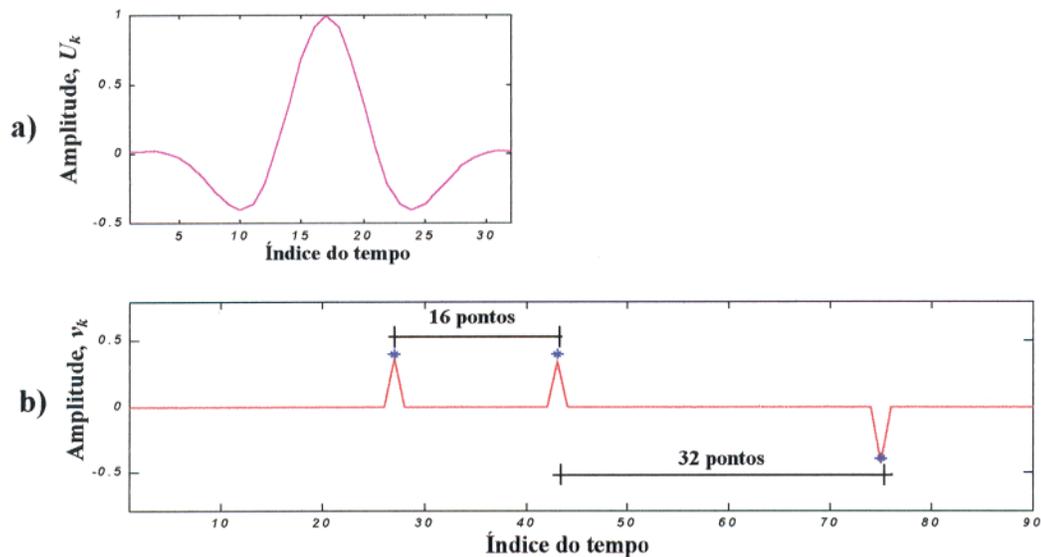
O objetivo dessa seção é uma avaliação do modelo convolucional simples quanto à resolução de separação dos eventos sísmicos contidos no traço. O comportamento da RND é analisado em função do tipo de pulso fonte, se fase-mínima, fase-máxima ou fase misturada.

A RND se propõe a recuperar a função refletividade simples. Assim sendo, dois tópicos fundamentais são abordados:

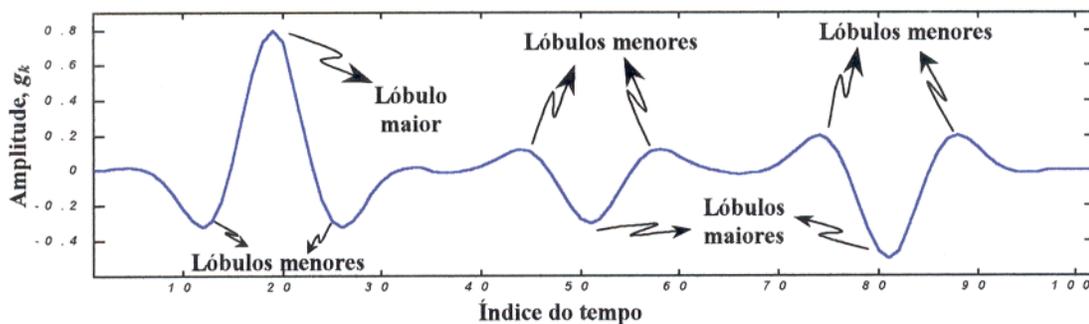
- 1- Separação temporal dos refletores sísmicos.
- 2- Tipo de pulso fonte responsável pela composição do traço sísmico.

Para o primeiro tópico, conclui-se que, no caso das funções de fase-mínima, de fase-máxima e de fase-mista, a resolução da RND possui as seguintes limitações: a separação dos refletores deve ter pelo menos da metade do comprimento da função-teste para refletores com mesma polaridade, e de separação igual ao número de amostras da função teste para refletores com polaridades invertidas. A Figura 5.43 (b) mostra um exemplo com três refletores de mesma amplitude e espaçados de acordo com as exigências da RND. A distância entre os dois primeiros refletores igual à 16 amostras por se tratar de refletores com mesma polaridade [metade do número total de amostras da função Gabor [Figura 5.43(a)] utilizada pela RND. Os dois últimos refletores sísmicos com polaridade invertida necessitam de 32 amostras de afastamento, que é o número total de amostras do pulso fonte. Esta figura tem também a saída da RND representada em asteriscos (\*), encontrando os três coeficientes de reflexão.

O segundo tópico é fundamental para a determinação das impedâncias acústicas. Observa-se a sensibilidade da RND para o tipo de pulso fonte. Por exemplo, a função do tipo Gabor, é interpretada pela rede de forma mais complexa em comparação às funções pulso de fase-máxima ou mínima. Isto deve-se ao fato da primeira apresentar informações antes e após a ocorrência de seu lóbulo principal, o que torna mais complexo o mapeamento dessa função fonte, que é realizado internamente pela RND. Este fato interfere diretamente na determinação da amplitude dos coeficientes de reflexão. Assim, um refletor de pequena amplitude pode ser confundido com os lóbulos menores da função-fonte relativa a um outro refletor de maior amplitude. Isto pode ser visto com mais detalhes na Figura 5.44 que ilustra a situação de um sismograma sintético com 100 amostras. Um trecho deste sismograma (amostras 23-30) caracterizado pelos lóbulos inferiores da função Gabor com amplitude quase igual a de um outro trecho do sismograma (amostras 45-55) caracterizado pelo lóbulo principal desta mesma função-fonte. Esta situação confunde a RND, podendo comprometer a dinâmica da RND em relação ao posicionamento de refletores sísmicos. Certamente há ganhos e perdas, por exemplo, se a RND detecta refletores de pequenas amplitudes, a mesma pode também detectar refletores que não existem na realidade e que foram confundidos com os lóbulos menores da função-fonte. Porém, se por outro lado, a rede não detectar esses refletores de baixas amplitudes, pode-se estar perdendo informações que podem ser importantes na análise do meio geológico.



**Figura 5.43** – Avaliação da resolução da RND em termos do comprimento teórico do pulso fonte. Para o exemplo apresentado, o posicionamento dos refletores recuperados pela rede, necessita de um afastamento de no mínimo a metade (16 amostras) do comprimento do pulso fonte para refletores de mesma polaridade, e de comprimento de um pulso fonte (32 amostras) para refletores com polaridades opostas.



**Figura 5.44** – Avaliação do pulso fonte sobre a resolução da RND, mostrando a semelhança dos lóbulos maiores e lóbulos menores.

### 5.2.5- Modelo da teoria do raio

A utilização da RND para a detecção dos refletores sísmicos é analisada para dados sintéticos gerados pela teoria do raio. O programa utilizado foi o SEIS88 (Cerveny 1977).

O modelo geométrico utilizado é um modelo 2-D, lateralmente não homogêneo, com interfaces curvas, especificadas por coordenadas arbitrárias. A fonte pode estar situada em qualquer ponto do meio, com exceção de camadas com espessura zero, ou seja, ela não pode estar situada entre duas interfaces coincidentes.

Na seção sísmica, afastamento-nulo (*zero offset*) da Figura 5.45, é visualmente trivial para o intérprete a marcação dos quatro refletores presentes. Além disso, ele teria que efetuar a leitura dos tempos de trânsito de cada refletor em cada traço. A utilização da RND propicia a automação desse procedimento a partir de sua dinâmica característica com a conveniente definição dos seus parâmetros livres (equações 5.8 e 5.9). O processamento da rede pode ser avaliado pela observação da Figura 5.46, que mostra a posição verdadeira dos refletores detectados, assim como as suas amplitudes estimadas. Vale ressaltar que esta é uma aplicação da RND para o caso de um pulso fonte de fase não-mínima. Observa-se também, que esta é apenas a representação gráfica do processamento realizado pela RND, que pode ser apresentado também na forma de tabela, mostrando para cada traço, os tempos de trânsito de cada um dos refletores detectados.

O próximo passo foi submeter a seção sísmica (*zero offset*) da Figura 5.45 a uma taxa de ruído na razão  $S/R= 15,7$ , conforme pode ser vista na Figura 5.47(b). Para uma melhor visualização é ilustrada na Figura 5.47(a) os três primeiros traços da seção. Em seguida, a RND atuou nesse sinal contaminado gerando como saída a seção ilustrada na Figura 5.48(b). Esta é também graficada em seus três primeiros traços para uma melhor análise do efeito produzido pelo ruído na seção sísmica da Figura 5.47. Verifica-se que ocorre uma detecção quase que completa dos coeficientes de reflexão, ocorrendo pequenas variações nas amplitudes estimadas desses coeficientes, mas, de um modo geral, gerando resultados satisfatórios.

Com isso, qualquer outro processamento sísmico que envolva a utilização dos tempos de trânsito dos refletores sísmicos (migração, inversão, etc.), poderá ser realizado de forma automática.

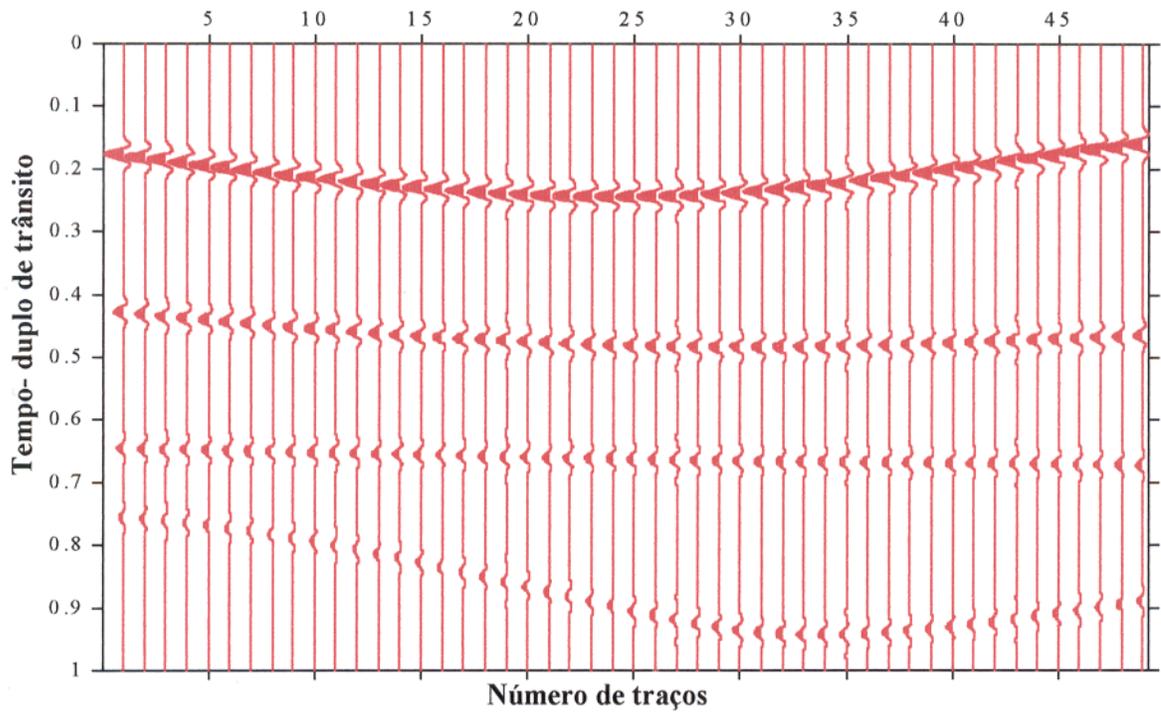


Figura 5.45 - Seção sísmica afastamento-nulo (*zero offset*) sem ruído.

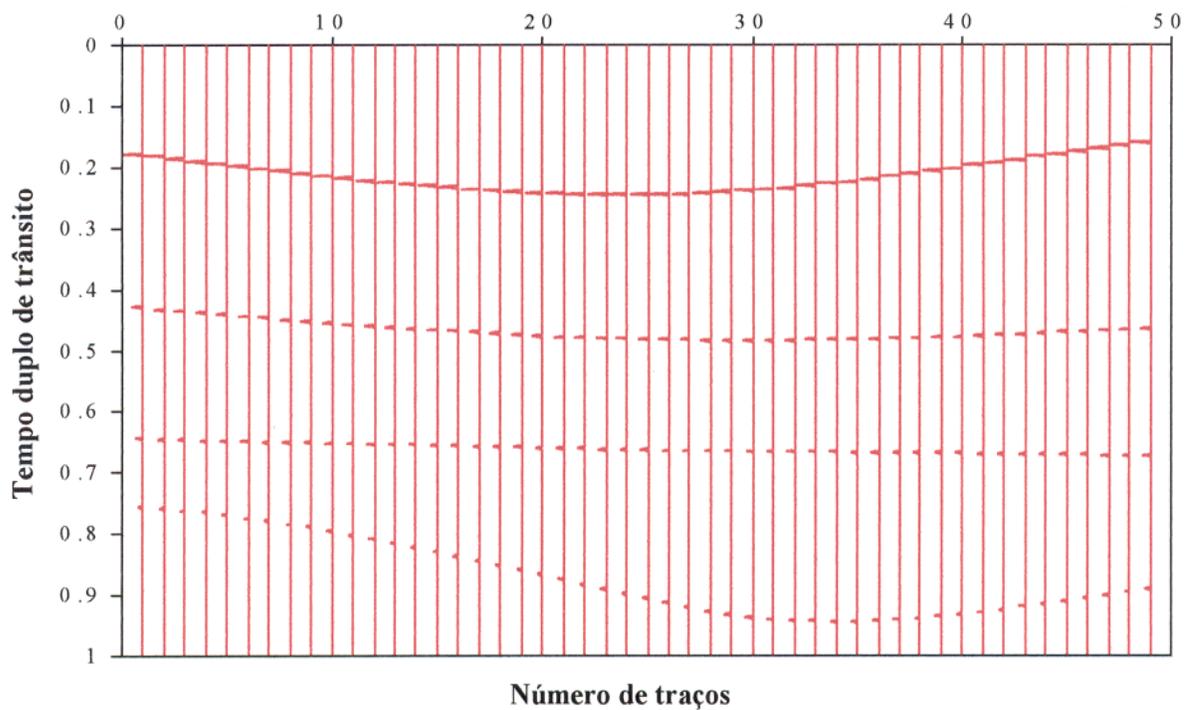
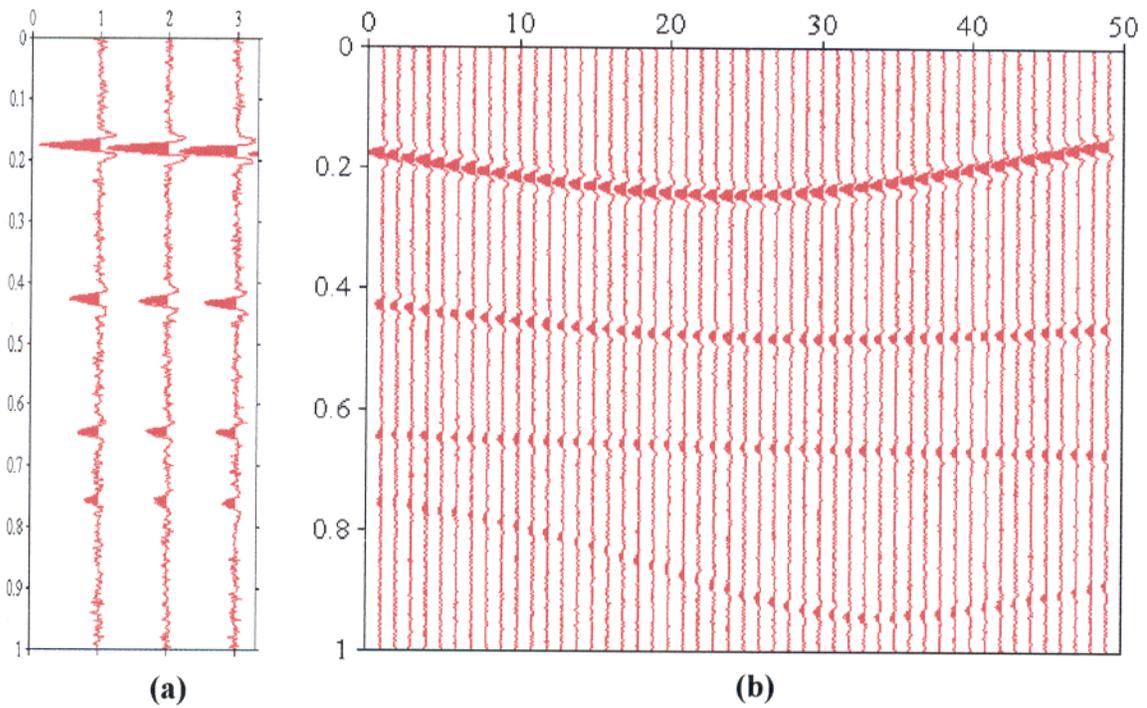
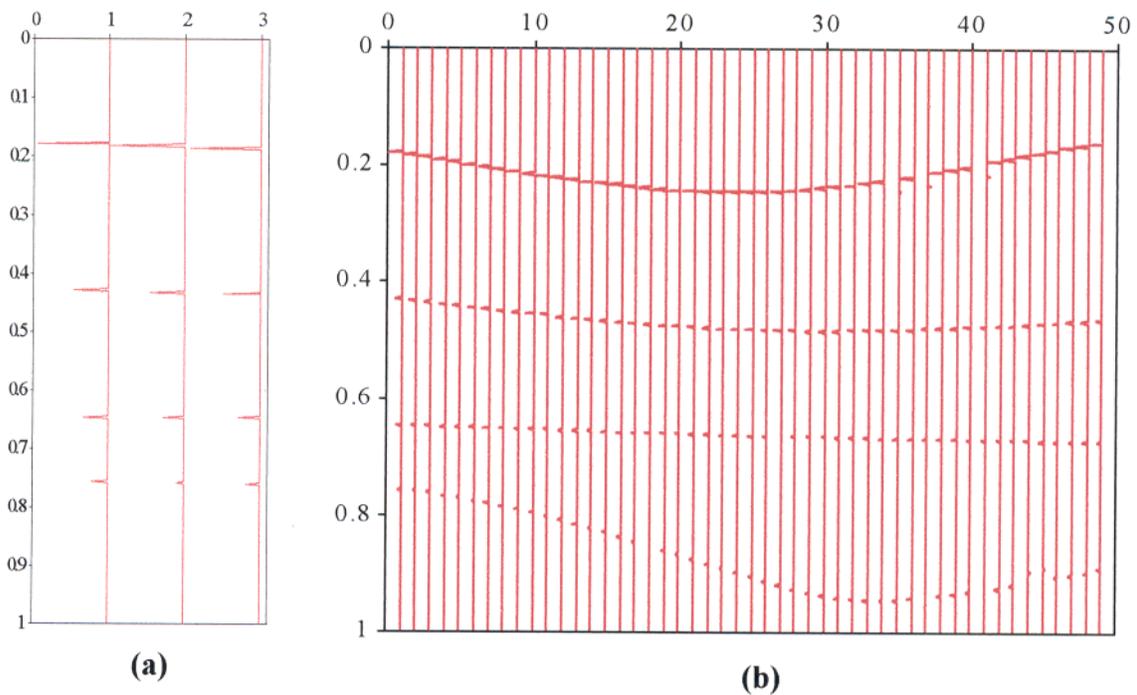


Figura 5.46 - Seção sísmica resultante da aplicação da RND mostrando a posição teórica e as amplitudes estimadas dos coeficientes de reflexão.



**Figura 5.47 – (b)** Seção sísmica afastamento nulo (*zero offset*) com razão  $S/R=15,7$ . **(a)** Ilustração dos três primeiros traços da seção.



**Figura 5.48 – (b)** Seção recuperada pela RND a partir da Figura 5.47. **(a)** Ilustração dos três primeiros traços da seção.

### 5.2.6- Comparação da RND com o filtro ótimo de Wiener-Hopf

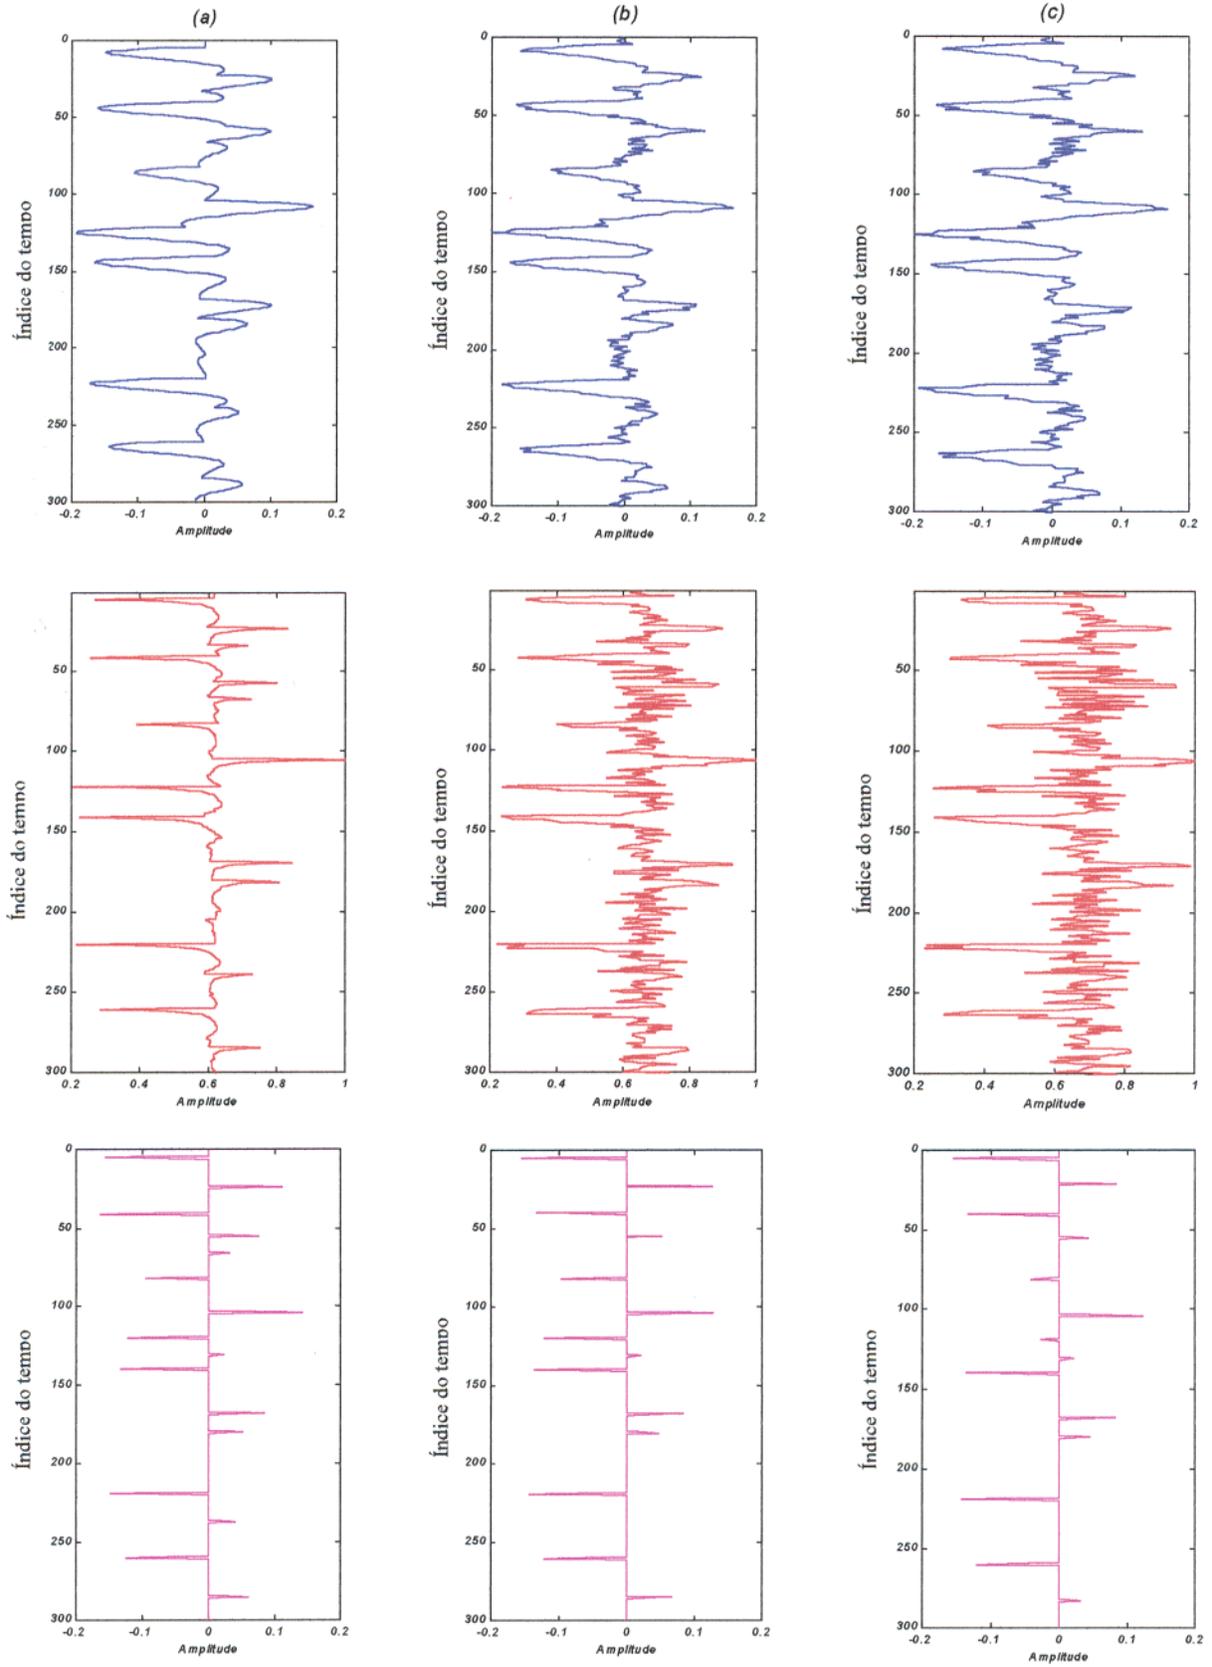
Um dos métodos clássicos dual de estimativa do pulso fonte e compressão dos eventos de um sismograma é o de Wiener-Hopf, descrito no Capítulo 2, que utiliza também o conceito do modelo convolucional simples.

Nesta seção é feita uma comparação simples entre os resultados de um filtro ótimo de Wiener-Hopf com os da RND, na determinação da polaridade e da estimativa da magnitude dos coeficientes de reflexão. O sismograma sintético é gerado por meio do modelo convolucional simples, utilizando como pulso fonte a função Berlage.

No primeiro gráfico da coluna (a) da Figura 5.49 é mostrado um traço sísmico, não contaminado por ruído. O resultado do operador de Wiener-Hopf sobre este traço é visto no segundo gráfico da coluna (a). No último gráfico dessa coluna é ilustrado a resposta da RND. No primeiro gráfico das colunas (b) e (c) da Figura 5.49 são ilustrados dois traços sísmicos, contaminados com ruído, cujas razões são, respectivamente,  $S/R=44.8$  e  $S/R=22.7$ . Eles estão seguidos dos demais gráficos que ilustram a deconvolução por Wiener-Hopf e a saída RND.

Nos resultados da aplicação do filtro de Wiener-Hopf, observa-se a contração dos pulsos relacionados à presença dos refletores. A dificuldade aparece à medida que é adicionado mais ruído no traço sísmico ocasionando por conseguinte uma amplificação desses ruídos.

Considerando o experimento, sob as mesmas condições simples de comparação, verifica-se que a aplicação da RND resultou em uma recuperação bastante satisfatória da função refletividade, reproduzindo na íntegra a polaridade e o posicionamento dos coeficientes de reflexão. Ocorrem, no entanto, pequenos desvios em relação às amplitudes desses coeficientes, a medida que se aumentou a contaminação por ruído. Pode-se dizer, então, que a RND mostrou-se bastante robusta quanto ao conteúdo de ruído presente nos dados, uma vez que não influenciou de na recuperação das polaridades e posicionamentos dos refletores sísmicos.



**Figura 5.49** - Comparação entre o filtro de Wiener-Hopf e a RND. (a) Sinal sem ruído; (b) Sinal com razão S/R = 44,8. (c) Sinal com razão S/R = 22,7.

## 6 - CONCLUSÕES

O desenho de uma nova arquitetura de rede neural do tipo recorrente apresentada neste trabalho, sob a denominação de RND, vem de encontro à necessidade da redução do tempo de processamento e conseqüente melhoria da qualidade dos traços sísmicos processados. A principal vantagem dessa nova arquitetura de rede é que, apesar da utilização de um modelo linear simples para a obtenção de suas equações, as quais descrevem os parâmetros livres da rede, o processamento aqui apresentado através da RND mostra uma boa flexibilidade para o tratamento de modelos não lineares, isto deve-se ao fato de que a RND não discrimina o tipo de pulso fonte utilizado na determinação de seus parâmetros livres,  $w_{ij}$  e  $I_i$ , podendo ser de fase-mínima, fase-máxima ou fase-misturada.

Este processo não deve ser entendido na forma de um método deconvolucional clássico. Pelo próprio desenvolvimento teórico da RND, o enfoque principal é dado para a determinação das verdadeiras posições temporais (ou espaciais), com a correspondente polaridade dos refletores sísmicos, uma vez que, pelas características específicas da rede, apenas dois parâmetros podem ser determinados,  $w_{ij}$  e  $I_i$ . Esta qualidade já a diferencia sobremaneira dos trabalhos anteriores utilizando a rede de Hopfield.

Neste trabalho, optou-se pela procura da possibilidade de um processamento eficiente para alcançar os objetivos, que consiste na detecção do posicionamento dos coeficientes de reflexão. Com isso, abriu-se mão, de uma maior ênfase para a determinação das verdadeiras amplitudes desses coeficientes, em função da maior complexidade dos eventos responsáveis pelos valores grafados nos sismogramas.

As perspectivas futuras desse trabalho seguem duas linhas de pensamento. A primeira é no sentido da ampliação das aplicações da RND do tipo recorrente para dados sísmicos reais, nos quais as técnicas convencionais de filtragem e deconvolução no tempo podem ser substituídas por rede neural. A segunda, prossegue com aplicação na extração do pulso fonte a partir do sismograma, e na obtenção das verdadeiras amplitudes dos refletores sísmicos de forma simultânea.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALDRIDGE, D. F. 1990. *The Berlage Wavelet*. Geophysics, v.55, n.11: p 1508-1511.
- BRACEWELL, R. M. 1986. *The Fourier Transform and Its applications*. New York, USA, McGraw-Hill Book, Co., 275 pg.
- CERVENY, V.; MOLOTKOV, I. A. & PSENCIK, I. 1977. *Ray Method in Seismology*. Karlova University, Praga, 140 pg.
- CLAERBOUT, J. F. 1985. *Fundamentals of Geophysical Data Processing*. California, USA, Blackwell Scientific Publications, 220 pg.
- COHEN, M.A., & S. CROSSBERG. 1983. *Absolute Stability of Global Pattern Formation and Parallel Memory Storage by Competitive Neural Networks*. IEEE Transactions on Systems, Man, and Cybernetics SMC-13, p. 815-826.
- DIMRI, V. 1992. *Deconvolution and Inverse Theory*. Amsterdam, Holanda, Elsevier Science Publishers B. V, 367 pg.
- HAYKIN, S. 1998. *Neural Networks*. New York, USA, McMillan College Publishing Co., 350 pg.
- HOPFIELD, J.J. 1982. *Neural Networks and Physical Systems with Emergent Collective Computational Abilities*. Proceedings of the National Academy of Sciences of the USA 79, p. 2554 - 2558.
- HUBRAL, P. & KREY, T. 1980. *Interval Velocities From Seismic Reflection Time Measurements*. Society of Exploration Geophysicists, Tulsa, Oklahoma, 74101.
- LEITE, L. W. B. 1998. *Introdução a Análise Espectral em Geofísica*. Belém, Pará. FADESP/CNPq, 424 pg.
- LEITE, L. W. B. 1999. *Tópicos Especiais da Transformada-Z na Propagação de Ondas Elásticas Planas*. Primeiro semestre de 1999. Curso de Pós-Graduação em Geofísica, CG, UFPa. (Notas de aula).
- MC CULLOCH, W. S. & PITTS, W. 1943. *A Logical Calculus of the Ideas Immanent in Nervous Activity*. Bulletin of Mathematical Biophysics, v5, p.115-133.
- MENDEL, J. M. 1983. *Optimal Seismic Deconvolution*. New York, USA, Academic Press, Inc., 345 pg.

- MENKE, W. 1984. *Geophysical Data Analysis: Discrete Inverse Theory*. Londres, Inglaterra, Academic Press, Inc., 327 pg.
- ROBINSON, E.A. 1967. *Statistical Communication and Detection*. Londres, Inglaterra, Charles Griffin and Company Ltd.
- ROBINSON, E.A. & TREITEL, S. 1967. *Principles of Digital Wiener Filtering*. Geophysical Prospecting, v. 15, n. 3, p. 311-333.
- SADI, HAMID N.AL 1979. *Seismic exploration: technique and processing*. Boston, Stuttgart, Birkhäuser, Basel, 176 pg.
- WANG, L. X. MENDEL, J. M. 1992. *Adaptive minimum prediction-error deconvolution and source using Hopfield neural networks*. Geophysics, v.57, n.4 : p.670-679.
- YILMAZ, O. 1989. *Seismic Data Processing*. Society of Exploration Geophysics. Tulsa, USA, 557 pg.

## **Apêndice**

# Apêndice A

## Demonstração da condição $w_{ij} \geq 0$

Na teoria clássica das redes neurais do tipo recorrente é prescrito que a matriz de peso sináptico  $\{W=[w_{ki}]\}$  é simétrica, e os elementos de sua diagonal principal devem ser nulos. É demonstrado a seguir que tal exigência pode ser relaxada para a condição  $w_{ij} \geq 0$  no caso da rede neural recorrente discreta.

A variação do estado do neurônio  $v_j$  é dada simplesmente por

$$\Delta v_j = v_j(t) - v_j(t-1). \quad (\text{A.1})$$

A variação da função de Liapunov é semelhantemente dada por

$$\Delta E_j(t) = E_j(t) - E_j(t-1), \quad (\text{A.2})$$

onde  $E$  é dado por

$$E = -\sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i v_j + 2 \sum_{i=1}^N I_i v_i. \quad (\text{A.3})$$

Substituindo a expressão (A.3) em (A.2), tem-se que

$$\Delta E_j(t) = -\sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i(t) v_j(t) + 2 \sum_{i=1}^N I_i v_i(t) + \sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i(t-1) v_j(t-1) - 2 \sum_{i=1}^N I_i v_i(t-1). \quad (\text{A.4})$$

Admitindo a diagonal principal da matriz de peso sináptico diferente de zero,  $w_{ii} \neq 0$ , e sua condição de simetria,  $w_{ij} = w_{ji}$ , então

$$\begin{aligned} \Delta E_j(t) = & -2v_j(t) \sum_{i=1}^N w_{ij} v_i(t) - w_{jj} \left\{ [v_j(t)]^2 - v_j(t-1)v_j(t) \right\} + 2I_j v_j(t) + \\ & + 2v_j(t-1) \sum_{i=1}^N w_{ij} v_i(t) - w_{jj} \left\{ [v_j(t-1)]^2 - v_j(t-1)v_j(t) \right\} - 2I_j v_j(t-1) \end{aligned} \quad (\text{A.5})$$

e

$$\Delta E_j(t) = -2[v_j(t) - v_j(t-1)] \left[ \sum_{i=1}^N w_{ij} v_i(t) - I_j \right] - w_{jj} \left\{ [v_j(t)]^2 - 2v_j(t-1)v_j(t) + [v_j(t-1)]^2 \right\}. \quad (\text{A.6})$$

Utilizando a expressão (A.1), (A.6) simplifica para

$$\Delta E_j(t) = \underbrace{-2 \Delta v_j \left[ \sum_{i=1}^N w_{ij} v_i(t) - I_j \right]}_{\text{A}} \underbrace{- w_{jj} (\Delta v_j)^2}_{\text{B}}. \quad (\text{A.7})$$

Os termos “**A**” e “**B**” são sempre negativos se  $w_{jj} \geq 0$ . Assim, o decaimento uniforme da função energia associado à variação dos estados dos neurônios da rede discreta prescinde da imposição de que a matriz de pesos sinápticos  $W$  possua sua diagonal principal igual à zero, bastando somente que  $w_{jj} \geq 0$ .

Para a aplicação da RND, no caso de posicionamento temporal dos refletores sísmicos, é apenas suficiente reconhecer que

$$w_{jj} = \sum_{k=1}^N U_{k-j} U_{k-j} \geq 0 \quad , \quad (\text{A.8})$$

com a diagonal de  $W$  dada por termos da forma  $(U_{k-j})^2 \geq 0$ .