



Deconvolução de Perfis Geofísicos de Poço por Rede Neural Recorrente

Aldenize Ruela Xavier, Universidade Federal do Oeste do Pará

André Andrade, Universidade Federal do Pará

Carlos Eduardo Guerra, Universidade Federal do Oeste do Pará

Copyright 2008, SBGf - Sociedade Brasileira de Geofísica

Este texto foi preparado para a apresentação no IV Simpósio Brasileiro de Geofísica, Brasília, 14 a 17 de novembro de 2010. Seu conteúdo foi revisado pelo Comitê Técnico do IV SimBGf, mas não necessariamente representa a opinião da SBGf ou de seus associados. É proibida a reprodução total ou parcial deste material para propósitos comerciais sem prévia autorização da SBGf.

Resumo

O perfil geofísico, obtido através do deslocamento ascensional de uma ferramenta no interior de um poço, é visto como uma convolução da propriedade física real da rocha em subsuperfície, com a função que representa a distorção causada pela ferramenta nesta propriedade (resposta vertical da ferramenta). Neste trabalho, apresenta-se um método para a suavização das perturbações lineares produzidas pela ferramenta, sobre o perfil, com o desenvolvimento de três arquiteturas de redes neurais recorrentes, a primeira visa à estimativa da função resposta vertical da ferramenta, a segunda à definição dos limites verticais das camadas, e a terceira à obtenção da propriedade física. A aplicação do método aqui apresentado, para a melhoria da qualidade dos perfis de poço em dados sintéticos mostrou-se bastante eficiente, sendo possível a recuperação do perfil ideal. A sua aplicação aos dados da formação Lagunillas, bacia do Lago Maracaibo, Venezuela, mostrou eficiência para o caso dos perfis litológicos, aqueles que realizam a separação entre as rochas reservatórios e as selantes, como o perfil de raio gama natural.

Introdução

O perfil de poço é uma curva em função da profundidade, que mostra as variações de uma ou mais características ou propriedades físicas das rochas perfuradas (resistividade, potencial elétrico natural, tempo de trânsito de ondas mecânicas, radioatividade natural ou induzida, etc.). Tais curvas, obtidas através do deslocamento ascensional e contínuo de uma ferramenta de perfilagem no interior de um poço, são vistas como uma convolução da propriedade física real da rocha em subsuperfície, com a função que representa a distorção causada pela ferramenta nesta propriedade (resposta vertical da ferramenta).

Para a indústria do petróleo, o maior interesse é a obtenção destas propriedades da rocha o mais próximo possível da realidade em subsuperfície. Neste caso, precisa-se realizar a operação inversa à convolução para

extrair uma estimativa da propriedade real da rocha. Alguns trabalhos utilizaram metodologias diferentes na tentativa de solucionar este problema, como a estatística (Nosal, 1983) e a inteligência artificial (Baldwin *et al*), para determinar a resposta vertical da ferramenta, identificação das interfaces de camadas e a associação de dados do perfil de poço com a geologia. Andrade & Luthi (1997) desenvolveram um algoritmo interpretativo baseado em redes neurais (competitiva e função de base radial) para obter o imageamento da porosidade. Nikraves (2004), desenvolveu um algoritmo para determinar automaticamente a litologia em perfil de poço usando rede neural de multi-camadas. Fischetti & Andrade (2002) desenvolveram um algoritmo de rede neural para a determinação automática das interfaces em perfil de poço. Em todos os casos a busca é a mesma, tornar menor possível a diferença entre o perfil ideal e o perfil obtido pelo modelo convolucional. Na tentativa desta minimização é que se relaciona a função energia, característica da rede neural recorrente, com a função objeto de minimização do erro, comumente utilizada na geofísica. Entretanto, com a implementação ocorrendo através das redes neurais, evita-se a determinação das derivadas parciais desta função.

O problema tratado está dividido em três etapas. Na primeira etapa, busca-se estimar a resposta vertical da ferramenta, este resultado viabiliza o processamento das duas próximas fases. Na segunda etapa, busca-se a disposição geométrica das rochas em subsuperfície, no intuito de delimitar o topo e a base (interfaces) das diferentes rochas com melhor precisão. Na terceira etapa, busca-se minimizar o efeito da ferramenta sobre a magnitude da propriedade física, em cada uma das camadas rochosas atravessadas pelo poço. O resultado final deste processamento é utilizado pela indústria petrolífera para a avaliação econômica do volume de hidrocarboneto, contido na camada reservatório.

O processamento adotado para a solução de cada uma das etapas é o de construir arquiteturas convenientes de redes neurais recorrentes, propiciando uma maior clareza aos dados contidos nos perfis e otimizando o tempo gasto na interpretação, busca-se ainda, auxiliar a automação das outras etapas da avaliação de formação.

A eficiência e as limitações desta metodologia são exemplificadas com um perfil de raio gama natural, obtido na formação Lagunillas, bacia do Lago Maracaibo, Venezuela.

Metodologia/ Problema Investigado

Adota-se aqui uma arquitetura de rede neural (Figura 1), que pode ser tratada como uma variante das redes recorrentes clássicas, como a rede neural de Hopfield (Wang *et al*,1992).

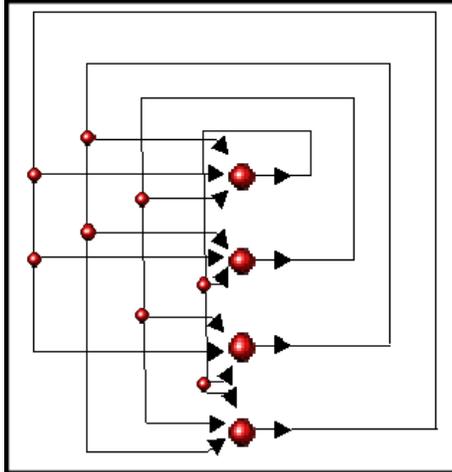


Figura 1 – Estrutura de uma rede neural recorrente.

A premissa fundamental neste trabalho é a da associação entre a função energia da rede com uma função de erro específica do problema. De tal modo, que o processo de decréscimo da função energia, induzido pela dinâmica da rede, leve a uma minimização local da função erro, aproximando o perfil processado do perfil ideal. Através desta associação determina-se a matriz de pesos sinápticos e o vetor de entradas externas, que serão utilizados pela rede para obtenção da identificação e a localização das interfaces em profundidade e com isto, a determinação das espessuras das camadas e os valores da propriedade física medidos em cada uma delas.

2.1 Rede Neural Recorrente

Para a rede neural recorrente adotada, define-se o potencial de entrada P_k , na forma

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

onde v_i representa o estado do neurônio no tempo t e

w_{ki} representa a matriz de pesos sinápticos, possuindo as seguintes propriedades: $w_{ki} = w_{ik}$ e $w_{kk} \geq 0$.

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

Apresenta-se a função de ativação de cada neurônio recorrente na forma

$$v_k(t) = f[P_k(t-1)] = \begin{cases} 1, & \text{se } P_k(t-1) \geq I_k \\ 0, & \text{se } P_k(t-1) < I_k \end{cases} \quad (2)$$

Esta formulação para a função de ativação difere daquela adotada na rede neural de Hopfield, devido à presença do parâmetro livre I_k , designado como entrada externa, determinante do novo estado do neurônio v_k no tempo t , como mostrado na Figura 2.

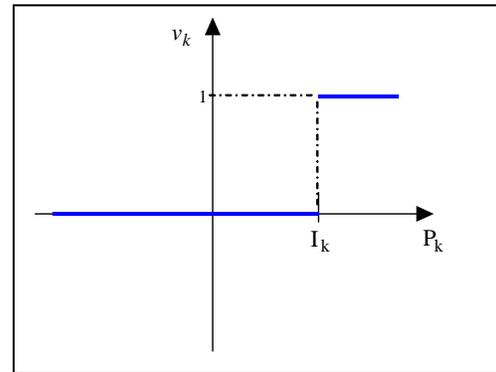


Figura 2 – Função de ativação da rede recorrente.

Adota-se como função energia uma forma variante à das redes recorrentes clássicas, escrita na forma

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

A variação da função energia ΔE associada à dinâmica de toda a rede, devido à mudança de estado de um único neurônio a cada instante de tempo, é sempre menor ou igual a zero, garantindo, com isso, a convergência para um mínimo local.

2.2 Modelo convolucional do perfil

Define-se a convolução entre duas funções $p(t)$ e $g(t)$ da seguinte forma

$$p * g = \int_0^t p(\xi)g(t-\xi)d\xi = \int_0^t p(\xi-t)g(t)dt = g * p \quad (4)$$

Para a convolução discreta unidimensional, entre duas séries temporais $p_i(t)$ e $g_i(t)$, tem-se

$$y = (p * g)_k = \sum_{i=1}^N p_i g_{k-i} \quad (5)$$

Um perfil de poço pode ser descrito através do modelo convolucional, na forma

$$y_i = \sum_{i=1}^N p_i g_{k-i} \quad (k = 1,2,3,\dots,N), \quad (6)$$

onde y_i representa o perfil geofísico mensurado no poço, p_i a distribuição ideal da propriedade física, considerada constante em cada um dos elementos infinitesimais de volume, que uma ferramenta de perfilagem investiga em

uma rocha. A resposta vertical da ferramenta (g_k), atua como um peso no cálculo da média móvel ponderada da propriedade física da formação (Figura 3).

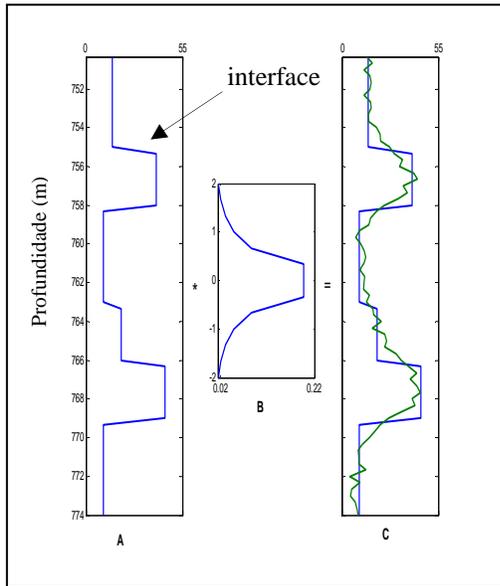


Figura 3 - Modelo convolucional do perfil. A) Perfil sintético. B) Resposta vertical da ferramenta. C) Perfil obtido através da convolução (linha verde).

A Figura 3(C) mostra um exemplo de um perfil geofísico obtido pelo modelo convolucional (linha verde), sendo que a resposta vertical da ferramenta e o perfil ideal, que mostram a posição das interfaces e o valor da propriedade física em cada camada, são vistos nas Figuras 3(B) e 3(A), respectivamente. Observa-se na figura 3(C) os efeitos, induzidos pela ferramenta no perfil, que desejamos reduzir com o processamento aqui apresentado, ou seja, a alteração na posição das interfaces e na magnitude das propriedades físicas, além do inevitável ruído das medidas, aqui tomado como aditivo e gaussiano.

2.3 Estimativa para o perfil ideal

O diagrama de blocos do modelo convolucional está representado na Figura 4, onde y_i representa o perfil geofísico mensurado, g_i a resposta vertical da ferramenta e p_i a propriedade física real da rocha. Deseja-se conhecer a distribuição da propriedade física da rocha com a profundidade, neste sentido insere-se o conceito de deconvolução aqui apresentado. Para o processamento com as três redes recorrentes aqui desenvolvidas, temos que prover uma estimativa externa para o valor da função resposta vertical da ferramenta g_i , como em Andrade e Luthi (1997), bem como, para os valores das propriedades físicas em cada uma das camadas.

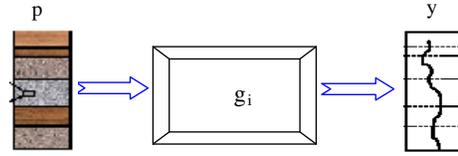


Figura 4 - Diagrama de blocos do modelo convolucional do perfil geofísico, y_i é o perfil geofísico de poço e p_i representa as propriedades das rochas.

2.4 Rede neural para a recuperação da resposta da ferramenta

A função característica do problema é escrita como a função objeto de minimização do erro, a qual é representada pela soma dos quadrados dos desvios, dada por

$$E = \frac{1}{2} \sum_{k=1}^N (y_k - y'_k)^2, \quad (7)$$

onde y'_k é o perfil obtido pelo modelo convolucional mostrado na expressão (6) e y_k o perfil medido.

Assumindo $g_i \neq 0$ e $p_i \neq 0$ para $i > 0$ a expressão (7) pode ser escrita da seguinte maneira

$$E = \frac{1}{2} \sum_{k=1}^N \left(y_k - \sum_{i=1}^N p_{k-i} g_i \right)^2. \quad (8)$$

A resposta vertical da ferramenta é obtida em duas etapas. A primeira trata da obtenção de sua estimativa externa (g_{est}), [3]. A rede neural recorrente será, então, escrita para obter uma correção desta estimativa externa. Assim, a resposta vertical da ferramenta (g_{rec}) será escrita na forma

$$g_{rec} = g'_i g_i^{est}. \quad (9)$$

Em seguida g'_i pode ser normalizado de modo a satisfazer $|g'_i| \leq 1$. Sendo assim, g'_i atua como um peso para a correção da resposta vertical da ferramenta (g_i^{est}) e expresso por,

$$g'_i = \left(\sum_{j=1}^M \frac{1}{2^{j-1}} x_{ij} \right) - 1, \quad (10)$$

onde x_{ij} assumem valores em $\{0,1\}$. Essa expressão pode ser entendida como uma decodificação de um vetor binário com M posições.

Substituindo a expressão (9) na expressão (8), e desprezando os termos que não dependem de x_{ij} , tem-se para a função energia, associada à solução do problema de determinação da resposta vertical da ferramenta, a expressão

$$E = - \sum_{k=1}^N \left[\sum_{i=1}^N p_{k-i} \sum_{j=1}^N \frac{1}{2^{j-1}} \left(y_k + g_i^{est} \sum_{i=1}^N p_{k-i} \right) g_i^{est} \right] x_{ij} + \frac{1}{2} \sum_{i_1=1}^N \sum_{i_2=1}^N \sum_{j_1=1}^M \sum_{j_2=1}^M \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} g_{i_1}^{est} g_{i_2}^{est} x_{i_1 j_1} x_{i_2 j_2}. \quad (11)$$

Associando a equação (11) com a equação (3) tem-se a matriz de pesos sinápticos da rede, dada por

$$w_{i_1 i_2 j_1 j_2} = -2 \sum_{k=1}^N p_{k-i_1} p_{k-i_2} \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} g_{i_1}^{est} g_{i_2}^{est} \quad (12)$$

e o vetor de entrada externa, dado por

$$I_j = \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N p_{k-i} \frac{1}{2^{j-1}} \left(y_k + g_i^{est} \sum_{i=1}^N p_{k-i} \right) g_i^{est} \quad (13)$$

No caso presente, a seqüência temporal que descreve a resposta vertical da ferramenta não tem nenhum significado físico, sendo apenas um elemento de processamento necessário à obtenção da espessura das camadas e à determinação do valor real da propriedade física.

2.5 Rede neural para a identificação das interfaces.

Para identificar a presença das interfaces, escreve-se a seqüência p_i , da seguinte maneira

$$p_i = c_i + r_i \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) \quad (14)$$

onde c representa o valor da propriedade física na camada i , representada pelo perfil quadratizado, a seqüência $r_i \in \{0,1\}$, que pode ser determinística ou aleatória, de tal forma que se $r_i = 1$, encontra-se uma interface de amplitude dada

por $\frac{c_{i-1} + c_{i+1}}{2}$ e se $r_i = 0$, encontra-se uma camada

considerada homogênea e isotrópica, apresentando uma amplitude constante igual a c_i .

Fazendo a substituição da expressão (6) na expressão (7), adotando o valor de p_i dado pela equação (14) e desprezando os termos que não dependem de r_i , obtém-se a seguinte expressão

$$E = - \sum_{k=1}^N \sum_{i=1}^N \left(y_k - \sum_{j=1}^N c_j g_{k-j} \right) h_i g_{k-i} r_i + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N h_i h_j g_{k-i} g_{k-j} r_i r_j, \quad (15)$$

onde os termos h_i e h_j são dados por

$$h_i = \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) \quad \text{e} \quad h_j = \left(\frac{c_{j-1} + c_{j+1}}{2} - c_j \right).$$

Fazendo uma associação, termo a termo, das expressões (3) e (15) obtém-se a matriz de pesos da rede, dada por

$$w_{ij} = \frac{1}{2} \sum_{k=1}^N h_i h_j g_{k-i} g_{k-j} \quad (16)$$

e o vetor de entrada externa, expresso da seguinte forma

$$I_i = - \frac{1}{2} \sum_{k=1}^N \left(y_k - \sum_{j=1}^N c_j g_{k-j} \right) h_i g_{k-i}, \quad (17)$$

para $i \neq j$, em que $1 \leq i, j \leq N$ e, $w_{ij} \geq 0$ para $i = 1, 2, 3, \dots, N$, e c é o valor da propriedade física na camada i .

2.6 Rede neural para a obtenção da propriedade física.

O objetivo nesta parte do trabalho é a recuperação do perfil ideal, que contém a representação das camadas litológicas distintas e os valores da propriedade física mensurada. A rede neural cujos pesos sinápticos foram

determinados pela equação (16) e a entrada pela equação (17), fornece as posições das interfaces das camadas. Para que se possa encontrar o valor da propriedade utilizada-se, novamente, a função objeto de minimização do erro da equação (7) e faz-se necessário que a distribuição ideal da propriedade física deixe de ser expressa pela equação (14) e passe a ser expressa pela equação abaixo

$$p_i = p'_i p_i^{est}, \quad (18)$$

onde p_i^{est} é o perfil quadratizado e p'_i é dado pela seguinte expressão

$$p'_i = \left(\sum_{j=1}^M \frac{1}{2^{j-1}} x_{ij} \right) - 1, \quad (19)$$

onde x_{ij} representa a saída dos neurônios, no conjunto $\{0,1\}$.

Desenvolvendo a expressão (7), através do modelo convolucional, utilizando para a nova expressão do p_i dada na equação (18) e desprezando os termos que não dependem de x_{ij} e, além disso, como a minimização que deve ser realizada é pontual, o valor de p_i dispensa o somatório em k e então, obtemos a seguinte expressão para a função energia

$$E = - \left[\sum_{i=1}^N g_{k-i} \sum_{j=1}^N \frac{1}{2^{j-1}} \left(y_k + p_i^{est} \sum_{i=1}^N g_{k-i} \right) p_i^{est} \right] x_{ij} + \frac{1}{2} \sum_{i_1=1}^N \sum_{i_2=1}^N \sum_{j_1=1}^M \sum_{j_2=1}^M \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} p_{i_1}^{est} p_{i_2}^{est} x_{i_1 j_1} x_{i_2 j_2}. \quad (20)$$

Associando a equação (20) com a equação (3) tem-se a seguinte matriz de pesos sinápticos, dada por

$$w_{i_1 i_2 j_1 j_2} = -2 g_{k-i_1} g_{k-i_2} \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} p_{i_1}^{est} p_{i_2}^{est} \quad (21)$$

e o vetor de entrada externa será dado por

$$I_j = \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N g_{k-i} \frac{1}{2^{j-1}} \left(y_k + p_i^{est} \sum_{i=1}^N g_{k-i} \right) p_i^{est}. \quad (22)$$

O perfil da Figura 5(A), foi obtido através da convolução entre o perfil ideal da figura 5(B) e de uma função que representa a resposta vertical da ferramenta.

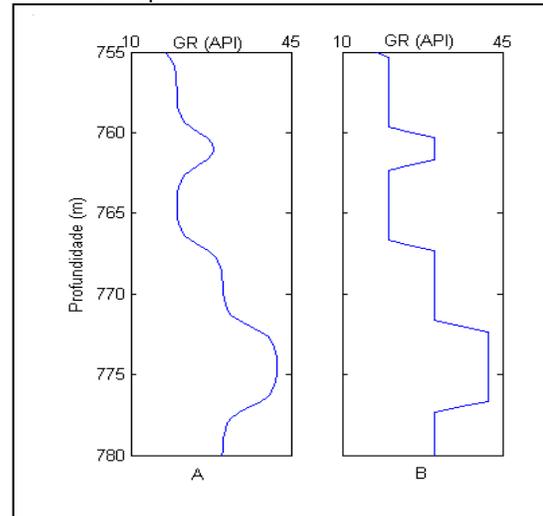


Figura 5 - A) Modelo sintético de raio gama natural obtido pelo modelo convolucional. B)

Perfil real de raio gama utilizado para obter o modelo convolucional.

Após o processamento da rede obtem-se a propriedade física da rocha, representada em vermelho, na Figura 6.

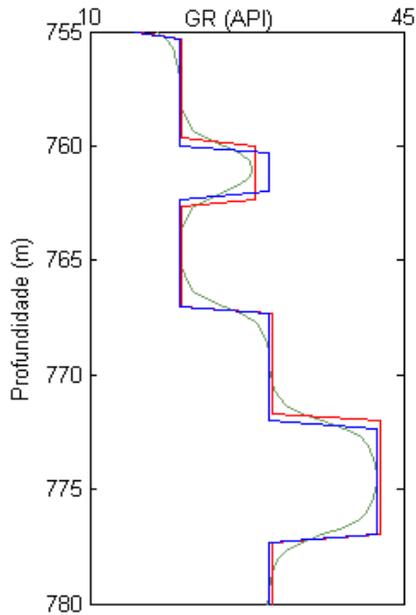


Figura 6 - Perfil obtido pelo processamento da rede neural recorrente (vermelho) e perfil real (azul), perfil convolvido, (verde).

Apresenta-se uma aplicação dos dados reais do perfil de poço da formação Lagunillas na bacia do Lago Maracaibo, localizado a oeste da Venezuela.

Na Figura 7(A) tem-se o perfil de raio gama natural do poço. A Figura 7(B) mostra, em azul, o perfil utilizado como primeira aproximação para a propriedade física da rocha e, em verde, o valor da propriedade corrigido através do processamento das redes neurais recorrentes. Na Figura 7(C), observa-se a diferença entre o valor da propriedade medido pela ferramenta e o valor corrigido. Para alguns trechos do perfil, obtem-se valores de raios gama maiores do que indica a ferramenta, também detecta-se o inverso,

para outros trechos do perfil. Isto ocorre devido à suavização da contaminação da resposta vertical da ferramenta, feita pela rede neural. Através desta melhoria na qualidade dos dados, pode-se obter valores mais realistas das propriedades das rochas em subsuperfície, melhorando a avaliação econômica do volume de hidrocarboneto contido na camada reservatório.

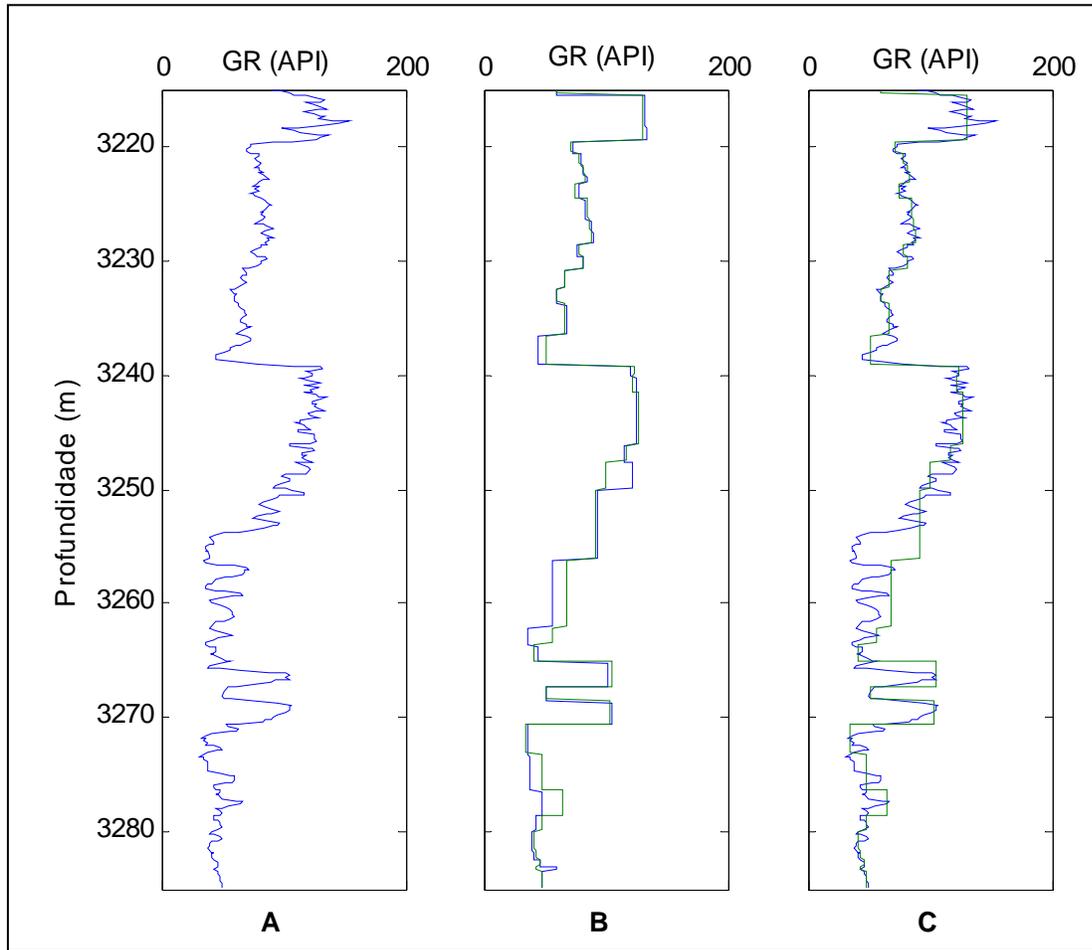


Figura 7 - A) Perfil de raio gama natural. B) Perfil quadratinizado (azul) x Perfil processado pela rede (verde). C) Perfil de raio gama natural x Perfil processado.

3. Conclusão

A redução no tempo de processamento dos dados de perfis de poço, a retirada autônoma de informações destes dados e a busca pela melhor representação da subsuperfície são uma necessidade imediata na indústria do petróleo e tem absorvido elevado custo computacional e econômico.

A aplicação do método aqui apresentado, para a melhoria da qualidade dos perfis de poço em dados sintéticos mostrou-se bastante eficiente, sendo possível a recuperação do perfil ideal. A sua aplicação aos dados da formação Lagunillas, mostrou eficiência para o caso dos perfis litológicos, aqueles que realizam a separação entre as rochas reservatórios e as selantes, como o perfil de raio gama natural.

4. Agradecimentos.

Os autores expressam seus agradecimentos à ANP e ao CNPq, pela concessão de bolsas de mestrado e pesquisa.

5. Referências

E. A. Nosal, 1983. *Statiscal Determination of geophysical well log response function*, Geophysics, 48, p. 1525-1535.

J.L. Baldwin, D. N. Otte, R. M. Bateman, 1989. *Computer Emulation of Human Mental Processes: Application of Neural Network Simulators to problems in well log interpretation*. SPE 64th Annual Technical Conference, USA.

A. Andrade, S. M. Luthi, 1997. *Determinação de Interfaces em Perfis através de Rede Neural de Hopfield*, 5^o Congresso Brasileiro de Geofísica.

M. Nikravesh, 2004. *Soft computing based computational intelligent for reservoir characterization*, Expert Systems with Applications, 26, 19-38,

A. I. Fischetti, A. Andrade, 2002. *Porosity images from well logs*, Journal of Petroleum Science and Engineering, 36, 149-158.

Wang, Li-Xin, Mendel Jerry M., 1992. *Adaptative minimum prediction-error deconvolution and source wavelet estimation using Hopfield neural network*, Society of Exploration Geophysicists, p. 670-679.