



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

DISSERTAÇÃO DE MESTRADO

**DECONVOLUÇÃO DE PERFIS DE POÇO ATRAVÉS DE
REDE NEURAL ARTIFICIAL RECORRENTE**

ALDENIZE DE LIMA RUÉLA

Belém - 2005

Universidade Federal do Pará
Centro de Geociências
Curso de Pós-Graduação em Geofísica

**Deconvolução de Perfis de Poço através de Rede Neural
Recorrente.**

Dissertação apresentada por

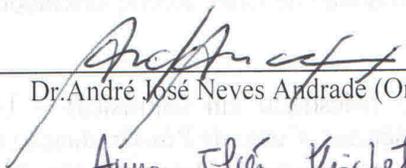
Aldenize de Lima Ruéla

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

Data de aprovação: 05/03/2006

Conceito: 94% (EXCELENTE)

COMITÊ DE TESE:



Dr. André José Neves Andrade (Orientador)



Dra. Anna Ilcéa Fischetti Miranda



Dr. Antonio Abel Gonzalez Carrasquilla

Belém
2005

Universidade Federal do Pará
Centro de Geociências
Curso de Pós-Graduação em Geofísica

**Deconvolução de Perfis de Poço através de Rede Neural
Recorrente.**

Dissertação apresentada por

Aldenize de Lima Ruéla

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

Data de aprovação:

Conceito:

COMITÊ DE TESE:

Dr. André José Neves Andrade (Orientador)

Dra. Anna Ilcéa Fischetti Miranda

Dr. Antonio Abel Gonzalez Carrasquilla

Belém
2005

*Aos meus pais, Francisco Ubirajara
Soares Ruéla e Benedita de Lima Ruéla
pelos incentivos e oportunidades que me
propiciaram.*

AGRADECIMENTOS

Ao Prof. Dr. André Andrade pela orientação, discussão, incentivo e, sobretudo pela dedicação com que se envolveu neste projeto tornando possível a realização deste trabalho.

Ao convênio ANP/UFPA/PRH-06 pela bolsa a mim concedida e pelo apoio ao Prolog (Laboratório de Processamento de dados Geofísicos de Poço).

Ao meu esposo, Elias Guimarães Xavier, pela sua paciência e apoio nos momentos mais difíceis.

À Maria de Jesus Cavalcante pela amizade e incentivo.

As amigas do Prolog: Poliana, Elyana, Anna Ilcéa e Anna Carmela, pelo companheirismo e contribuições nesta dissertação.

SUMÁRIO

DEDICATÓRIA	i
AGRADECIMENTOS	ii
LISTA DE ILUSTRAÇÕES	vi
RESUMO	01
ABSTRACT	02
1 INTRODUÇÃO	03
2 TÓPICOS EM GEOFÍSICA DE POÇO	06
2.1 INTRODUÇÃO.....	06
2.2 RESOLUÇÃO VERTICAL.....	06
2.3 LIMITES VERTICAIS DAS CAMADAS.....	08
2.4 RESPOSTA VERTICAL DA FERRAMENTA.....	10
2.4.1 O Fator Geométrico.....	11
2.5 MODELO CONVOLUCIONAL DOS PERFIS.....	14
3 REDES NEURAIS ARTIFICIAIS	16
3.1 INTRODUÇÃO.....	16
3.2 RESUMO HISTÓRICO.....	16
3.3 O NEURÔNIO BIOLÓGICO.....	17
3.4 O NEURÔNIO ARTIFICIAL.....	19
3.4.1 Neurônio Binário.....	20

3.4.2 Função de ativação	21
3.4.3 Pesos Sinápticos	22
3.5 REDE NEURAL DE HOPFIELD.....	23
3.5.1 Função Energia	24
4 DECONVOLUÇÃO DE PERFIS DE POÇO	26
4.1 INTRODUÇÃO.....	26
4.2 REDE NEURAL RECORRENTE.....	26
4.2.1 Parâmetros da Rede	27
4.2.1.1 Potencial de Entrada.....	27
4.2.1.2 Função de ativação.....	28
4.2.1.3 Função Energia.....	29
4.3 BLOCO DE PROCESSAMENTO.....	32
4.3.1 Perfil Quadratizado	33
4.3.2 Perfil de Alta Resolução	35
4.3.3 Estimativa da Resposta Vertical da Ferramenta	35
4.3.4 Recuperação da Resposta Vertical da Ferramenta	36
4.3.5 Identificação das Interfaces	38
4.3.6 Recuperação da Propriedade Física	39
5 RESULTADOS	41
5.1 APLICAÇÃO NA AVALIAÇÃO DE FORMAÇÃO.....	55
6 CONCLUSÃO	58
REFERÊNCIAS BIBLIOGRÁFICAS	59

Lista de Ilustrações

Figuras

Figura 2.1: Ferramenta de indução. L é o espaçamento entre as bobinas transmissoras e receptoras.....	6
Figura 2.2: Ferramenta de densidade. L_L é o espaçamento entre a fonte e o detector longe, as medidas realizadas neste ponto possuem alta profundidade de investigação e baixa resolução vertical, enquanto que a distância entre a fonte e o detector perto, L_p possui alta resolução vertical, porém baixa profundidade de investigação.....	7
Figura 2.3: Variação da resolução vertical e profundidade de investigação para os diferentes tipos de ferramentas de perfilagem.....	8
Figura 2.4: Identificação das interfaces em uma seção geológica.....	9
Figura 2.5: Resposta vertical 3D para uma ferramenta de indução de duas bobinas.....	12
Figura 2.6: Integração radial do fator geométrico diferencial $g(r)$ para $L = 1m$.	13
Figura 2.7: Integração vertical do fator geométrico diferencial $g(r)$ para $L = 1m$	13
Figura 2.8: Modelo convolucional do perfil. A) Perfil sintético ideal. B) Resposta vertical da ferramenta. C) Perfil obtido através da convolução (linha verde).....	15
Figura 3.1: Modelo do neurônio biológico.....	18
Figura 3.2: Sinapses.....	19

Figura 3.3: Modelo do Neurônio artificial de McCulloch-Pitts.....	20
Figura 3.4: Função de ativação degrau simples para um modelo de rede neural de Hopfield.....	22
Figura 3.5: Arquitetura da rede neural de Hopfield.....	23
Figura 3.6: Diferença entre mínimo local e mínimo global.....	24
Figura 4.1: Estrutura de uma rede neural recorrente com auto-alimentação.....	27
Figura 4.2: Função de ativação da rede recorrente.....	28
Figura 4.3: A) Perfil de raio gama natural.B) Perfil quadratizado. C) Perfil real (azul) e perfil quadratizado (vermelho).....	34
Figura 5.1: Exemplo, com dados sintéticos, do bloco de processamento com rede neural recorrente. A) Perfil sintético GR. B) Primeira estimativa para o perfil ideal (linha verde), perfil obtido como resultado final do processamento (linha vermelha) e perfil ideal (linha azul). C) Perfil ideal (linha azul), perfil obtido como resultado final (linha vermelha) e perfil sintético (linha verde).....	42
Figura 5.2: A) Perfil sintético GR. B) Perfil de alta resolução vertical. C) Perfil ideal (linha vermelha), perfil obtido como resultado final (linha azul) e perfil sintético (linha verde).....	43
Figura 5.3: A – Perfil de Raio Gama Natural (preto) e Perfil processado (azul). B Testemunho	44
Figura 5.4: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadratizado (linha azul) perfil processado através da rede neural recorrente (linha verde). C) Perfil de raio gama natural (linha azul) e perfil processado (linha verde).....	46

Figura 5.5: Segunda forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil de densidade. C) mostra a diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (linha verde).....47

Figura 5.6: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadratizado (linha azul) e perfil processado através da rede neural recorrente (linha verde). C) mostra o perfil de raio gama natural (linha azul) e o perfil obtido pelo processamento (linha verde).....49

Figura 5.7: Segunda forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil de densidade. C) mostra a diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (linha verde).....50

Figura 5.8: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadratizado (linha azul) e perfil processado através da rede neural recorrente (linha verde). C) mostra o perfil de raio gama natural (linha azul) e o perfil obtido pelo processamento (linha verde).....51

Figura 5.9: Segunda forma de processamento para o perfil real: A) mostra o perfil de raio gama natural (GR). B) Perfil de densidade. C) mostra a diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (verde).....52

Figura 5.10: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadratizado (linha azul) e perfil processado através da rede neural recorrente (linha verde). C) mostra o perfil de raio gama natural (linha azul) e o perfil obtido pelo processamento (linha verde).....53

Figura 5.11: Segunda forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil de densidade. C) mostra a diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (linha verde).....54

Figura 5.12: A) Perfil de raio gama natural (azul) e perfil processado com o quadratizado (verde). B) Volume de argila sem o processamento (azul), volume de argila com o processamento (verde).....56

Figura 5.13: A) Perfil de raio gama natural (azul) e perfil processado com o perfil de densidade (verde), B) Volume de argila sem o processamento (azul), volume de argila com o processamento (verde).....57

RESUMO

Para a indústria do petróleo, a interpretação dos perfis de poço é a principal fonte de informação sobre a presença e quantificação de hidrocarbonetos em subsuperfície. Entretanto, em duas situações as novas tecnologias, tanto em termos do processo construtivo das ferramentas, quanto da transmissão dos dados não têm justificativa econômica, ensejando a utilização de um conjunto de perfis convencionais: reavaliações de campos maduros e avaliações de campos marginais. Os procedimentos de aquisição dos perfis convencionais podem alterar o valor da propriedade física bem como a localização dos limites verticais de uma camada rochosa. Este é um antigo problema na geofísica de poço – o paradoxo entre a resolução vertical e a profundidade de investigação de uma ferramenta de perfilagem. Hoje em dia, isto é contornado através da alta tecnologia na construção das novas ferramentas, entretanto, este problema ainda persiste no caso das ferramentas convencionais como, a ferramenta de raio gama natural (GR). Apresenta-se, neste trabalho, um novo método para atenuar as alterações induzidas no perfil pela ferramenta, através da integração do clássico modelo convolucional do perfil com as redes neurais recorrentes. Assume-se que um perfil de poço pode ser representado através da operação de convolução em profundidade entre a variação da propriedade física da rocha (perfil ideal) e uma função que representa a alteração produzida sobre a propriedade física, chamada como resposta vertical da ferramenta. Assim, desenvolve-se um processamento iterativo dos perfis, o qual atua na forma da operação de deconvolução, composto por três redes neurais recorrentes. A primeira visa estimar a resposta vertical da ferramenta; a segunda procura definir os limites verticais de cada camada rochosa e a última é construída para estimar o valor real da propriedade física. Este processamento é iniciado com uma estimativa externa tanto para o perfil ideal, quanto para a resposta vertical da ferramenta. Finalmente, mostram-se as melhorias na resolução vertical e na avaliação da propriedade física produzida por esta metodologia em perfis sintéticos e em perfis reais da formação Lagunillas, bacia do Lago Maracaibo, Venezuela.

ABSTRACT

For oil industry, the logs analysis is the main information source about the presence and quantification of hydrocarbon in subsurface. However, in two situations the new logging technologies are not economically viable and conventional logging tools must be used: The reevaluation of mature oil fields and evaluation of marginal oil fields. In conventional logs its data acquisition procedure may blur the value of physical property and the vertical limits of a rock layer. We are talking about an old problem in well logging – The paradox between vertical resolution and depth of investigation of a logging tool. Nowadays it is well handling by the high technology of new tools, but this problem persists in conventional old tools, e.g. natural gamma ray log (GR). Here, we present a method to smooth this kind of linear distortion in well logs by an integration of classical well log convolution model with recurrent neural networks. We assume that a well log can be well represented by an in depth convolution operation between the variation of rock physical property (ideal log) and a function that causes the distortion, called as vertical tool response. Thus, we develop an iterative data processing, which acts as a deconvolution operation, composed by three recurrent neural networks. The first one seeks to estimate the vertical tool response; the second one search for the vertical limits definition of each rock layer and the last one is constructed to estimate the actual physical property. To start this process we supply an appropriated first guess of ideal log and vertical tool response. Finally, we show the improvements in vertical resolution and in the physical property evaluation produced by this methodology in synthetic logs and actual well log data from Lagunillas formation, Maracaibo basin, Venezuela.

1 INTRODUÇÃO

Nos últimos anos, tem aumentado, na América do Sul, o interesse na reavaliação de campos maduros, onde existem apenas dados de perfis convencionais ou campos marginais que não apresentam viabilidade econômica para o uso de novas tecnologias em perfilagem de poço. Estes fatos motivam uma revisão em um antigo problema da geofísica de poço, que é o paradoxo entre a resolução vertical e a profundidade de investigação das ferramentas de perfilagem. O interesse aqui é melhorar a resolução vertical sem alterar a profundidade de investigação da ferramenta, através de um algoritmo de processamento dos dados de perfil baseado na técnica das redes neurais recorrentes.

O perfil de poço é uma curva, em função da profundidade, que mostra as variações de uma ou mais propriedades físicas das rochas perfuradas (resistividade, potencial elétrico natural, tempo de trânsito de ondas mecânicas, radioatividade natural ou induzida, etc.). Para tais curvas, obtidas através do deslocamento ascensional e contínuo de uma ferramenta de perfilagem no interior de um poço, sendo cada um de seus pontos em profundidade uma média ponderada da propriedade física no interior de um volume de rocha investigado pela ferramenta. Assim, pode-se considerar o efeito da resposta vertical da ferramenta sobre o perfil, a alteração do valor real da propriedade física mensurada em um ponto em profundidade com informações indesejáveis da sua vizinhança. Neste sentido, o perfil de poço, como qualquer outra medida realizada através de sensores físicos, possui uma limitação intrínseca em sua resolução, isto é, na sua habilidade para distinguir dois eventos adjacentes. No ambiente do poço, o menor evento para o qual uma leitura verdadeira é obtida por uma ferramenta de perfilagem é chamado de resolução vertical intrínseca (Luthi, 2001). Esta resolução está geralmente relacionada com a configuração da ferramenta, ou seja, com o espaçamento entre bobinas nas ferramentas de indução ou com a distância fonte-detector nas ferramentas nucleares. A incapacidade de uma ferramenta de perfilagem em avaliar corretamente as camadas reservatórios com espessuras menores que a resolução vertical intrínseca é chamada de problema de *camada fina*. O termo *camada fina* é obviamente relativo e depende do tipo de perfil utilizado. Outro problema relacionado com a resolução vertical de um perfil de poço é a determinação da espessura aparente de uma camada rochosa, que depende da identificação em profundidade do topo e da base da camada atravessada pelo poço. O termo espessura aparente é utilizado no sentido de representar a distância entre o topo e a base de uma

camada vista pela ferramenta e só será a verdadeira espessura se a camada for plana e horizontal em relação ao eixo vertical do poço.

Retem-se esta discussão ao caso particular da resposta vertical unidimensional da ferramenta e considera-se como homogênea a formação rochosa que envolve o poço, para possibilitar a utilização da operação de convolução como modelo do perfil de poço e, assim, tratar o efeito da distorção da propriedade física produzido pela ferramenta através da operação inversa da convolução - a deconvolução.

Alguns autores utilizaram metodologias diferentes na tentativa de resolver este problema: métodos estatísticos (Nosal, 1983; Flexa et al., 2001), filtros e Transformada de Fourier (Barber, 1988; Andrade & Luthi, 1993) e rede neural de Hopfield (Andrade et al., 1995). Nos últimos anos, foram publicados muitos trabalhos mostrando a aplicabilidade de redes neurais artificiais na indústria do petróleo, envolvendo uma grande classe de algoritmos inteligentes, por exemplo, “soft” computing (Nikraves, 2004) e algoritmo interpretativo (Fischetti & Andrade, 2002).

Mostra-se aqui, uma aproximação da solução do problema de deconvolução de perfil de poço através da associação entre a função energia, relacionada com as redes neurais recorrentes e uma função erro, no sentido dos mínimos quadrados, relacionada com o problema. Assim, o comportamento descendente da função energia produzido pela dinâmica da rede é associado com a minimização da função erro. Nesta aproximação, as derivadas parciais da função erro são evitadas e mostra-se, também, que a limitação de minimização local da função energia não introduz problemas adicionais em sua aplicação à deconvolução de perfil de poço.

O roteiro desta dissertação apresenta, no capítulo 2, definições importantes de Geofísica de Poço, para o melhor entendimento do trabalho.

O capítulo 3 aborda de forma geral as redes neurais artificiais, com ênfase na rede neural recorrente mais comum que é a rede neural de Hopfield.

No capítulo 4 desenvolve-se o processo computacional iterativo através da descrição das três redes neurais recorrentes. A primeira visa estimar a resposta vertical da ferramenta; este resultado torna possíveis os dois próximos procedimentos. Com a segunda rede neural, estabelece-se a disposição geométrica, em subsuperfície, de cada camada rochosa, pela definição de suas interfaces (topo e base da camada). Na última, é estabelecida a minimização do efeito da ferramenta sobre a magnitude da propriedade física real da rocha.

A eficiência e as limitações desta metodologia são avaliadas no capítulo 5, com perfis sintéticos e perfis reais de raio gama natural (GR) da formação Lagunillas, bacia do Lago Maracaibo, Venezuela. O resultado final mostra a melhoria na resolução vertical e na avaliação da propriedade física com redução da relação sinal/ruído e no tempo de processamento dos dados dos perfis de poço. Mostram-se ainda os benefícios do uso deste processamento dos perfis para melhorar a avaliação do volume de folhelho.

2 TÓPICOS EM GEOFÍSICA DE POÇO

2.1 INTRODUÇÃO

Apesar dos avançados métodos geofísicos e geológicos atuais poderem sugerir locações mais prováveis para os reservatórios petrolíferos, somente após a perfuração do poço é que se confirmam ou não os prognósticos. Uma das formas mais comuns para a verificação do potencial produtivo de um poço é através da avaliação de formação, por meio dos perfis geofísicos. Para tanto é necessário o conhecimento sobre as características dos perfis e as limitações a eles associadas para a realização de inferências coerentes a respeito das propriedades de cada uma das camadas investigadas pela ferramenta de perfilagem ao longo do poço. Neste sentido, abordam-se, neste capítulo conceitos básicos sobre algumas das principais características do perfil geofísico como: a resolução vertical, os limites verticais das camadas, a resposta vertical da ferramenta, que podem ser convenientemente tratados através do modelo convolucional do perfil.

2.2 RESOLUÇÃO VERTICAL

Os perfis de poço, assim como qualquer medida obtida através de sensores físicos, têm uma limitação intrínseca em sua resolução, isto é, na sua habilidade em distinguir dois eventos distintos e adjacentes. O menor evento capaz de ser individualizado por uma ferramenta é chamado de resolução intrínseca. Esta resolução está geralmente relacionada à configuração ou construção da ferramenta: como o espaçamento entre bobinas na ferramenta de indução (Figura 2.1) ou como a distância fonte-detetor nas ferramentas nucleares (Figura 2.2).

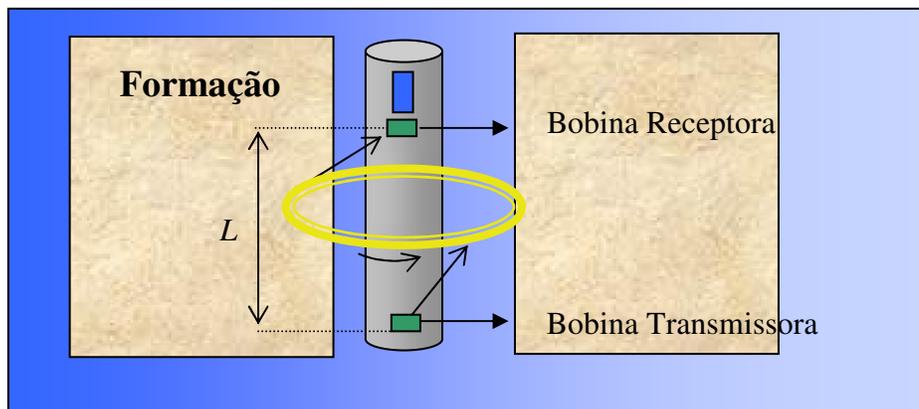


Figura 2.1: Ferramenta de indução. L é o espaçamento entre as bobinas transmissoras e receptoras.

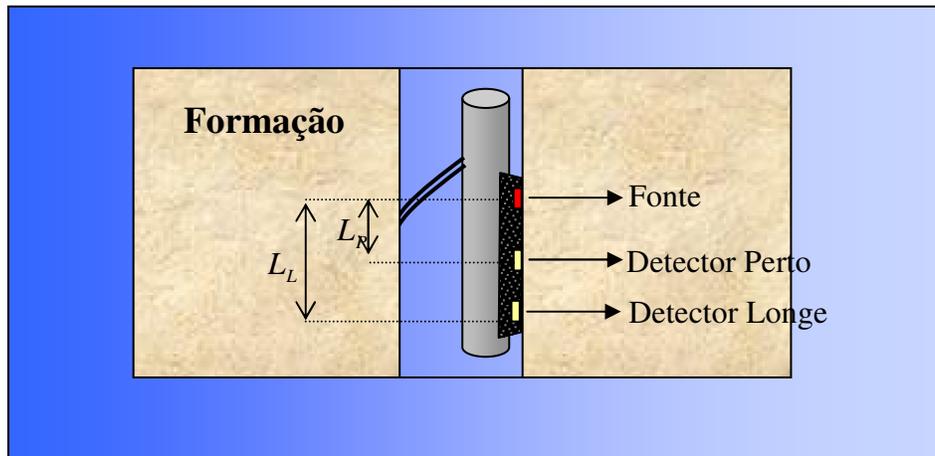


Figura 2.2: Ferramenta de densidade. L_L é o espaçamento entre a fonte e o detector longe, as medidas realizadas neste ponto possuem alta profundidade de investigação e baixa resolução vertical, enquanto que a distância entre a fonte e o detector perto, L_p possui alta resolução vertical, porém baixa profundidade de investigação.

A descrição da resolução da ferramenta de perfilagem pode ser dividida em duas partes: resolução horizontal ou profundidade de investigação e resolução vertical que define as espessuras das camadas.

A profundidade de investigação refere-se à distância, na direção do raio do poço, na qual a posição máxima de medida é realizada.

A resolução vertical é a espessura da camada necessária para que a ferramenta leia o verdadeiro valor da propriedade física na rocha investigada, sem a influência das rochas adjacentes e circunvizinhas, (Crain, 1986).

Devido a este fato, camadas geológicas muito finas geralmente não são percebidas pelas ferramentas da geofísica de poço. Na tentativa de amenizar este problema, utilizam-se medidas com diferentes profundidades de investigação e resolução vertical.

A resolução vertical refere-se, portanto, a menor espessura de camada que pode ser individualizada em um perfil, no ambiente sedimentar caracterizado por acamamentos.

A figura 2.3 mostra as profundidades de investigação e resolução vertical de algumas ferramentas de perfilagem, observe que as ferramentas com alta profundidade de investigação, ou seja, capaz de inferir sobre as rochas mais distantes do raio do poço, são as que possuem menor resolução vertical, isto é, não conseguem identificar as interfaces em camadas finas.

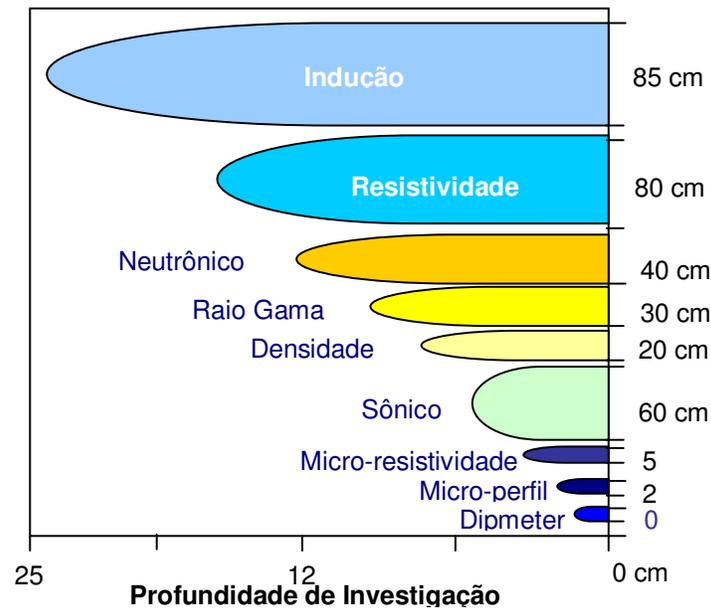


Figura 2.3: Variação da resolução vertical e profundidade de investigação para os diferentes tipos de ferramentas de perfilagem.

2.3 LIMITES VERTICAIS DAS CAMADAS

Nas bacias sedimentares, onde normalmente são colhidos os dados de perfil de poço aberto, o intérprete está particularmente interessado na localização em profundidade do topo e base das diversas camadas litológicas, depositadas ao longo do tempo, até o limite da perfuração do poço, com o objetivo de determinar a espessura aparente dessas camadas. O termo espessura aparente é utilizado no sentido de representar a distância entre o limite superior e o limite inferior da camada e, somente será tomada como a espessura verdadeira, se essa camada for plana e perpendicular em relação ao eixo do poço, o que não ocorre na maioria das situações geológicas.

A importância do conhecimento da espessura de uma camada pode ser avaliada através da análise da equação 2.1, a qual é, normalmente, utilizada para a avaliação econômica do volume de hidrocarboneto contido no reservatório,

$$V_o = (hA)\phi(1 - S_w). \quad (2.1)$$

O termo V_o representa o volume total de hidrocarboneto armazenado (in place) na rocha. A é a área do reservatório, S_w é a saturação de água na rocha, ϕ é a porosidade e, finalmente, h é a espessura da camada reservatório.

A determinação da espessura aparente de uma camada rochosa será obtida de forma indireta, a partir da definição das superfícies de contato das rochas vizinhas de diferentes litologias. Normalmente, nas bacias sedimentares, os contatos litológicos ocorrerão em função de variações do ambiente deposicional ou por efeito de erosão. Estas superfícies de contato, devido a sua natureza, não apresentam uma geometria bem definida e se apresentam nas mais variadas formas. Para contornar esse problema e possibilitar a sua identificação por meio dos perfis, conceitua-se o termo interface na forma: interfaces são superfícies planas de separação entre as camadas rochosas vizinhas, que possuem um contraste de natureza física mensurável por uma ferramenta de perfilagem de poço ou, apresentam diferentes formas geométricas da curva (padrões) nos perfis geofísicos de poço (Andrade, 1992).

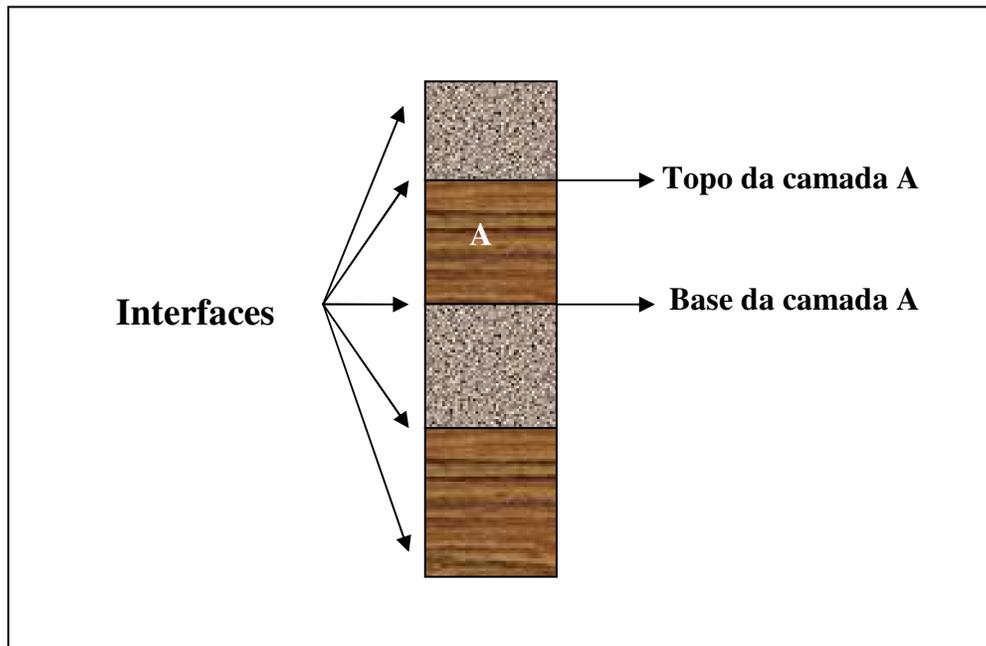


Figura 2.4: Identificação das interfaces em uma seção geológica.

Para a interpretação de perfis, um termo comumente utilizado para a identificação das formas geométricas, representativas de eventos geológicos em subsuperfície é o termo eletrofácies (Luthi, 2001), o qual descreve o conjunto de respostas dos perfis, que caracterizam uma camada rochosa, permitindo a sua distinção das demais. Os primeiros estudos visando uma abordagem quantitativa para a identificação litológica foram realizados por O. Serra (Luthi,

2001). Desde então, diversos métodos objetivando a determinação de litologias por meio de perfis têm sido propostos.

A fácies, convencionalmente sedimentar, faunal, etc., é conceituada por meio de um conjunto de atributos, os quais são característicos de certas rochas deformadas sob condições (ambientes) equivalentes. O termo eletrofácies difere do termo fácies, no sentido em que ele representa uma associação empírica do conjunto de respostas de perfis em lugar de propriedades com alguma significância genética das rochas. Entretanto, a disposição espacial das fácies sedimentares pode ser, na maioria dos casos, representada pelas eletrofácies, uma vez que a maioria dos processos sedimentares possui um característico intervalo de valores de uma propriedade física associada (Doveton, 1986).

2.4 RESPOSTA VERTICAL DA FERRAMENTA.

O sinal obtido a partir da passagem de uma ferramenta de perfilagem em frente a uma formação rochosa pode ser considerado, em cada ponto de observação, como uma média ponderada do valor do parâmetro físico sobre todo o volume de rocha investigado. Concentra-se, agora, sobre o conceito de função resposta vertical da ferramenta na forma unidimensional, onde deve ser explicitado, que este conceito é uma simplificação da realidade, na medida em que ele implica na hipótese de que a formação rochosa envolvendo o poço é radialmente homogênea e isotrópica.

A resposta vertical da ferramenta é um parâmetro intrínseco à mesma, que atua como peso para a determinação da medida realizada, ou a média ponderada do parâmetro físico da formação, considerado constante em cada um dos elementos infinitesimais de volume de rocha investigado pela ferramenta de perfilagem.

A função resposta vertical da ferramenta contamina o valor real do parâmetro em um ponto de medida com informações indesejáveis da sua vizinhança.

2.4.1 O Fator Geométrico.

A análise das características da ferramenta de indução feita por Henri Georges Doll em 1949, através da solução do problema eletromagnético (lei de Bio-Savart, eq. 2.2), levaram-no ao conceito de fator geométrico que é a idéia básica na qual a resposta vertical da ferramenta está inserida, para o caso especial de um arranjo de duas bobinas (figura 2.1)

A ferramenta de indução proposta por Doll, é constituída por um par de bobinas, uma transmissora e outra receptora, separadas por uma distância L e montadas sobre um mandril isolante.

A solução para o problema da ferramenta de duas bobinas é obtida através da lei de Bio-Savart e escrita como:

$$V = \left[\frac{4\pi w^2 A_t A_r I_t}{L} \right] \left[\frac{L}{2} \frac{r^3}{\left(r^2 + \left(\frac{L}{2} - z \right)^2 \right)^{3/2} \left(r + \left(\frac{L}{2} + z \right)^2 \right)^{3/2}} \right] C(r, z), \quad (2.2)$$

em que L é o espaçamento entre a bobina transmissora e receptora, A_t e A_r correspondem ao produto da área da bobina transmissora e receptora pelo número de voltas destas mesmas bobinas, I_t , corrente que alimenta a bobina transmissora, enquanto que r e z são as coordenadas cilíndricas de um anel unitário condutor de rocha.

Para valores fixos de L , o segundo termo da equação 2.2 é uma função de r e z , ou da posição espacial de um anel unitário. Ele é referido geralmente como sendo o fator geométrico diferencial, $g(r, z)$ (Ellis, 1987). Na ferramenta de indução, $g(r, z)$ representa a função resposta da ferramenta (Figura 2.5), ou seja, é um peso relativo que se atribui à condutividade de cada anel unitário de rocha por sua contribuição ao sinal total na bobina receptora. A voltagem final registrada é escrita na forma de uma convolução linear entre a resposta da ferramenta e a condutividade do meio ($C(r, z)$). Fazendo o termo entre o primeiro par de colchetes na eq. 2.2 como k ; a voltagem, segundo o modelo convolucional, pode ser escrita como:

$$V = k \int_0^\infty \int_{-\infty}^\infty g(r, z) C(r, z) dr dz \quad (2.3)$$

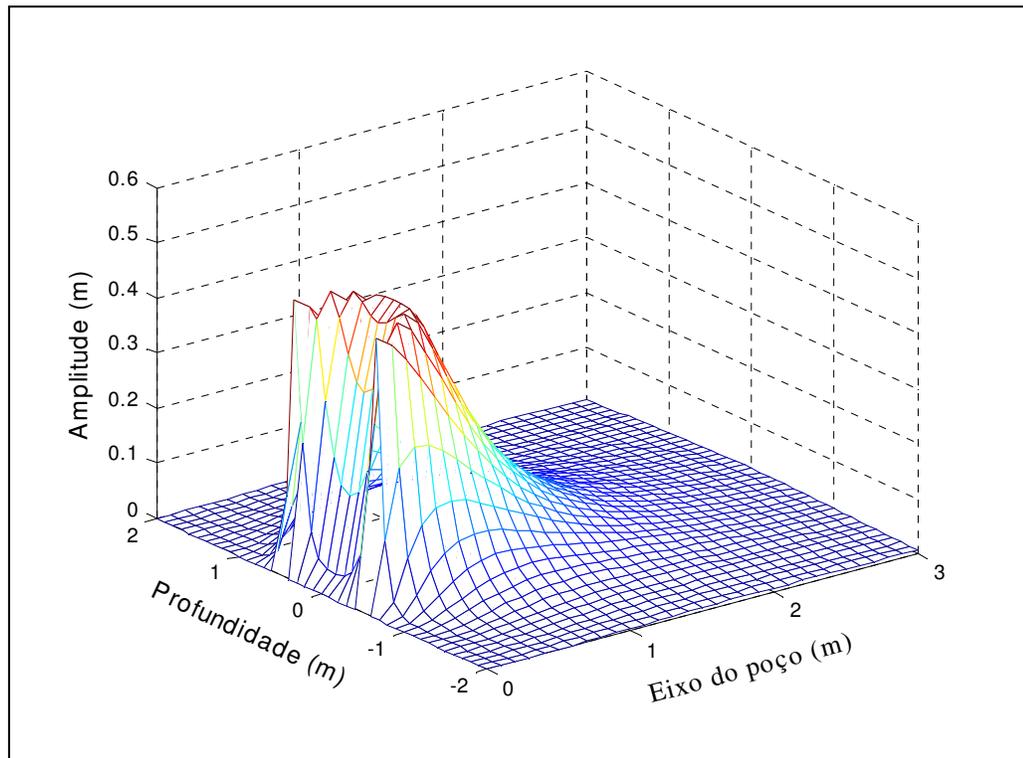


Figura 2.5: Resposta vertical 3D para uma ferramenta de indução de duas bobinas.

Para examinar-se separadamente os efeitos das investigações radial e vertical da ferramenta de duas bobinas, é necessário o cálculo de duas integrais

$$g(r) = \int_0^{\infty} g(r, z) dz, \quad e, \quad (2.4)$$

$$g(z) = \int_0^{\infty} g(r, z) dr. \quad (2.5)$$

A equação 2.4 refere-se à investigação radial enquanto a equação (2.5) refere-se à investigação vertical da ferramenta, como mostram respectivamente as Figuras 2.6 e 2.7.

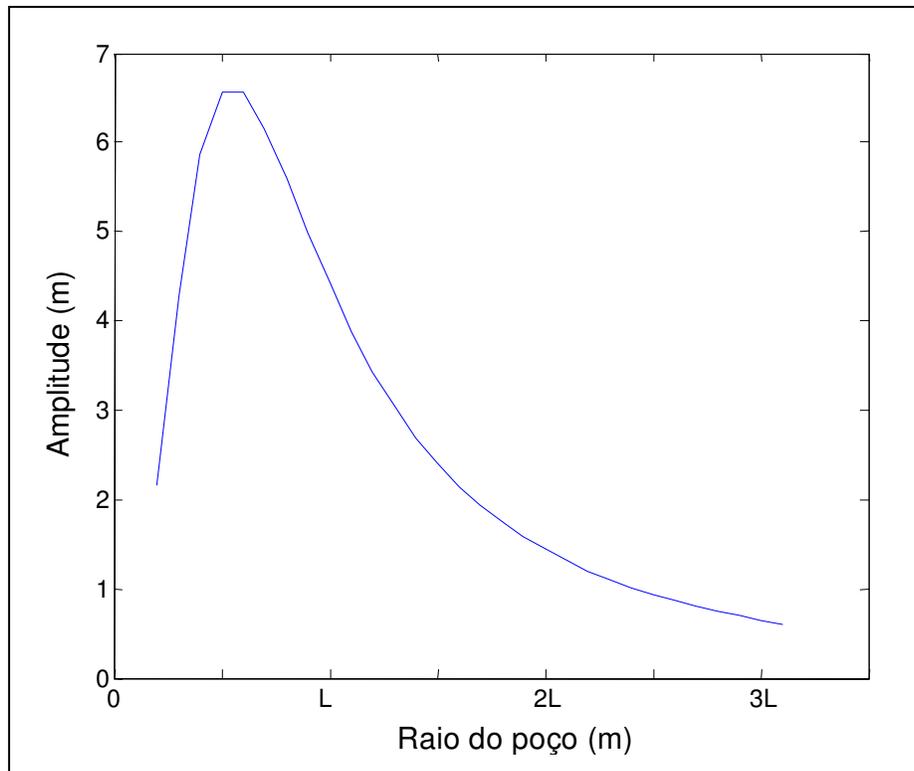


Figura 2.6: Integração radial do fator geométrico diferencial $g(r)$ para $L = 1\text{ m}$.

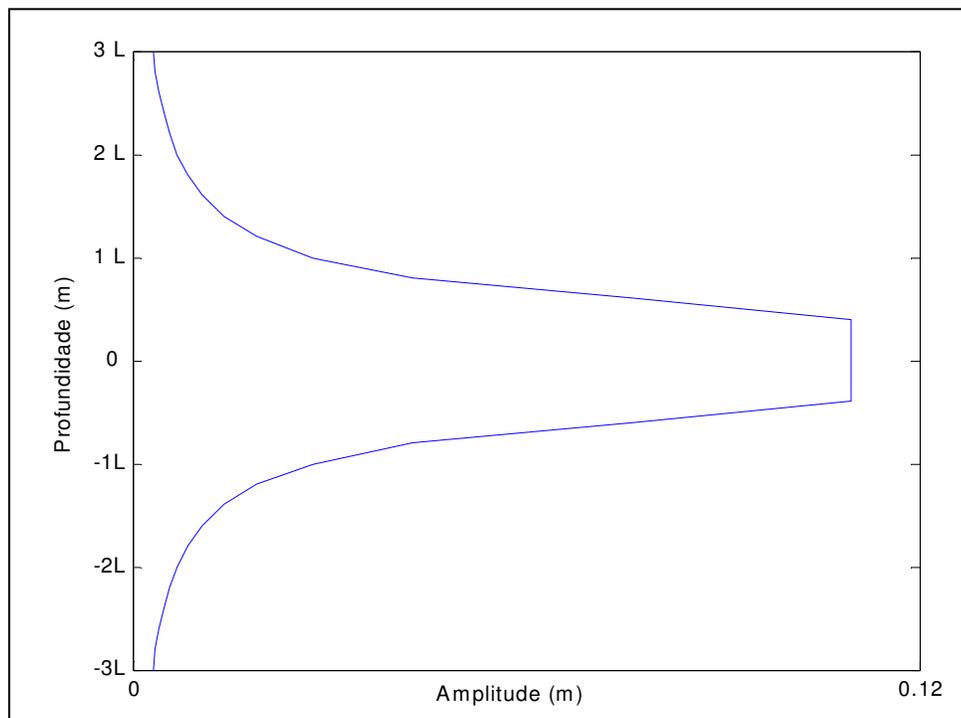


Figura 2.7: Integração vertical do fator geométrico diferencial $g(r)$ para $L = 1\text{ m}$.

Verifica-se que a integração do fator geométrico radial, $g(r)$, tem seu peso máximo a uma distância aproximadamente igual a $L/2$, a partir do eixo da sonda. A partir da distância $r > 3L$ as contribuições dos anéis ali posicionados são negligíveis (Figura 2.6).

Por outro lado, a integração do fator geométrico vertical, $g(z)$, mostra que a resolução vertical da ferramenta é aproximadamente igual a $2L$, a partir do centro das bobinas transmissora e receptora (Figura 2.7).

A aproximação linear proposta por Doll negligencia os efeitos de propagação da onda eletromagnética no interior da formação (*skin effect*) (Ellis, 1987). Mostra-se através da solução das equações de Maxwell, que a função resposta vertical da ferramenta de indução é diferente a cada ponto do perfil, sendo esta variação dependente dos efeitos de propagação, que se agravam para altos valores de condutividade.

2.5 MODELO CONVOLUCIONAL DOS PERFIS.

O produto da convolução entre duas funções $p(t)$ e $g(t)$ é definido da seguinte forma

$$p * g = \int_0^t p(\xi)g(t - \xi)d\xi = \int_0^t p(\xi - t)g(t)dt = g * p. \quad (2.6)$$

As convoluções são definidas no domínio contínuo, mas devido à necessidade de implementação em dispositivos computacionais, o operador é discretizado.

Define-se a convolução discreta unidimensional, entre duas seqüências $p(t)$ e $g(t)$, no ponto k , como

$$y_k = (p * g)(k) = \sum_{t=0}^N p_t g_{k-t}. \quad (2.7)$$

No processamento de sinais, um sinal ou perfil degradado pela ação dos instrumentos de registro é matematicamente representado através da operação de convolução entre o sinal real (p) e a função resposta vertical da ferramenta (g), expresso na equação abaixo

$$y_i = \sum_{i=1}^N p_i g_{k-i} = \sum_{i=1}^N p_{k-i} g_i \quad (k = 1, 2, 3, \dots, N), \quad (2.8)$$

em que, y_i representa o perfil geofísico mensurado no poço, p_k 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.

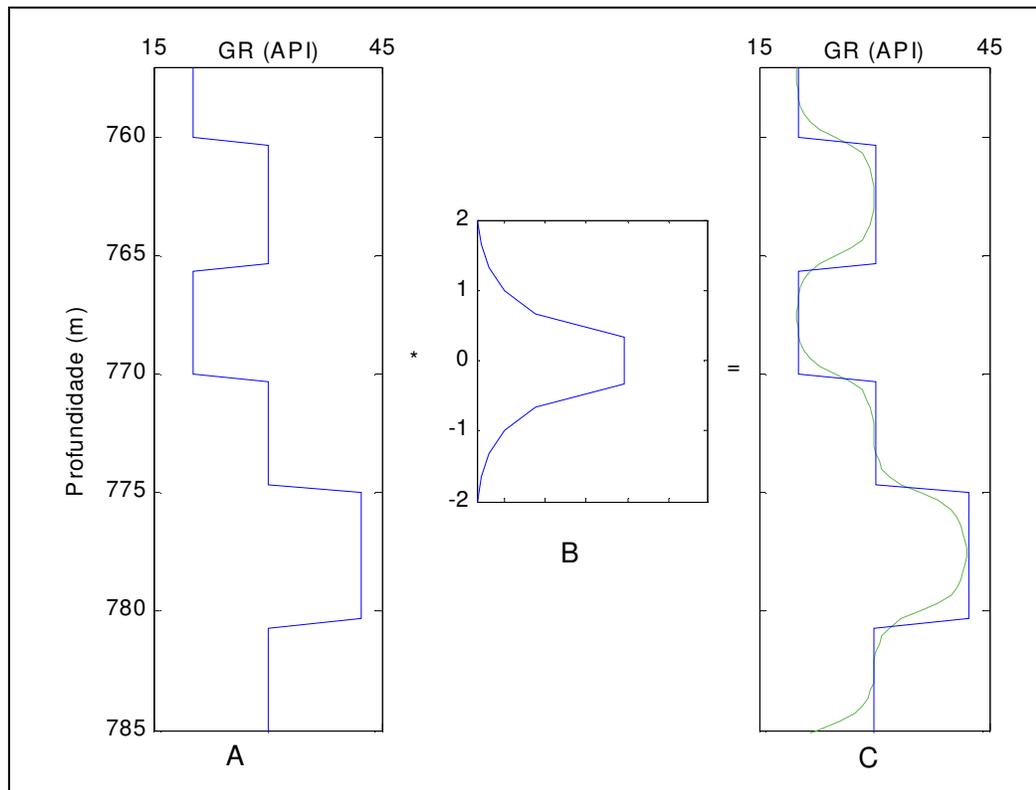


Figura 2.8: Modelo convolucional do perfil. A) Perfil ideal. B) Resposta vertical da ferramenta. C) Perfil sintético obtido através da convolução (linha verde).

A Figura 2.8-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 mostra a posição das interfaces e o valor da propriedade física em cada camada, são vistos nas Figuras 2.8-B e 2.8-A, respectivamente. Observa-se na Figura 2.8-C os efeitos, induzidos pela ferramenta no perfil, que se deseja reduzir através do processamento das redes neurais recorrentes aqui apresentadas, ou seja, a alteração na posição das interfaces e na magnitude das propriedades físicas.

3 REDES NEURAIS ARTIFICIAIS

3.1 INTRODUÇÃO

A teoria de Redes Neurais Artificiais vem se consolidando mundialmente como uma nova e eficiente ferramenta para se lidar com a ampla classe dos, assim chamados, problemas complexos, em que extensas massas de dados devem ser modeladas e analisadas, como por exemplo, um perfil de poço, envolvendo simultaneamente, tanto os aspectos estatísticos e computacionais como os dinâmicos e de otimização.

A idéia das redes neurais é simular o funcionamento do cérebro diretamente em um computador. Dado uma determinada *entrada*, diferentes estados mentais podem ocorrer como consequência de mudanças nas conexões, que podem ser inibidas ou ativadas, variando de acordo com a interação do sistema com o meio ambiente e com seus outros estados internos. Tais redes constituem um intrincado conjunto de conexões entre os neurônios que estão dispostos em camadas hierarquicamente organizadas.

3.2 RESUMO HISTÓRICO

Redes Neurais artificiais, um termo raro há cerca de uma década na literatura científica, representa hoje uma vigorosa área de pesquisa multidisciplinar. É frequentemente identificada como uma subespecialidade de Inteligência Artificial, outras vezes como uma classe de modelos matemáticos para problemas de classificação e reconhecimento de padrões, outras ainda como uma parte da teoria conexionista dos processos mentais e finalmente, como uma categoria de modelos em ciência da cognição. Essa idéia de criar uma máquina inteligente com neurônios artificiais já tem circulado há algum tempo. Hoje, redes neurais artificiais constituem genuinamente uma teoria para o estudo de fenômenos complexos.

O estudo em redes neurais foi inicialmente desenvolvido pelo neurofisiologista McCulloch e pelo matemático Walter Pitts da Universidade de Illinois, os quais, dentro do espírito cibernético, fizeram uma analogia entre células nervosas vivas e o processo eletrônico num trabalho publicado sobre os neurônios formais (McCulloch & Pitts, 1943).

O processo de aprendizado no cérebro foi explicado na mesma época pelo psicólogo Donald Hebb, sua lei diz que se um neurônio A é repetidamente estimulado por um outro neurônio B, ao mesmo tempo em que ele está ativo, ele ficará mais sensível aos estímulos de B, e

a conexão sináptica de B para A será mais eficiente. Deste modo, B achará mais fácil estimular A para produzir uma saída.

Um importante impulso foi dado na 1ª Conferência Internacional de Inteligência Artificial, em 1956, quando foi apresentado um modelo de rede neural artificial pelo pesquisador Nathaniel Rochester.

Marvin Minsky e Seymour Papert, dois cientistas de renome na época, publicaram, em 1969, um livro chamado “PERCEPTRON”, no qual, resumiram e criticaram seriamente a pesquisa sobre as redes neurais, alegando que, além de utilizar processos de aproximações empíricos, não realizava também algumas operações booleanas. O impacto desta publicação foi fatal, retraíram, com a crítica, praticamente todo o investimento e programas de pesquisa para essa tecnologia, que até então ainda era emergente.

Apenas em 1982 foi que John Hopfield, físico e biólogo do Instituto de Tecnologia da Califórnia, deu um novo impulso às redes neurais, contestando, com sucesso, as teses matemáticas de Minsky e Papert, restaurando, assim, o interesse e fomentando novos programas de pesquisa.

John Hopfield, usando uma pesquisa baseada no sistema neurológico de uma lesma de jardim, apresentou um sistema computacional neural composto de muitos elementos de processamento interconectados, que buscam atingir um estado de energia mínima (em repouso). O modelo do físico representa a operação do neurônio a partir de um determinado nível de excitação (limiar), mostrando que a memória do sistema é armazenada nas interconexões entre as unidades neurais.

A rede neural desenvolvida neste trabalho é baseada nas definições de Hopfield.

3.3 O NEURÔNIO BIOLÓGICO

O cérebro humano possui, pelo que se conhece, cerca de 10 bilhões de neurônios. São as células mais diferenciadas do organismo, pois apresentam a maior complexidade estrutural e funcional. Como qualquer célula biológica, o neurônio (Figura 3.1) é delimitado por uma fina membrana celular que além da sua função biológica normal, possui determinadas propriedades que, conforme será visto, são essenciais para o funcionamento elétrico da célula nervosa.

A partir do corpo celular, ou **soma** – o centro dos processos metabólicos da célula nervosa – projetam-se extensões filamentosas, os **dendritos**, e o **axônio**. O neurônio possui geralmente um único axônio, embora esse possa apresentar algumas ramificações. Em alguns casos estende-se por distâncias comparáveis às dimensões do organismo podendo chegar a vários metros.

O neurônio, basicamente, capta o estímulo nos dendritos e o transmite pelo axônio para que atinja um outro neurônio ou outros tipos de células.

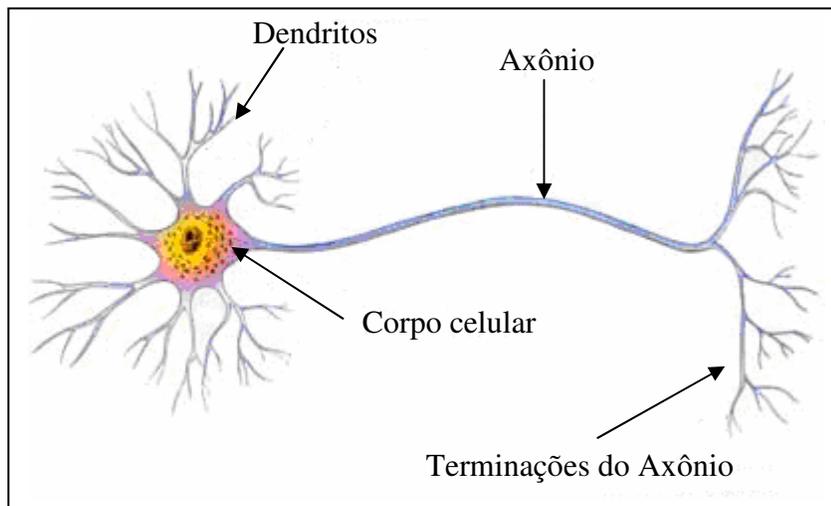


Figura 3.1: Modelo do neurônio biológico.

Pode-se entender o neurônio biológico como um dispositivo computacional elementar do sistema nervoso, que possui entradas – muitas entradas – e uma saída. As entradas ocorrem através das **conexões sinápticas**, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos como **impulsos nervosos** ou **potenciais de ação**, e constituem a informação que o neurônio processará, de alguma forma, para produzir como saída um impulso nervoso no seu axônio.

Uma vez captado o estímulo nas terminações nervosas, ele é transformado em impulso elétrico da ordem de 70 mv. Esse impulso elétrico é chamado de potencial de ação. Este potencial de ação percorre o axônio e atinge um outro neurônio. O contato que ocorre entre dois neurônios é denominado de **sinapse**, mostrado na figura 3.2.

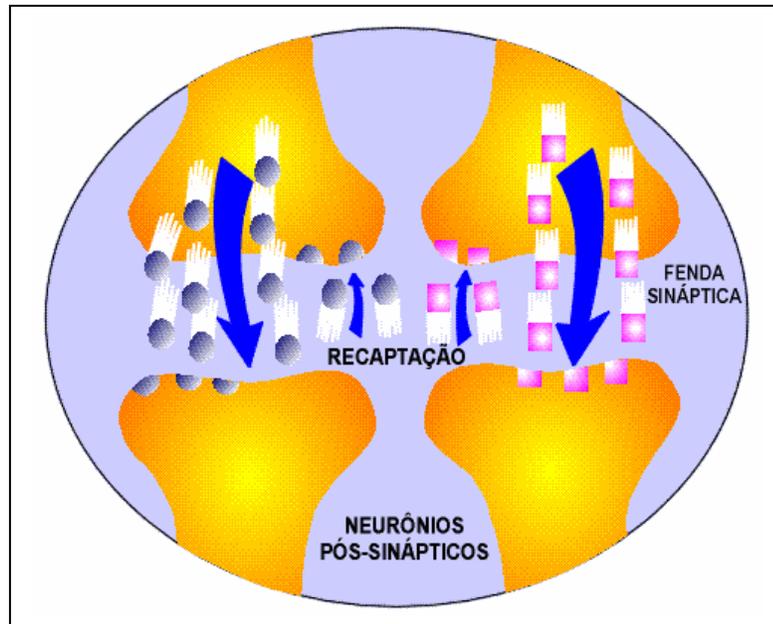


Figura 3.2: Sinapses

Um fenômeno importante que ocorre no neurônio é a formação de um potencial de ativação na membrana axonal, que é definido como uma onda de depolarização de curta duração, que se propaga ao longo da membrana. Quando uma membrana sofre depolarização suficientemente alta para superar um determinado valor conhecido como limiar de disparo o impulso nervoso é transmitido de um neurônio para outro.

3.4 NEURÔNIO ARTIFICIAL

Os neurônios biológicos são dispositivos extremamente lentos, quando comparados com os computadores digitais. Estes neurônios operam na faixa dos milissegundos, ao passo que os computadores processam os dados num tempo do nanosegundo.

As conexões entre os neurônios procuram simular as conexões sinápticas biológicas fazendo uso de uma variável chamada **peso**. A função de **soma** acumula os dados recebidos (estímulos) de outros elementos, e a **função de ativação** processa a função soma transformando-a em um sinal de saída.

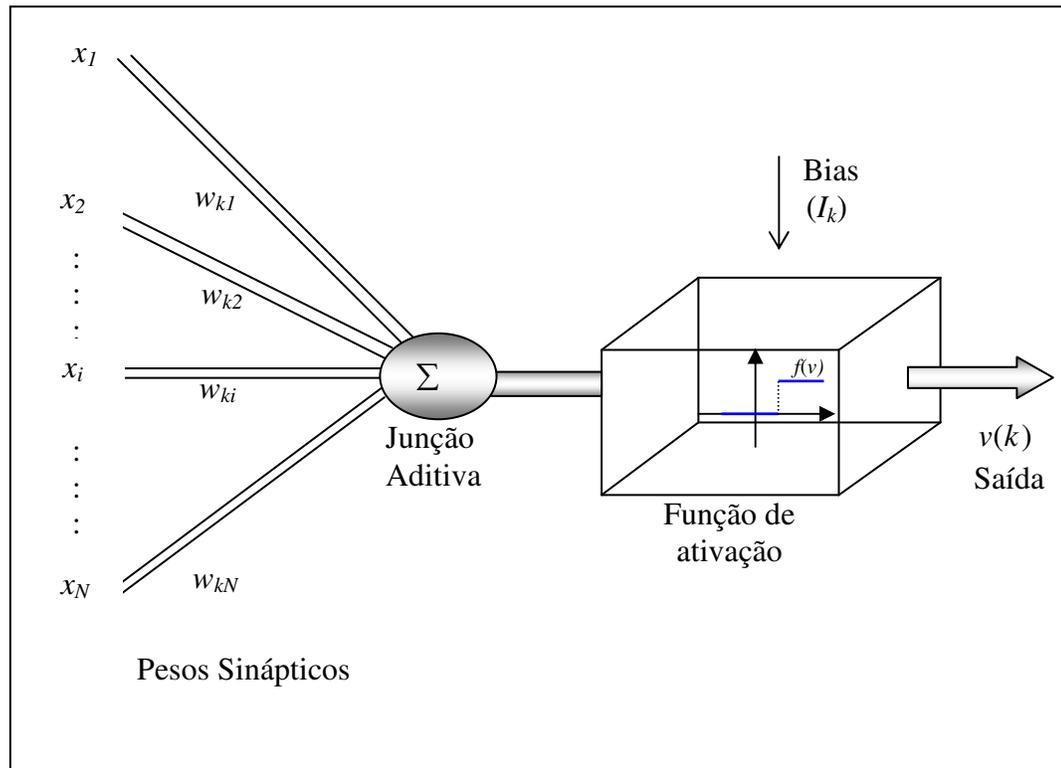


Figura 3.3: Modelo do neurônio artificial de McCulloch-Pitts.

Biologicamente falando, um neurônio passa adiante um estímulo conforme a força dos estímulos recebidos provenientes dos neurônios que, com ele, estão conectados. A soma dos impulsos recebidos é que determina a continuação do estímulo. No mundo artificial, o mesmo efeito é simulado, dentro das possibilidades tecnológicas atuais.

3.4.1 Neurônio Binário

O modelo neural da Figura 3.3, além de incluir um conjunto de sinapses, um somador e uma função de ativação, inclui também uma entrada aplicada externamente, representado por I_k . O bias I_k tem o efeito de aumentar ou diminuir o valor da entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

Podemos, portanto descrever um neurônio k escrevendo o seguinte par de equações:

$$P_k = \sum_{j=1}^N w_{kj} x_j , \quad (3.1)$$

e

$$v_k = f(P_k + I_k), \quad (3.2)$$

em que x_1, x_2, \dots, x_N são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{kM}$ são os pesos sinápticos do neurônio k ; P_k é a saída do combinador linear devido aos sinais de entrada; I_k é o bias; f é a função de ativação; e v_k é o sinal de saída do neurônio. O uso do bias I_k tem o efeito de aplicar uma transformação afim à saída P_k do combinador linear no modelo da Figura 3.3.

Na expressão (3.1) N é a quantidade de neurônios que compõe a rede, 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 para $w_{ij} < 0$, respectivamente. O peso aplicado a conexão existente entre os neurônios N_i e N_j é denotada por w_{ij} .

3.4.2 Função de Ativação

A função de ativação tem como objetivo limitar a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um vetor finito. Geralmente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$.

Os modelos de neurônio binário normalmente adotam a função degrau simples como função de ativação, na forma

$$v_k(t) = f[P_k(t-1)] = \begin{cases} 1, & \text{se } P_k(t-1) \geq 0 \\ 0, & \text{se } P_k(t-1) < 0 \end{cases} \quad (3.3)$$

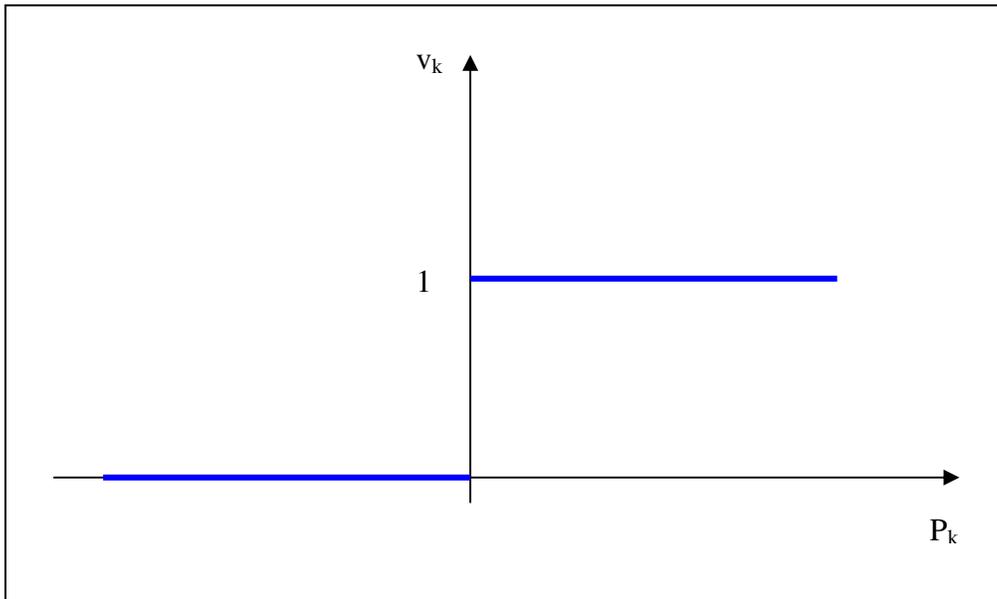


Figura 3.4: Função de ativação degrau simples, para um modelo de rede neural de Hopfield.

3.4.3 Pesos Sinápticos

Podemos comparar os pesos no neurônio artificial com as sinapses do neurônio biológico, por isso os pesos são chamados de *pesos sinápticos*. Os pesos, representados por w_{ij} , são valores que apresentam o grau de importância que determinada entrada possui em relação àquele determinado neurônio. Ou seja, esse valor, o peso, muda em função da intensidade do sinal de entrada, e dessa forma, o peso muda o seu valor representativo para a rede. Significa que, quando uma entrada é bastante estimulada, acaba estimulando, também, o peso correspondente à sua conexão. Um peso quando é bastante estimulado, automaticamente terá mais influência no resultado do sinal de saída.

Os pesos podem ser vistos, matematicamente, como um vetor de valores $(\omega_1, \omega_2, \dots, \omega_n)$. Havendo mais de um neurônio na rede, podemos então ter uma coleção de vetores, ou seja, uma matriz de pesos, onde cada linha ou coluna corresponde a um neurônio. Quando as entradas (x_1, x_2, \dots, x_n) são apresentadas para o neurônio, elas são multiplicadas pelos pesos, e a soma desses resultados é, então, o sinal de excitação no neurônio. Desta forma, podemos escrever:

$$S = \sum_{i=0}^n x_i w_i \quad (3.4)$$

3.5 REDE NEURAL DE HOPFIELD

Este tipo de rede apresenta pelo menos uma recorrência entre os neurônios e está associada aos sistemas dinâmicos. Uma rede recorrente possui uma única camada de neurônios, onde o sinal de saída de cada neurônio alimenta os outros neurônios. 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*), ou seja, um mesmo neurônio não pode receber sua própria saída como entrada.

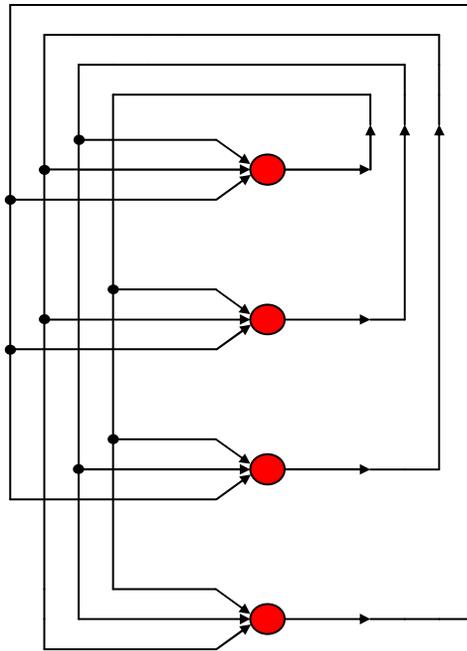


Figura 3.5: Arquitetura da rede neural de Hopfield.

As redes de Hopfield (Hopfield; 1982, Hopfield & Tank, 1985) possuem suas raízes na Física Estatística, mais do que em observações biológicas. As redes de Hopfield são totalmente recorrentes e podem ser descritas como um sistema dinâmico cujo espaço de estados contém um conjunto de pontos fixos (estáveis) que representam as memórias fundamentais do sistema. Conseqüentemente, estas redes possuem uma propriedade emergente que ajuda a recuperar informações e lidar com ruídos.

A rede de Hopfield originalmente proposta utiliza uma matriz simétrica de pesos, de modo que as realimentações existentes geram um comportamento dinâmico não-linear

caracterizado apenas pela presença de pontos fixos. Após a entrada de um sinal inicial arbitrário o estado atingido pela rede será conduzido a um estado estável caracterizado por pontos fixos geralmente associados a memórias fundamentais. A validade deste argumento pode ser mostrada através de uma função energia e da garantia de que a dinâmica é sempre dissipativa. Iterações sucessivas do algoritmo mudam o estado da rede de forma a colocá-la próxima a um mínimo local da função energia associada à dinâmica da rede (figura 3.6).

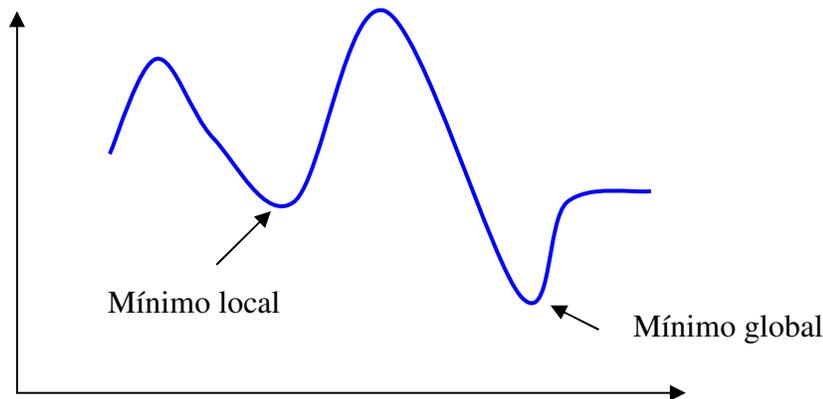


Figura 3.6: Diferença entre mínimo local e mínimo global.

A versão discretizada no tempo da rede neural de Hopfield requer as seguintes observações:

- 1- A saída de cada neurônio retorna para todos os outros.
- 2- Não existe auto alimentação, 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 3.5.

3.5.1 Função Energia

Considere uma rede discreta de Hopfield, assim a matriz de pesos sinápticos é quadrada, simétrica e possui diagonal nula, ou seja, a matriz W é tal que seus elementos satisfazem

$w_{ij} = w_{ji}$ e $w_{ii} = 0$, e seja v_i o estado do neurônio i , onde $i = 1, \dots, N$. A função energia é definida por

$$E = -\frac{1}{2} \sum_{l=1}^N \sum_{i \neq j=1}^N w_{ij} v_i v_j - \sum_{i=1}^N I_i v_i. \quad (3.5)$$

Os mínimos locais da superfície de energia correspondem a atratores do espaço de estados, que são as memórias da rede. Para garantir a emergência da memória associativa, duas condições devem ser satisfeitas:

1. As memórias fundamentais armazenadas pela rede correspondem a estados estáveis; e
2. Os estados estáveis constituem uma base de atração do sinal de entrada (região de influência).

4 DECONVOLUÇÃO DE PERFIS DE POÇO

4.1 INTRODUÇÃO

A rede neural recorrente pertence a uma classe especial de redes neurais artificiais que são aquelas com treinamento não supervisionado. Ela é composta por uma única camada recorrente, a qual após a recepção de um sinal de entrada externa promove o envio do sinal de saída como um novo sinal de entrada da rede. Este processo dinâmico do fluxo de sinais de saídas se transformarem em novos sinais de entrada é conhecido como recorrência neural e é controlado por uma função que depende apenas dos chamados parâmetros livres (matriz de pesos sinápticos e entrada externa). Esta função recebe o nome de função energia e através da modificação dos sinais de saída pelo processo dinâmico de recorrência neural é alcançado um de seus mínimos locais que é denominado como estado estável da rede. O interesse no uso de uma rede neural recorrente reside nesta sua característica, que pode ser interpretado como processo de minimização contínua associado à solução de um problema de otimização. Através da associação entre uma função de custo do problema de otimização com a função energia da rede recorrente está estabelecida a relação entre o estado estável da rede e uma solução local do problema de otimização.

4.2 REDE NEURAL RECORRENTE

A estimativa das propriedades físicas das rochas a partir de dados de perfis é posto como um problema de otimização, onde se busca a minimização de uma função de custo ou função objeto, que mede o erro entre o valor real da propriedade física e o valor mensurado pela ferramenta de perfilagem. Geralmente esta minimização é obtida através do cálculo das derivadas parciais da função objeto, mas devido à grande quantidade de parâmetros envolvidos neste processamento, esta atividade torna-se computacionalmente onerosa. Com o objetivo de promover a solução deste problema, evitando-se o cálculo das derivadas, apresenta-se neste capítulo os procedimentos adotados para a solução deste problema de otimização através das redes neurais recorrentes.

O processo de decréscimo contínuo da função energia, induzido pela dinâmica da rede, mostrada na figura 4.1, leva 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 em cada uma delas.

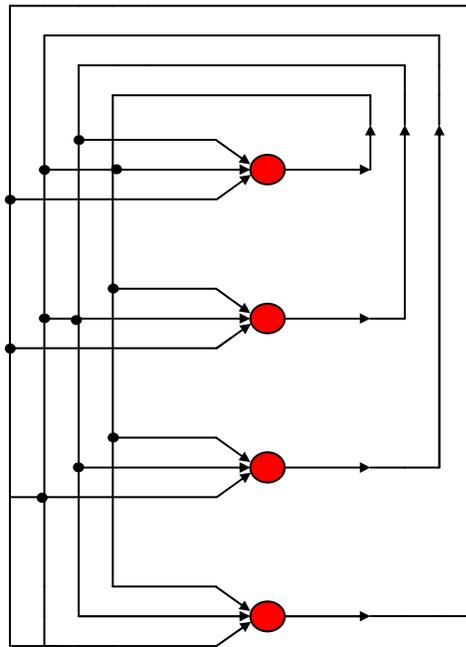


Figura 4.1: Estrutura de uma rede neural recorrente com auto-alimentação.

4.2.1 Parâmetros da Rede.

Uma rede neural recorrente é caracterizada por três parâmetros fixos, ou seja, independentes do problema de otimização e que controla o processo dinâmico da recorrência neural.

4.2.1.1 Potencial de Entrada

Define-se o potencial de entrada P_k da rede como o sinal de entrada líquido em cada um dos neurônios recorrentes. Exemplificando para um neurônio k o seu potencial de entrada é escrito na forma:

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

onde v_i representa o estado ou a saída do neurônio i no tempo $(t-1)$ e w_{ki} representa o elemento da matriz de pesos sinápticos associado a ligação entre o neurônio i e o neurônio k . A matriz W possui 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 (diferente de zero).

4.2.1.2 Função de ativação

A função de ativação de cada neurônio recorrente é definida pela expressão seguinte

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

Esta formulação para a função de ativação ($f(P_k(t-1))$) difere daquela adotada na rede neural de Hopfield (Hopfield, 1982), devido à presença do parâmetro livre I_k , designado como entrada externa, determinante do novo estado do neurônio $v_k(t)$, como mostrado na Figura 4.2.

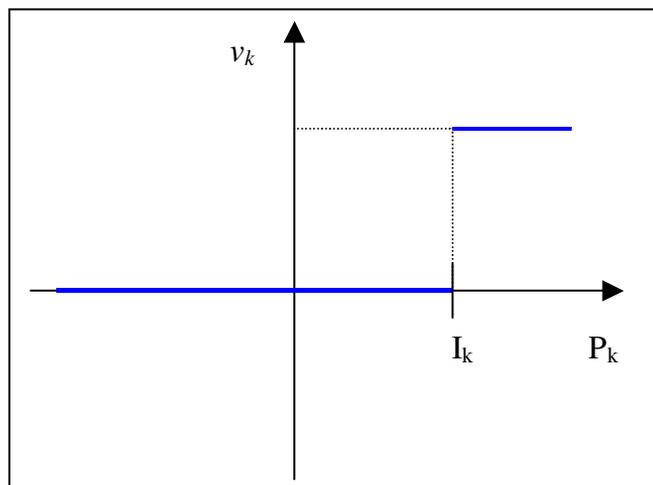


Figura 4.2: Função de ativação da rede recorrente.

4.2.1.3 Função Energia

Considerando que a atualização dos estados dos neurônios ocorre de acordo com a regra estabelecida pela expressão (4.2), a função energia (E) é definida como

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

Mostra-se a seguir que a variação da função energia associada com a dinâmica da rede neural recorrente, devido à mudança no estado de um único neurônio em cada instante de tempo, sempre é menor ou igual a zero e assegura sua convergência a um mínimo local, mostra-se também que essa minimização ocorre se considerarmos a matriz de pesos sinápticos positiva ou nula ($w_{kk} \geq 0$).

A variação de função energia (ΔE) associada com a dinâmica da rede neural recorrente, devido à mudança no estado de um único neurônio recorrente em cada instante de tempo, pode ser escrita como

$$\Delta E(t) = E_k(t) - E_k(t-1). \quad (4.4)$$

Substituindo a expressão (4.3) na expressão (4.4), tem-se

$$\Delta E(t) = -\sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i(t) v_j(t) + 2 \sum_{i=1}^N I_i v_i(t) - \left[-\sum_{i=1}^N \sum_{j=1}^N w_{ij} v_i(t-1) v_j(t-1) + 2 \sum_{i=1}^N I_i v_i(t-1) \right], \quad (4.5)$$

Considerando que a atualização da rede neural recorrente ocorre devido a mudança de estado do neurônio particular k , verifica-se as seguintes igualdades

$$\begin{aligned} \Delta E_k(t) &= -2v_k(t) \sum_{j=1}^N w_{kj} v_j(t) - w_{kk} \left\{ [v_k(t)]^2 - v_k(t-1)v_k(t) \right\} + 2I_k v_k(t) + 2v_k(t-1) \sum_{j=1}^N w_{kj} v_j(t) - \\ &\quad w_{kk} \left\{ [v_k(t)]^2 - v_k(t-1)v_k(t) \right\} + 2I_k v_k(t) \\ \Delta E_k(t) &= -2v_k(t) \sum_{j=1}^N w_{kj} v_j(t) + 2v_k(t-1) \sum_{j=1}^N w_{kj} v_j(t-1) + I_k [v_k(t) - v_k(t-1)] - w_{kk} \left\{ [v_k(t)]^2 - 2v_k(t-1)v_k(t) + [v_k(t-1)]^2 \right\} \\ \Delta E_k(t) &= 2[v_k(t) - v_k(t-1)] \left[\sum_{j=1}^N w_{ij} v_j(t) - I_k \right] - w_{kk} \left\{ [v_k(t)]^2 - 2v_k(t-1)v_k(t) + [v_k(t-1)]^2 \right\} \end{aligned}$$

$$\Delta E_k(t) = \underbrace{-2\Delta v_k \left[\sum_{j=1}^N w_{ij} v_j(t) - I_k \right]}_A - \underbrace{w_{kk} (\Delta v_k)^2}_B, \quad (4.6)$$

A característica principal da matriz de peso sináptico é sua diagonal principal ter todos os elementos maiores ou iguais zero ($w_{kk} \geq 0$). A condição de simetria ($w_{ki} = w_{ik}$) das redes neurais recorrentes clássicas é mantida. A expressão (4.5) foi desenvolvida considerando a atualização de um único neurônio recorrente, o neurônio k . Assim $v_k(t) \neq v_k(t-1)$, os outros neurônios permanecem com seus estados inalterados ou $v_k(t) = v_k(t-1)$.

Na expressão (4.6), a variação do estado do neurônio é escrita como $\Delta v = v(t) - v(t-1)$. Todos os outros termos foram previamente definidos.

Agora, avalia-se o sinal da expressão (4.6) considerando que as atualizações dos neurônios recorrentes são governadas pelas regras da função de ativação da expressão (4.2).

Na expressão (4.2) foi introduzido um parâmetro livre chamado de entrada externa (I_k).

Considerando a expressão (4.1), a expressão (4.6) pode ser reescrita como:

$$\Delta E_k(t) = \underbrace{-2\Delta v_k(t) [P_k(t) - I_k]}_A - \underbrace{w_{kk} (\Delta v_k)^2}_B, \quad (4.7)$$

Considere a Figura 4.2 para seguir o processo de atualização dos neurônios recorrentes e o comportamento da função de energia. Para assegurar o comportamento decrescente da variação de função energia na expressão (4.7), o termo w_{kk} é maior ou igual a zero, garantindo que o termo B é sempre positivo. Este fato nos permite analisar só o termo A para avaliar o sinal da expressão (4.7), a qual depende das variações do estado dos neurônios.

Caso 1 – Para $v_k(t-1) = 1$ e $v_k(t) = 0$. Analisando apenas o sinal de ΔE na expressão (4.7) tem-se $\Delta v_k < 0$, assim o sinal externo aos colchetes são positivos. Considerando que isso acontece na vizinhança de zero (Figura 4.2). Tem-se que analisar duas possibilidades: Na primeira $P_i \leq 0$, assim, o sinal interno aos colchetes é negativo e a análise total do sinal resulta em $\Delta E < 0$. O segundo caso considera $0 < P_i \leq I_i$ e novamente, o sinal da expressão dentro dos colchetes é negativo e a análise total do sinal resulta $\Delta E < 0$.

Caso 2 - Para $v_i(t-1) = 0$ e $v_i(t) = 1$. Analisando da mesma maneira como no caso 1 só o sinal de ΔE na expressão (4.7), tem-se agora $\Delta v_i > 0$, assim o sinal externo aos colchetes é negativo. Considere que P_i acontece na vizinhança de I_i (Figura 4.2). Tem-se agora, só uma possibilidade para analisar, isto é, $P_i > I_i$, assim o sinal da expressão dentro dos parênteses é positivo e a análise total do sinal resulta $\Delta E < 0$. Observe que a análise do comportamento de ΔE só garante uma minimização local da função energia. O uso de processamentos para procurar o mínimo global pode ser encontrado, por exemplo, em “simulated annealing” (Hopfield & Tank, 1985) ou “mean field annealing” (Macías et al, 1997). Para aplicações em perfil de poço o problema de obtenção de mínimo global é de difícil solução devido ao nível de ruído encontrado nos perfis. Mostra-se que uma rede neural recorrente, como a apresentada aqui, pode tratar o problema de deconvolução convenientemente sem qualquer perda nos resultados.

A função energia define uma particular rede neural recorrente pela caracterização de dois parâmetros livres (independentes dos estados dos neurônios recorrente): a matriz de pesos sinápticos (W) e a entrada externa (I_k). O estabelecimento desses parâmetros produz a associação entre os estados estáveis dos neurônios recorrentes e uma solução de um problema real particular.

Um exemplo desta arquitetura de rede neural recorrente é visto na figura 4.1, que difere da Figura 3.4 devido a possibilidade de auto-alimentação, garantida quando tomamos $w_{kk} \geq 0$.

Uma rede neural recorrente é caracterizada por uma função energia. A determinação desta função energia depende exclusivamente da determinação da matriz de pesos sinápticos e do vetor de entradas externas. Este conjunto recebe o nome de parâmetros livres da rede e são responsáveis pela existência da recorrência neural.

Para a associação das redes neurais recorrentes com a solução do problema de deconvolução de perfis os parâmetros fixos da rede, como potencial de entrada e função de ativação em cada neurônio recorrente, devem ser definidos para que se possa conceituar a função energia,

4.3 O BLOCO DE PROCESSAMENTO

A premissa fundamental admitida aqui é a associação entre a função energia da rede neural recorrente e uma função erro, característica do problema a ser tratado. Assim, o decréscimo da função energia induzido pelo processo dinâmico responsável pela atualização dos estados dos neurônios, leva a uma minimização local da função erro, isto é, o estado estável dos neurônios será a solução do problema. Esta associação pode ser obtida através da relação dos parâmetros livres (matriz de pesos sinápticos e vetor de entrada externa) em termos das características do problema.

De acordo com as definições estabelecidas na seção 2.5, o perfil de poço pode ser descrito pelo modelo convolucional, de acordo com a equação (2.6).

O objetivo aqui é resolver a operação de convolução (expressão 2.6) no sentido de sua operação inversa ou a deconvolução, assim pretende-se encontrar os valores reais de p_k , mas os valores de g_k também não são conhecidos a priori. Para superar esta indeterminação, introduz-se um bloco de processamento iterativo baseado em três arquiteturas de redes neurais recorrentes. A primeira visa uma estimativa para a resposta vertical da ferramenta. Com a segunda rede neural, estabelece-se a disposição geométrica de cada camada rochosa em subsuperfície (interfaces). Na última, é estabelecida a minimização do efeito da ferramenta na magnitude da propriedade física da rocha.

Para iniciar este processamento, precisa-se prover uma primeira estimativa sobre o perfil ideal que será usado para a obtenção da resposta vertical da ferramenta. Esta estimativa será feita através de duas aproximações:

- (1) o perfil quadratizado, e,
- (2) um perfil de mais alta resolução vertical do que aquele que está sendo processado.

4.3.1 Perfil Quadratzado

O algoritmo que constrói o perfil quadratzado é baseado no critério de médias móveis. Para decidir se um ponto em profundidade pertence a uma determinada camada, a diferença entre a média aritmética de leituras do perfil, incluindo e excluindo este ponto, são comparadas a um parâmetro. Se a diferença é menor que este parâmetro, o ponto pertence a esta camada, se o oposto acontece, uma interface é alcançada. O perfil quadratzado é construído incluindo e analisando ponto a ponto na direção da profundidade. A figura 4.3 mostra o resultado da implementação deste algoritmo. Na figura 4.3-A tem-se o perfil real de raio gama que foi utilizado para a obtenção do perfil quadratzado da Figura 4.3-B, para melhor comparação ambos foram sobrepostos na Figura 4.3 C. Esta associação entre o perfil real e o perfil quadratzado é feita a partir da suposição de material homogêneo (mesma litologia) em cada camada rochosa admitida no modelo convolucional do perfil de poço. O perfil quadratzado obtido pelo perfil sintético livre de ruído aproxima-se bastante do perfil ideal. Quando o perfil de poço real é utilizado, apenas uma fraca relação existe entre o perfil quadratzado e a variação da propriedade física da rocha.

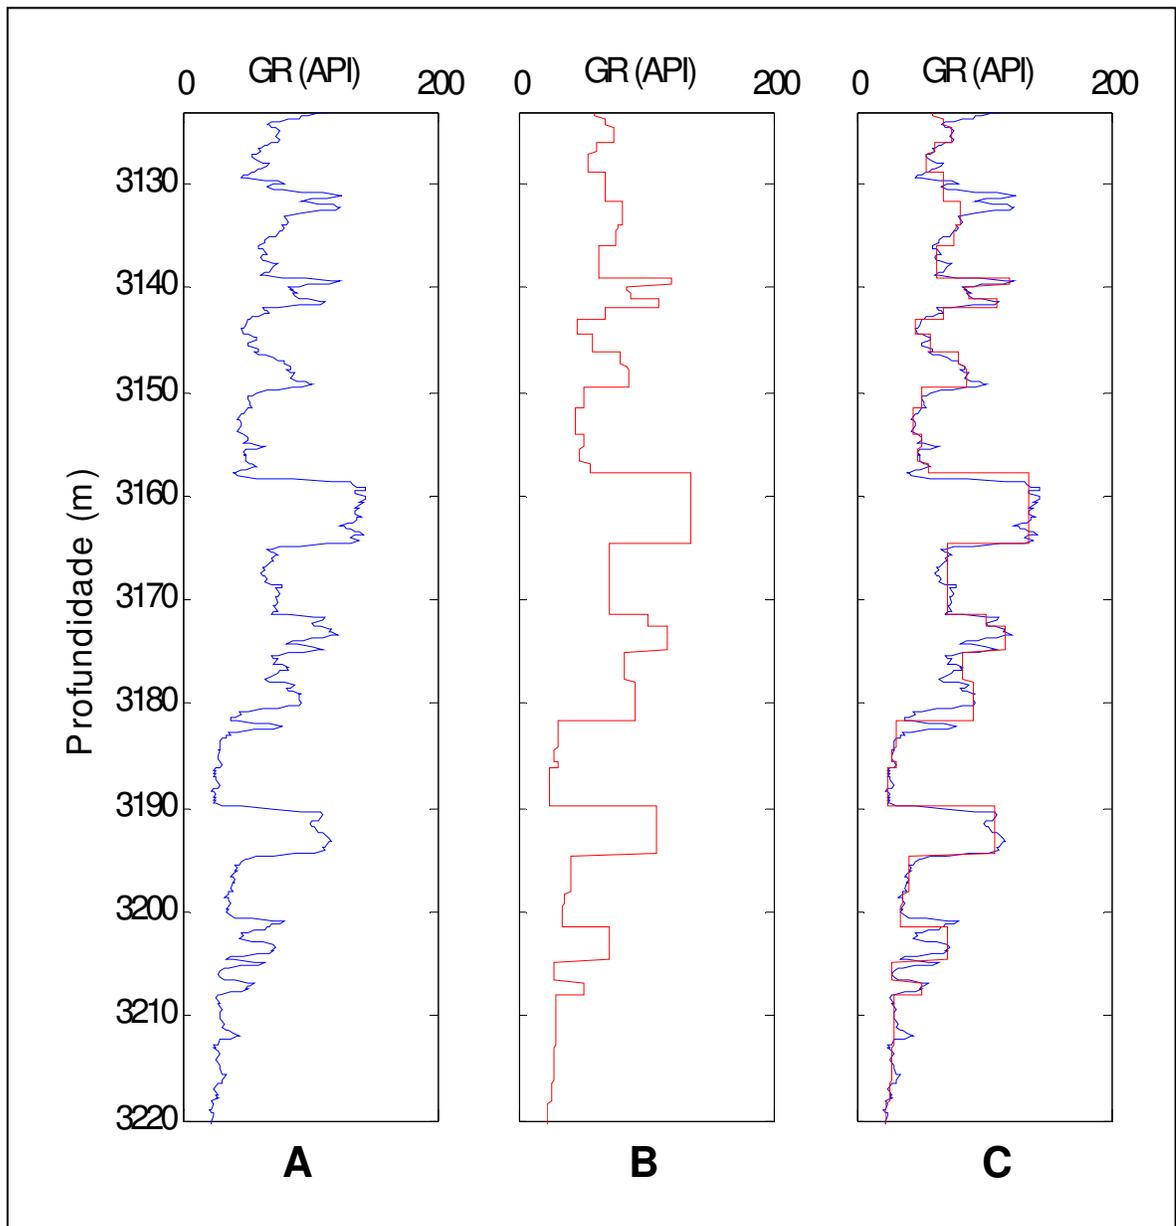


Figura 4.3: A) Perfil de raio gama natural. B) Perfil quadratizado. C) Perfil real (azul) e perfil quadratizado (vermelho).

4.3.2 Perfil de Alta Resolução

O segundo método para iniciar o processamento é substituir o perfil quadratizado por um perfil de mais alta resolução do que aquele que será processado, contanto que ambos sejam medidos no mesmo intervalo de profundidade para tirar proveito da melhor definição das interfaces que o perfil de alta resolução pode oferecer.

Ambos os métodos de iniciar o bloco de processamento tem o mesmo papel que é ajudar na localização das interfaces. Em uma seção de geologia complexa, o perfil quadratizado produz uma dura restrição, neste caso, a melhor forma de iniciar o processamento é através de um perfil de mais alta resolução que melhor representará as interfaces das camadas investigadas.

4.3.3 Estimativa da Resposta Vertical da Ferramenta

Para prover uma estimativa externa da resposta vertical da ferramenta, é utilizado o conceito de “point spread function” (Andrade & Luthi, 1993). A aproximação externa da resposta vertical da ferramenta é obtida como o resultado da divisão polinomial, no domínio de Fourier, entre a primeira estimativa para o perfil ideal e o perfil de poço em um intervalo de profundidade conveniente ou em uma camada espessa de modo a reduzir os efeitos de borda da ferramenta.

Considera-se os seguintes pares de transformadas de Fourier onde g representa a resposta vertical da ferramenta, p é o perfil no interior do intervalo de controle e p' é o perfil de alta resolução,

$$\begin{aligned} g_k^{est} &\Leftrightarrow G_k^{est} \\ p_k &\Leftrightarrow P_k \\ p'_k &\Leftrightarrow P'_k. \end{aligned}$$

Obtem-se a resposta vertical da ferramenta calculando-se a transformada inversa de Fourier da expressão,

$$G_k^{est} = \frac{P_k}{P'_k}.$$

Nas próximas seções, mostra-se como são obtidos os parâmetros livres de cada rede neural para operar no bloco de processamento, até uma meta de erro ter sido alcançada, produzindo a localização em profundidade das interfaces e a propriedade física real para cada camada rochosa em um poço.

4.3.4 Recuperação da Resposta Vertical 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

$$E = \frac{1}{2} \sum_{k=1}^N (y_k - y'_k)^2, \quad (4.8)$$

em que y'_k é o perfil obtido pelo modelo convolucional mostrado na expressão 2.6.

Assumindo $g_0 \neq 0$ e $p_i \neq 0$ para $i > 0$, a expressão (4.8) pode ser escrita da seguinte maneira

$$E = \frac{1}{2} \sum_{k=1}^N \left(y_k - \sum_{i=1}^N p_{k-i} g_i \right)^2. \quad (4.9)$$

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

$$g_{rec} = (1 + g'_i) g_i^{est}. \quad (4.10)$$

O termo g'_i assume valores no intervalo fechado $[0,1]$ e atua como peso na correção da estimativa externa da resposta vertical da ferramenta (g_i^{est}) e é expressa por

$$g'_i = \left(\frac{1}{2} \sum_{j=1}^M \frac{1}{2^{j-1}} x_{ij} \right), \quad (4.11)$$

em que x_{ij} será a saída da rede neural recorrente em $\{0,1\}$. A expressão (4.11) pode ser entendida como a decodificação de um vetor binário de M bits.

Substituindo a expressão (4.11) na expressão (4.10) e o resultado na expressão (4.9), ignorando 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:

$$E = - \sum_{k=1}^N \left[\sum_{i=1}^N p_{k-i} \sum_{j=1}^N \frac{1}{2^{j-1}} \left(y_k - \sum_{i=1}^N g_i^{est} p_{k-i} \right) g_i^{est} \right] x_{ij} + \frac{1}{8} \sum_{k=1}^N \sum_{i_1=1}^N \sum_{i_2=1}^N \sum_{j_1=1}^M \sum_{j_2=1}^M g_{i_1}^{est} g_{i_2}^{est} \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} x_{i_1 j_1} x_{i_2 j_2}. \quad (4.12)$$

Associando a equação (4.12) com a equação (4.3) tem-se a matriz de pesos sinápticos da rede, dada por:

$$w_{i_1 i_2 j_1 j_2} = \frac{1}{8} \sum_{k=1}^N p_{k-i_1} p_{k-i_2} \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} g_{i_1}^{est} g_{i_2}^{est}, \quad (4.13)$$

e o vetor de entrada externa, dado por:

$$I_j = - \frac{1}{4} \sum_{k=1}^N \sum_{i=1}^N p_{k-i} \frac{1}{2^{j-1}} \left(y_k - \sum_{i=1}^N g_i^{est} p_{k-i} \right) g_i^{est}. \quad (4.14)$$

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.

4.3.5 Identificação das Interfaces

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

$$p_i = c_i + r_i \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right), \quad (4.15)$$

em que 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 à c_i .

Fazendo a substituição da expressão (2.6) na expressão (4.8), adotando o valor de p_i dado pela equação (4.15) e desprezando os termos que não dependem de r_i , obtem-se a seguinte expressão:

$$E = - \sum_{k=1}^N \sum_{i=1}^N \left(y_k - \sum_{j=1}^N c_j g_{k-j} \right) h_i g_{k-i} r_i + \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N h_i h_j g_{k-i} g_{k-j} r_i r_j, \quad (4.16)$$

em que 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 (4.3) e (4.16) obtem-se a matriz de pesos da rede, dada por

$$w_{ij} = \frac{1}{2} \sum_{k=1}^N h_i h_j g_{k-i} g_{k-j} \quad (4.17)$$

e o vetor de entrada externa, que é expresso da seguinte forma

$$I_i = -\frac{1}{2} \sum_{k=1}^N \left(y_k - \sum_{j=1}^N c_j g_{k-j} \right) h_i g_{k-i}, \quad (4.18)$$

4.3.6 Recuperação da Propriedade Física

O objetivo aqui é a recuperação do perfil ideal, que contém a representação das interfaces entre as diferentes camadas rochosas e os valores de suas propriedades físicas. A rede neural, cujos pesos sinápticos foram determinados pela equação (4.17) e a entrada externa pela equação (4.18), fornece as posições das interfaces das camadas. Para que se possa encontrar o valor da propriedade utiliza-se, novamente, a função objeto de minimização do erro da equação (4.8) e faz-se necessário que a distribuição ideal da propriedade física deixe de ser expressa pela equação (4.15) e passe a ser expressa pela equação abaixo:

$$p_{rec} = (1 + p'_i) p_i^{est}, \quad (4.19)$$

em que p_i^{est} é a primeira aproximação do perfil ideal e p'_i é dado pela seguinte expressão

$$p'_i = \frac{1}{2} \left(\sum_{j=1}^M \frac{1}{2^{j-1}} x_{ij} \right), \quad (4.20)$$

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

Desenvolvendo a expressão (4.8), através do modelo convolucional, substituindo p_i por p_{rec} , determinado pela expressão (4.19), ignorando os termos que não dependem de x_{ij} e 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:

$$E = -\frac{1}{2} \left[\sum_{i=1}^N g_{k-i} \sum_{j=1}^N \frac{1}{2^{j-1}} \left(y_k - \sum_{i=1}^N p_i^{est} g_{k-i} \right) p_i^{est} \right] x_{ij} + \frac{1}{8} \sum_{i_1=1}^N \sum_{i_2=1}^N \sum_{j_1=1}^M \sum_{j_2=1}^M \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} p_{i_1}^{est} p_{i_2}^{est} x_{i_1 j_1} x_{i_2 j_2}. \quad (4.21)$$

Associando a equação (4.21) com a equação (4.3) tem-se a seguinte matriz de pesos sinápticos, dada por

$$w_{i_1 i_2 j_1 j_2} = \frac{1}{8} g_{k-i_1} g_{k-i_2} \frac{1}{2^{j_1-1}} \frac{1}{2^{j_2-1}} p_{i_1}^{est} p_{i_2}^{est}, \quad (4.22)$$

e o vetor de entrada externa será dado por

$$I_j = -\frac{1}{4} \sum_{k=1}^N \sum_{i=1}^N g_{k-i} \frac{1}{2^{j-1}} \left(y_k - \sum_{i=1}^N p_i^{est} g_{k-i} \right) p_i^{est}. \quad (4.23)$$

Com essas últimas expressões, o problema de deconvolução através de rede neural recorrente está completamente descrito.

5 RESULTADOS

A metodologia aqui desenvolvida mostra duas formas para a obtenção da primeira aproximação para o perfil real. A primeira trata de um processo estatístico que busca uma redução das variações do perfil, denominado aqui como perfil quadratizado. A segunda utiliza a informação da resolução vertical proveniente de um perfil de alta resolução vertical. A escolha da opção mais apropriada a ser utilizada depende basicamente da natureza e qualidade dos dados disponíveis. Mostra-se, na seqüência deste capítulo, a avaliação da metodologia em dados sintéticos e em dados reais provenientes da formação Lagunillas, Bacia do Lago Maracaibo, localizado a oeste da Venezuela.

Apresenta-se uma primeira aplicação desta metodologia utilizando dados de um perfil sintético obtido através do modelo convolucional. A Figura 5.1-A mostra o perfil de baixa resolução a ser processado. Utiliza-se o perfil quadratizado, adquirido a partir do perfil sintético, como a primeira aproximação do perfil ideal e uma estimativa externa da resposta vertical da ferramenta. Na Figura 5.1-B, mostra-se a comparação entre o perfil quadratizado (linha verde), o resultado final desta metodologia (linha vermelha) e o perfil ideal (linha azul). Na Figura 5.1-C substitui-se o perfil quadratizado pelo perfil sintético para permitir uma comparação com o resultado do processamento da rede.

Observa-se que o perfil resultante do processamento tem a definição dos limites das camadas dominada pelo perfil quadratizado, o qual não interfere na estimativa do valor da propriedade física, que se aproxima do valor real definido pelo perfil ideal. A proximidade entre os gráficos do perfil processado e do quadratizado nos induz a atribuir grande importância ao processo de quadratização, no entanto, a quadratização pode ser substituída por um outro perfil de mais alta resolução sem perda nos resultados, como será visto no exemplo a seguir. A importância desta etapa ao processamento é de informar a rede neural as prováveis localizações das interfaces e de transmitir um valor inicial das propriedades físicas para serem utilizadas no processamento das redes.

Uma segunda aplicação mostra a utilização de um perfil com maior resolução vertical adotado como aproximação para o perfil ideal. A Figura 5.2-A mostra o perfil de baixa resolução vertical, obtido pelo modelo convolucional. A Figura 5.2-B mostra o perfil sintético de mais alta

resolução e a Figura 5.2-C mostra o perfil obtido pelo processamento da rede (azul) e o perfil ideal (vermelho).

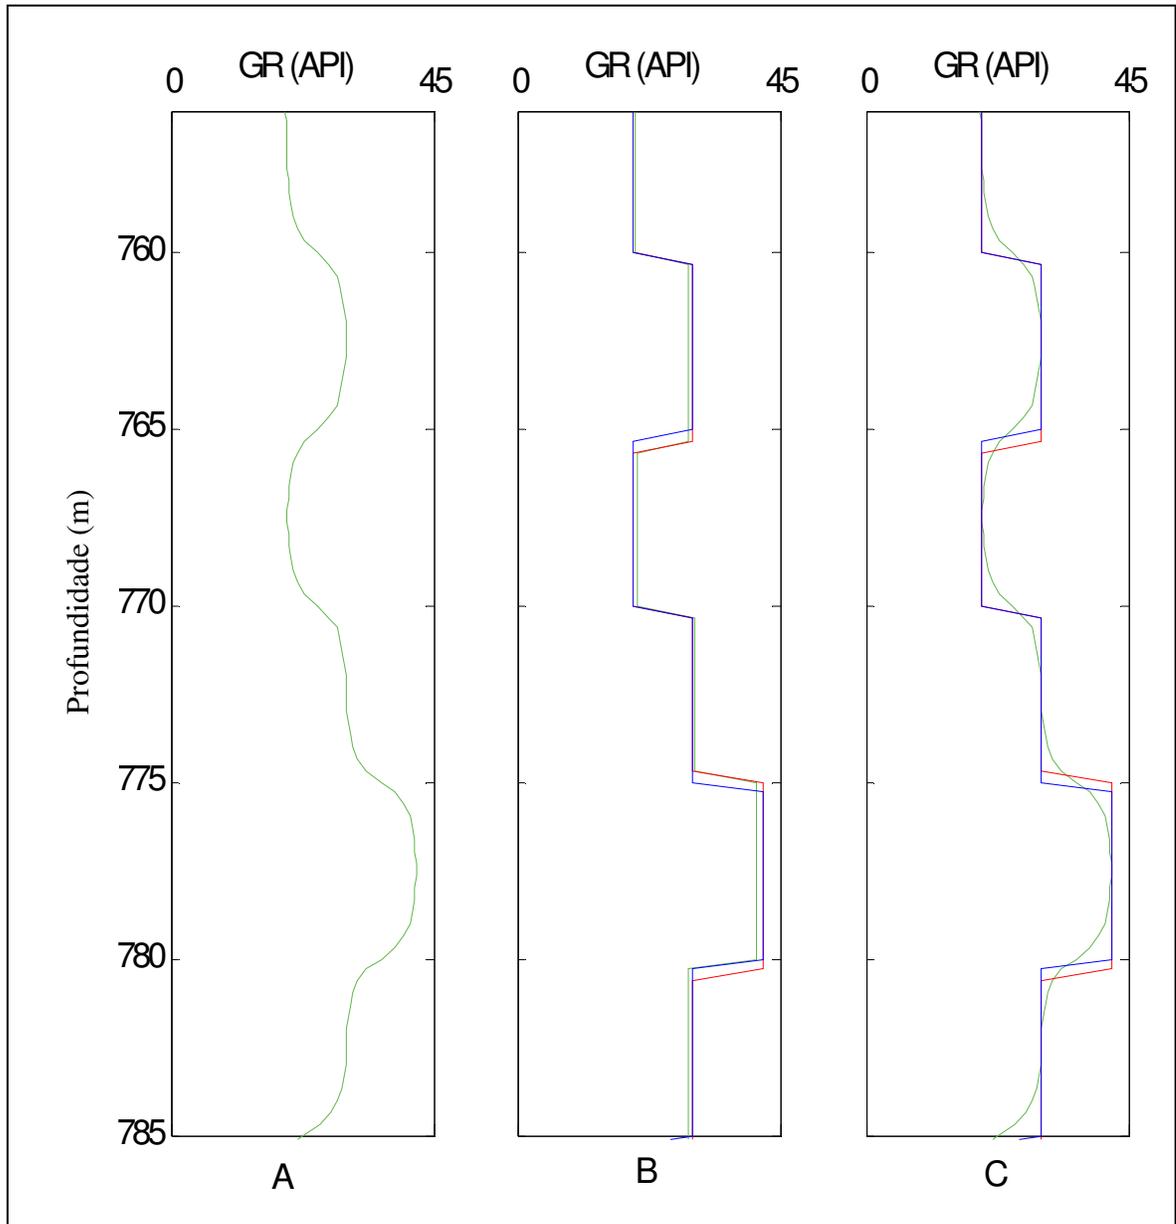


Figura 5.1: Exemplo, com dados sintéticos, do bloco de processamento com rede neural recorrente. A) Perfil sintético GR. B) Primeira estimativa para o perfil ideal (linha verde), perfil obtido como resultado final do processamento (linha vermelha) e perfil ideal (linha azul). C) Perfil ideal (linha azul), perfil obtido como resultado final (linha vermelha) e perfil sintético (linha verde).

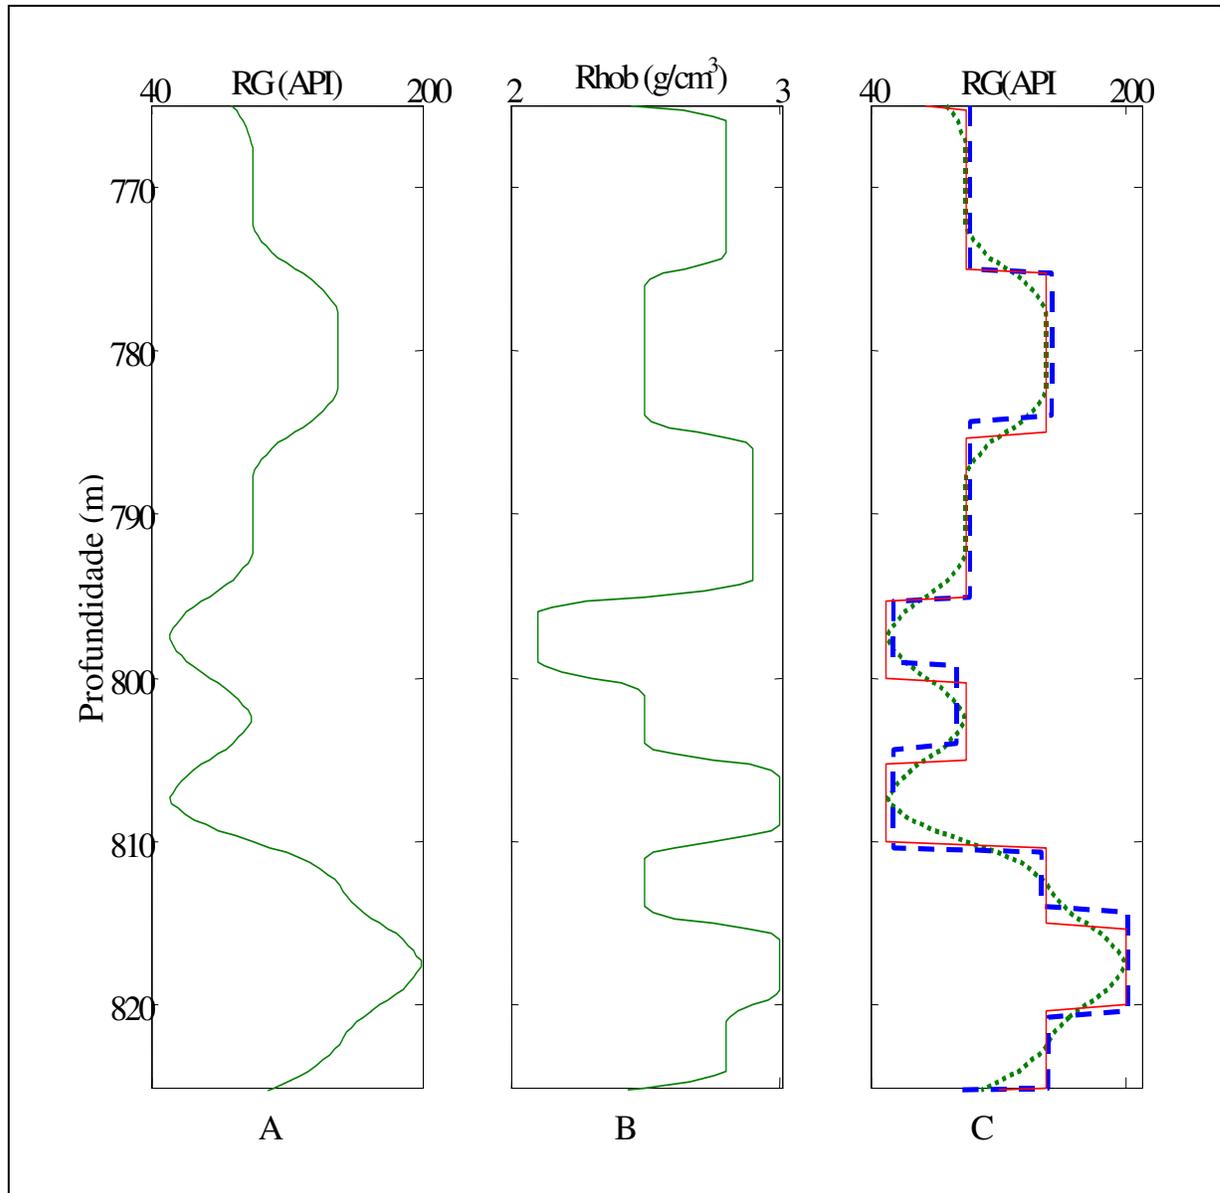


Figura 5.2: A) Perfil sintético GR. B) Perfil de alta resolução vertical. C) Perfil ideal (linha vermelha), perfil obtido como resultado final (linha azul) e perfil sintético (linha verde).

O processamento dos dados geofísicos de poço através das redes neurais recorrentes produz dados, que apresentam uma melhor individualização das camadas e mostra ainda a independência do bloco de processamento em relação a estimativa externa do perfil ideal nas duas possibilidades, adotadas nesta metodologia.

Um exemplo da aplicação desta metodologia com dados de perfis reais, adotando-se o processo de quadratização aqui apresentado é visto na figura 5.3. Nesta figura mostra-se o Perfil de Raio Gama (linha preta), e o resultado do processamento da rede (linha azul). Em todo intervalo de profundidade do perfil obtem-se uma melhor definição das camadas pelo perfil processado em comparação com o perfil original. Isto ocorre devido à minimização do efeito da resposta vertical da ferramenta produzida pelo processamento da rede neural recorrente. O testemunho mostrado na Figura 5.3-B confirma os resultados obtidos e possibilitam o cálculo mais realista de reservas a partir da melhoria da qualidade das medidas realizadas.

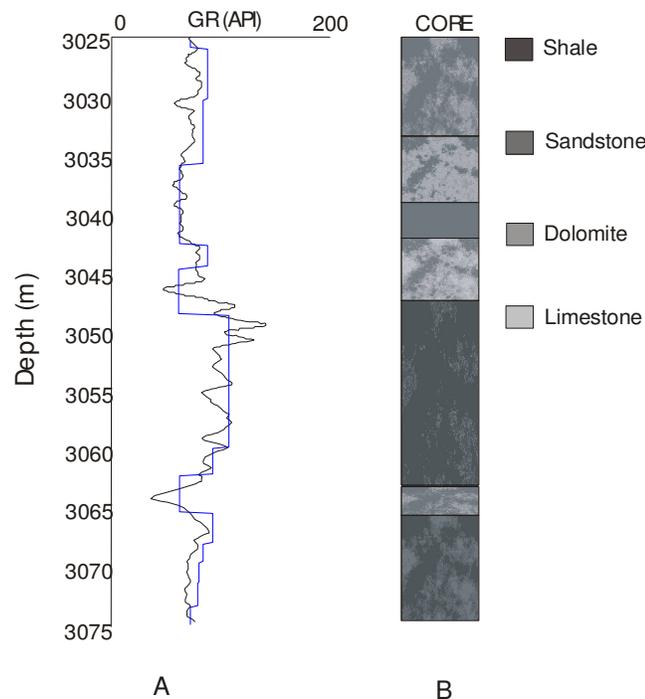


Figura 5.3: A – Perfil de Raio Gama Natural (preto) e Perfil processado (azul).
B – Testemunho

Uma segunda aplicação com dados reais de outro poço da formação Lagunillas, contendo perfis com diferentes resoluções verticais mostra o processamento com a rede neural recorrente utilizando-se das duas formas para a estimativa do perfil ideal: O perfil quadratizado e o perfil de densidade, que neste caso possui maior resolução vertical que o perfil de raio gama que será processado.

Com o intuito de melhorar a resolução vertical do perfil de raios gama, aplicou-se o método aqui apresentado utilizando o perfil quadratizado como primeira estimativa para o perfil

ideal. O perfil de raio gama natural (GR) lançado em unidades API é mostrado na Figura 5.4-A. Na Figura 5.4-B tem-se o perfil quadratizado (linha azul) e o perfil resultante do processamento (linha verde). O perfil quadratizado mostra a primeira aproximação para o valor da propriedade física da rocha em cada camada, assim o perfil processado pode ser interpretado como a correção do valor da propriedade. A Figura 5.4-C mostra o perfil de raio gama natural (linha azul) e o perfil resultante do processamento através das redes neurais recorrentes (linha verde). Para o caso real observa-se um comportamento do perfil processado semelhante aquele mostrado para o caso sintético, onde o perfil quadratizado influencia apenas na definição dos limites verticais das camadas e não no valor das correspondentes propriedades físicas.

Como o perfil de raios gama exibe um comportamento que indica a ocorrência de um ambiente deposicional complexo, mostra-se na Figura 5.5 os resultados da metodologia aqui apresentada, tomando-se o perfil de densidade como primeira estimativa sobre o perfil ideal. A Figura 5.5-A mostra o perfil de raio gama natural e a Figura 5.5-B, mostra o perfil de densidade. Na Figura 5.5-C, pode-se observar as diferenças entre a propriedade física medida pela ferramenta e o valor recuperado pelo processamento. Usando o perfil de densidade observa-se que o efeito da ferramenta sobre o perfil medido também pode ser atenuado. Com esta melhoria na qualidade dos dados pode-se obter valores mais realistas da propriedade física da rocha em subsuperfície e com isso melhorar a avaliação de óleo em uma camada reservatório.

Pode-se avaliar a influência da primeira estimativa sobre o perfil ideal comparando a Figura 5.4 com a Figura 5.5. Esta estimativa concentra-se na definição das posições das interfaces e não tem influência na obtenção da propriedade física da rocha. No entanto, o perfil quadratizado induz uma grande limitação ao processo, uma vez que ele é feito baseado na suposição de homogeneidade na camada rochosa e este comportamento é assimilado pela rede recorrente forçando a uma sobrevalorização da propriedade física. Deste modo, considera-se como a escolha mais apropriada para a primeira estimativa sobre o perfil ideal o uso de um perfil de mais alta resolução, onde o efeito do processamento sobre a propriedade física é atenuado, resultando em valores mais realistas, principalmente em casos de seqüências deposicionais complexas.

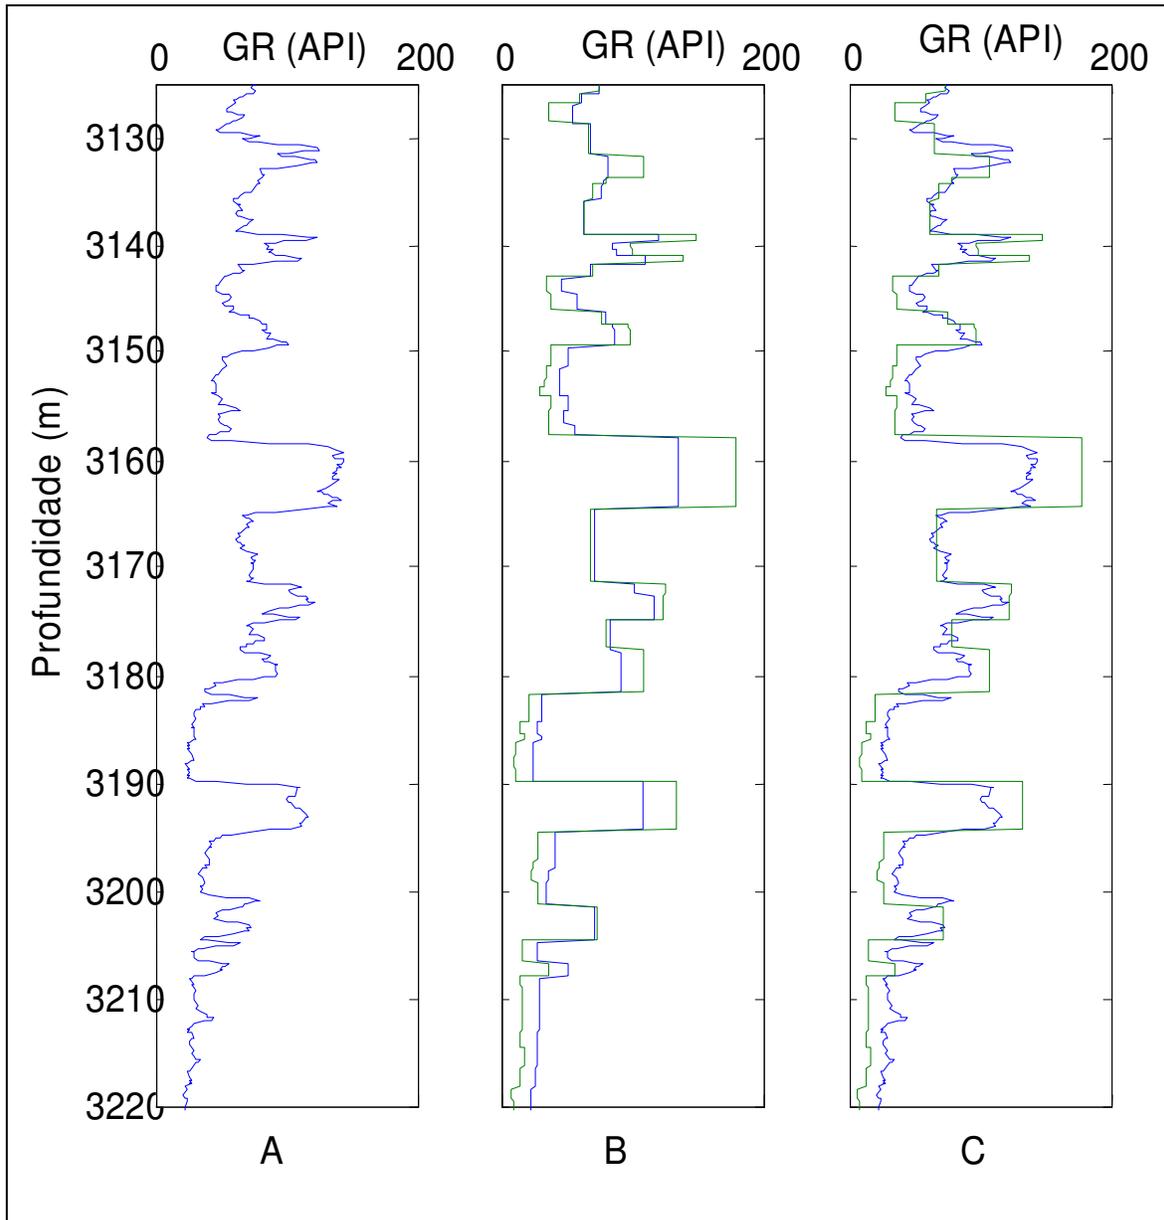


Figura 5.4: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadratizado (linha azul) perfil processado através da rede neural recorrente (linha verde). C) Perfil de raio gama natural (linha azul) e perfil processado (linha verde).

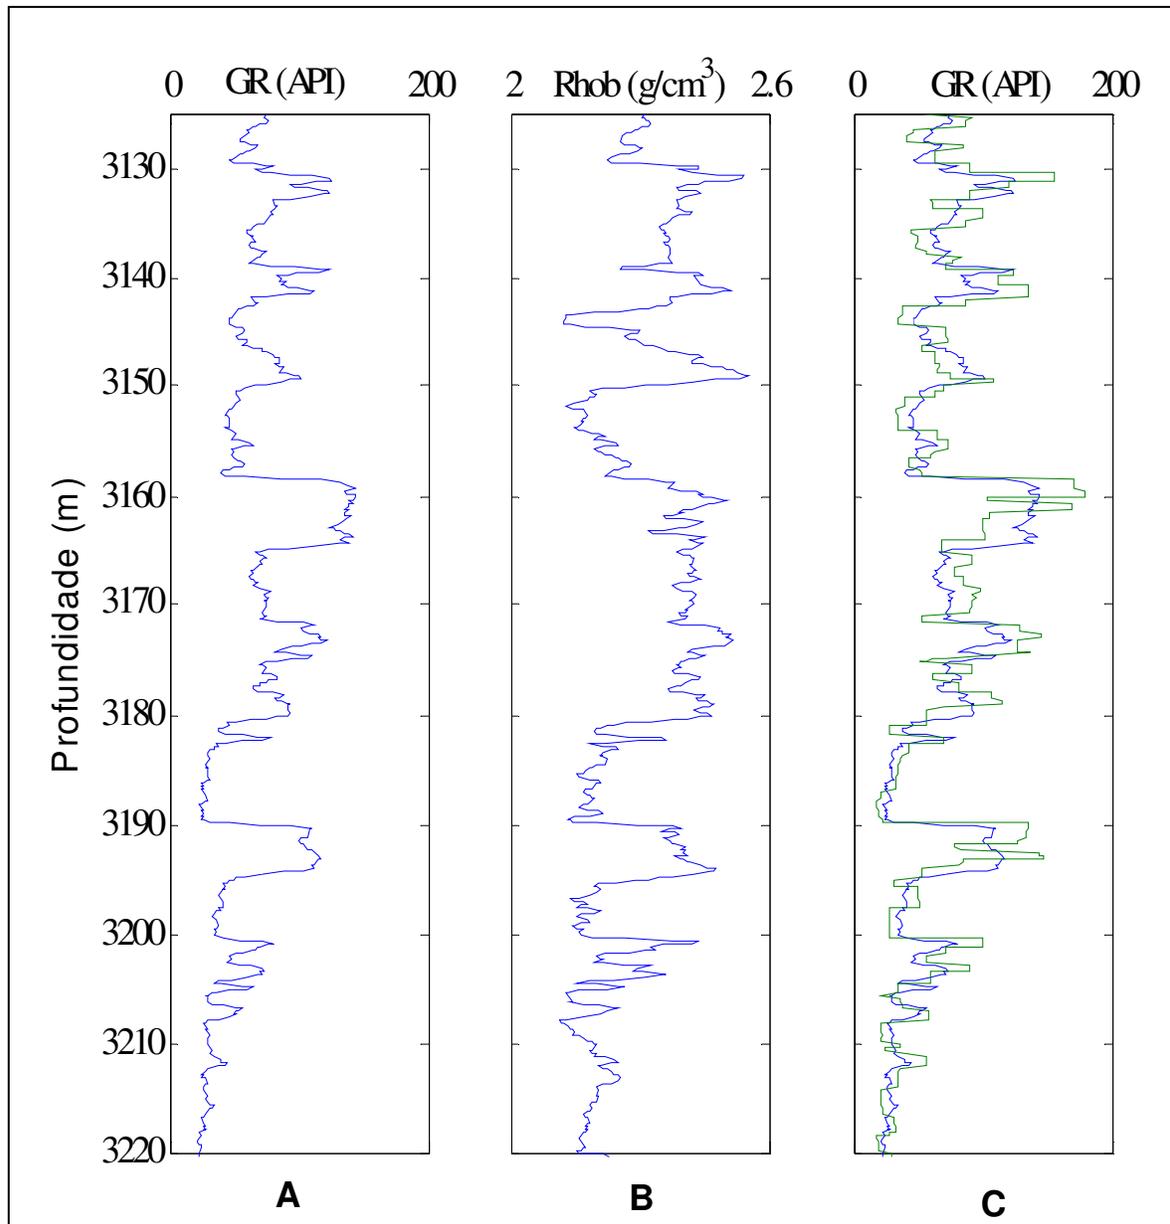


Figura 5.5: Segunda forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil de densidade. C) Diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (linha verde).

Apresentam-se agora três outras aplicações desta metodologia a dados reais de outros poços da formação Lagunillas, utilizando o mesmo procedimento anterior, ou seja, como primeira aproximação o perfil quadratizado e, em seguida, a primeira aproximação para o perfil ideal passa a ser o perfil de densidade.

Nas Figuras 5.6-A, 5.8-A e 5.10-A tem-se o perfil de raio gama natural do poço. As Figuras 5.6-B, 5.8-B e 5.10-B mostram, em azul, o perfil quadratizado e, em verde, o valor da propriedade corrigido através do processamento das redes neurais recorrentes. Nas Figuras 5.6-C, 5.8-C e 5.10-C observa-se a diferença entre o valor da propriedade medida pela ferramenta e o valor corrigido.

Nas Figuras 5.7-A, 5.9-A e 5.11-A tem-se o perfil de raio gama natural do poço. As Figuras 5.7-B, 5.9-B e 5.11-B mostram, o perfil de densidade utilizado como primeira aproximação para a propriedade física da rocha. Nas Figuras 5.7-C, 5.9-C e 5.11-C observa-se a diferença entre o valor da propriedade medida pela ferramenta e o valor corrigido.

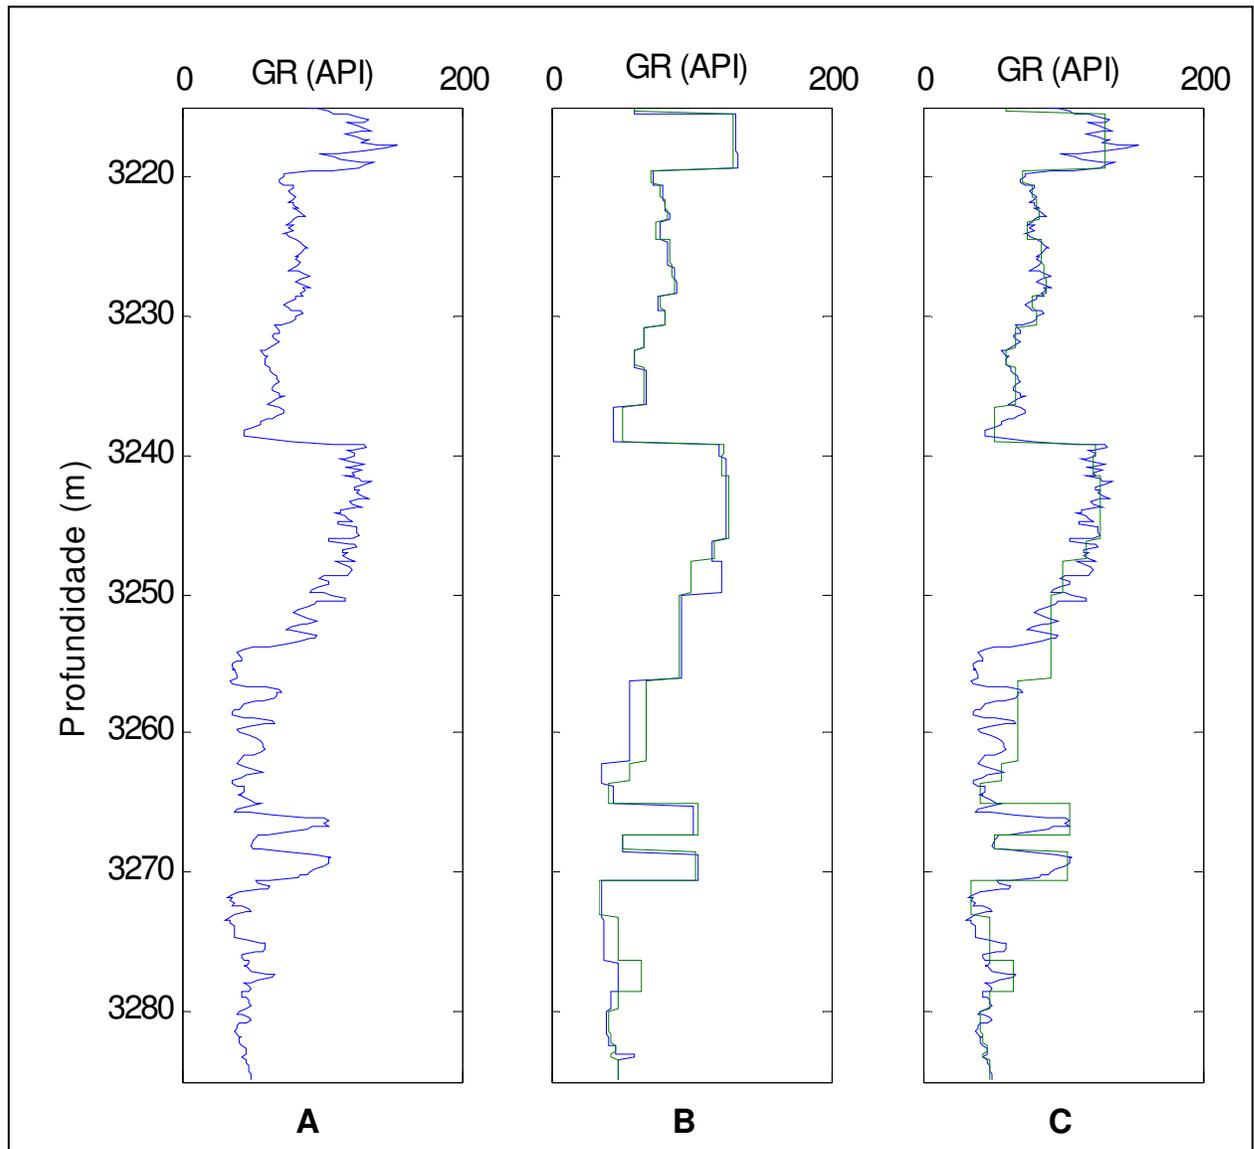


Figura 5.6: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadratinizado (linha azul) e perfil processado através da rede neural recorrente (linha verde). C) Perfil de raio gama natural (linha azul) e o perfil obtido pelo processamento (linha verde).

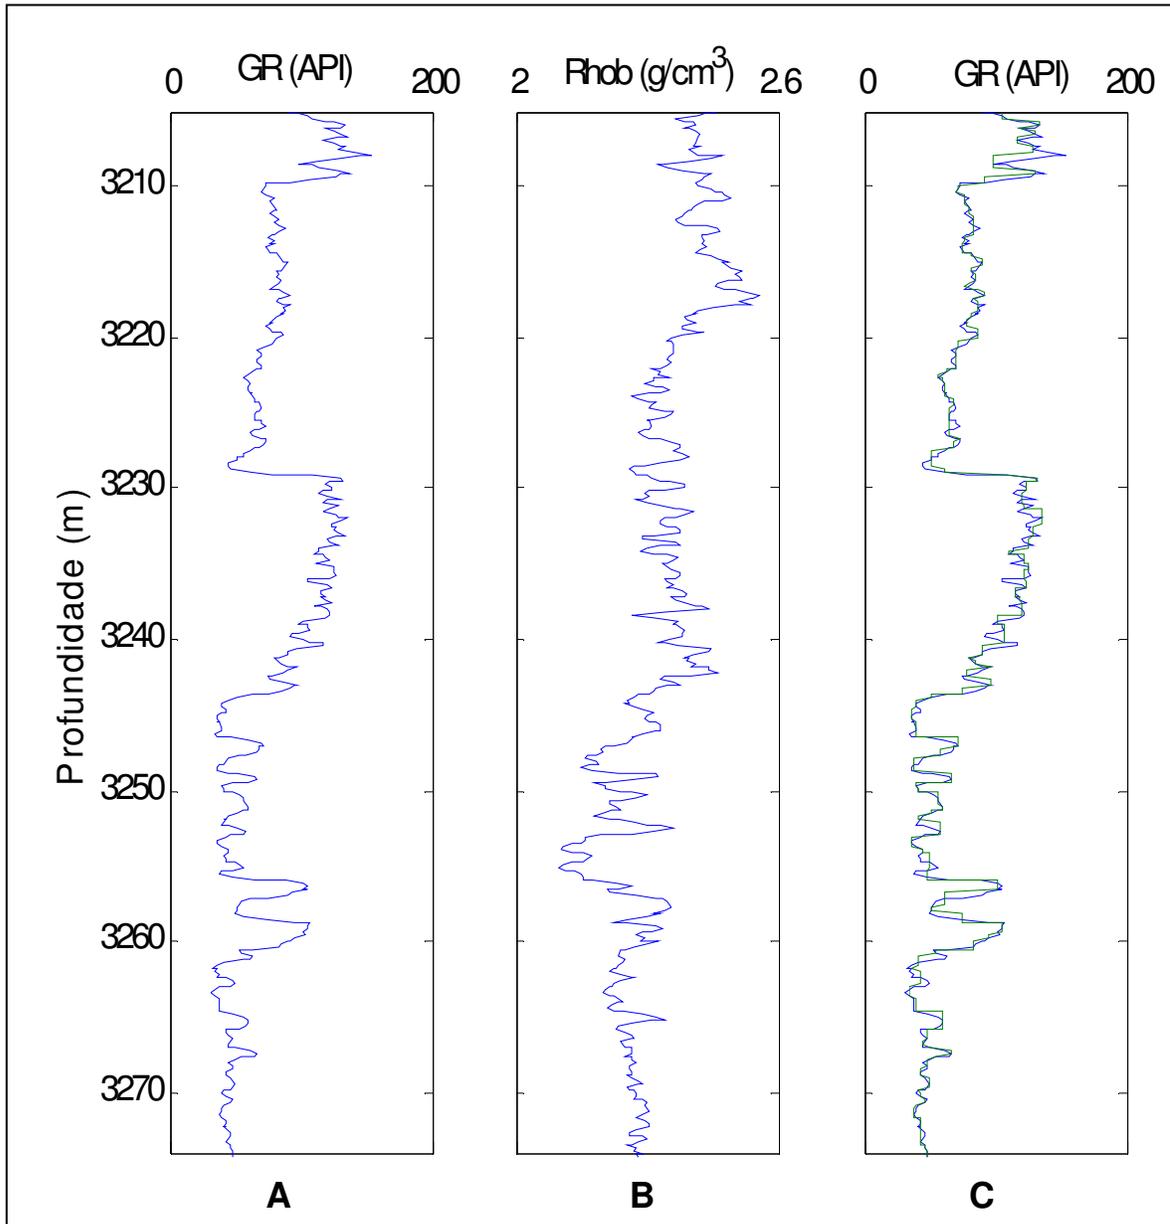


Figura 5.7: Segunda forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil de densidade. C) Diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (linha verde).

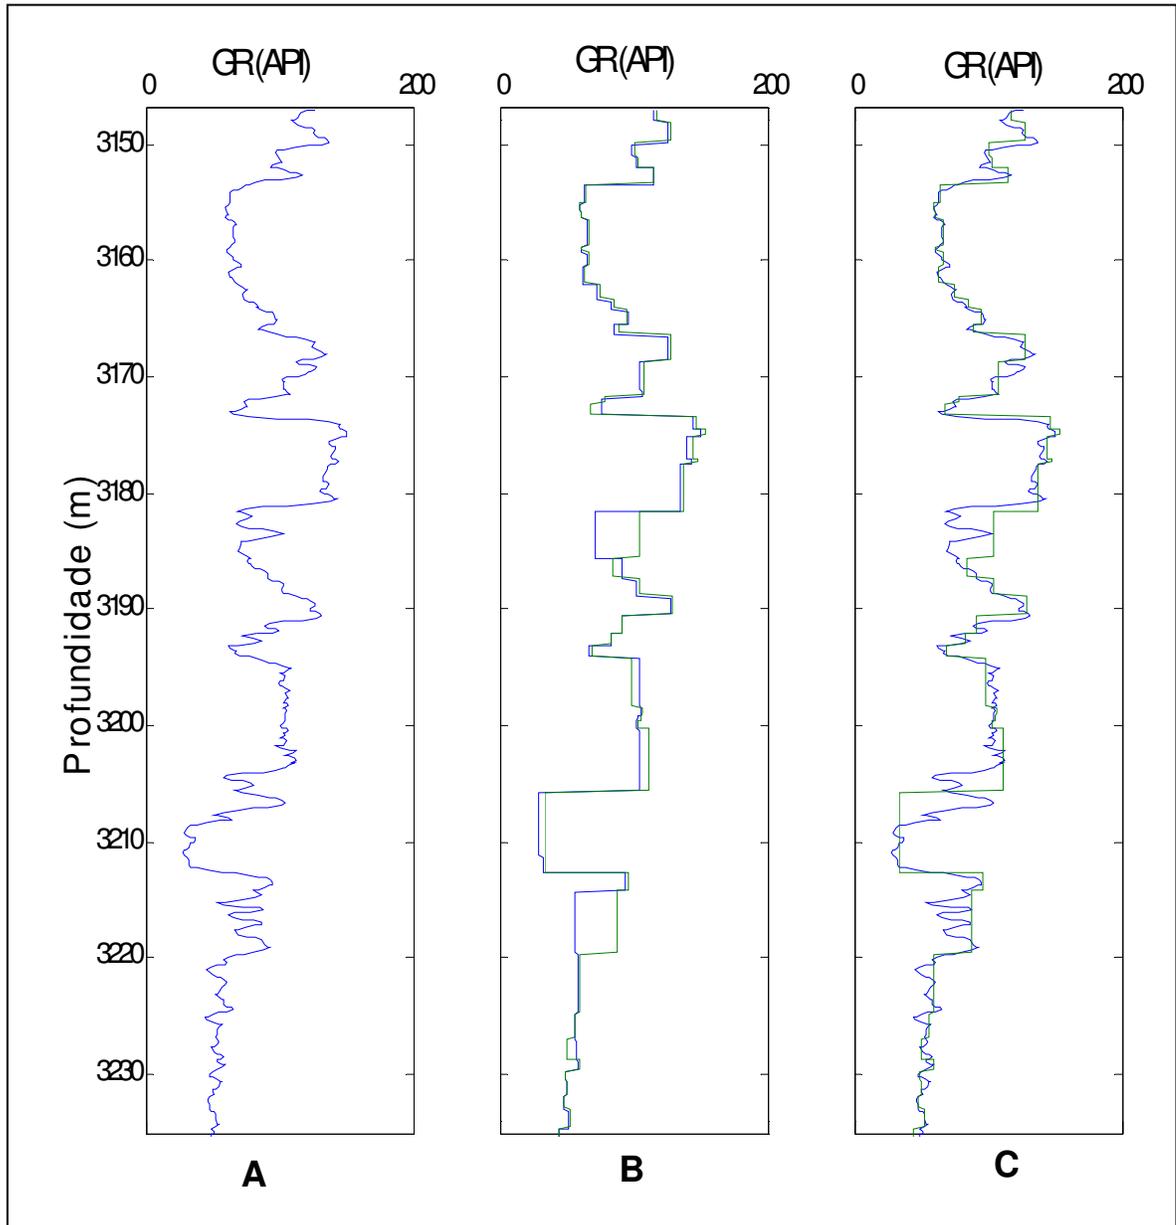


Figura 5.8: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadratizado (linha azul) e perfil processado através da rede neural recorrente (linha verde). C) Perfil de raio gama natural (linha azul) e o perfil obtido pelo processamento (linha verde).

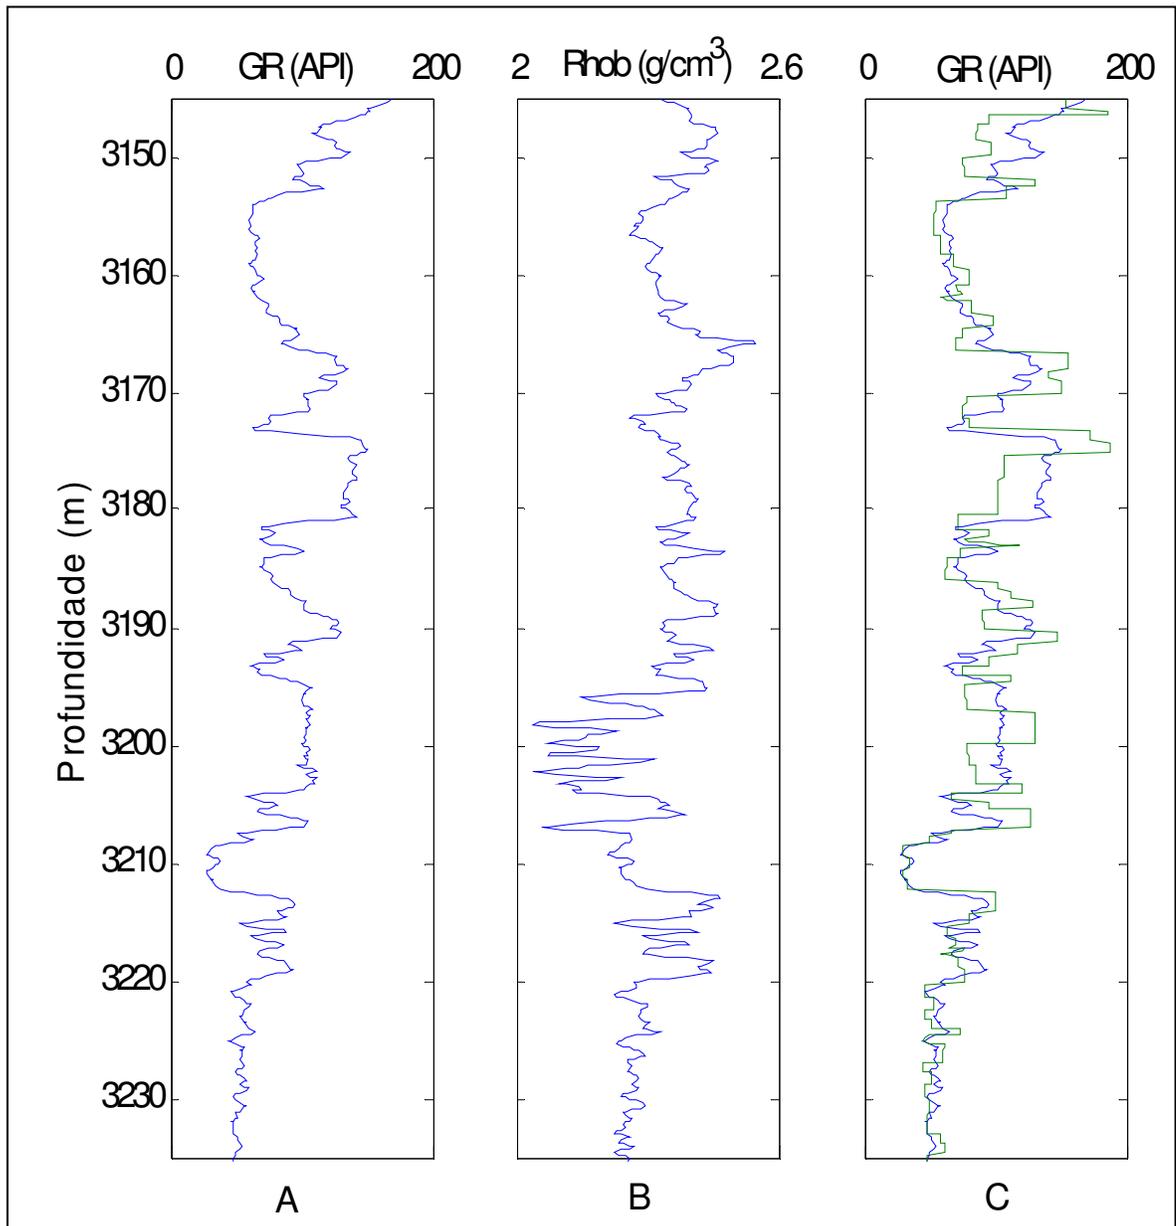


Figura 5.9: Segunda forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil de densidade. C) Diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (linha verde).

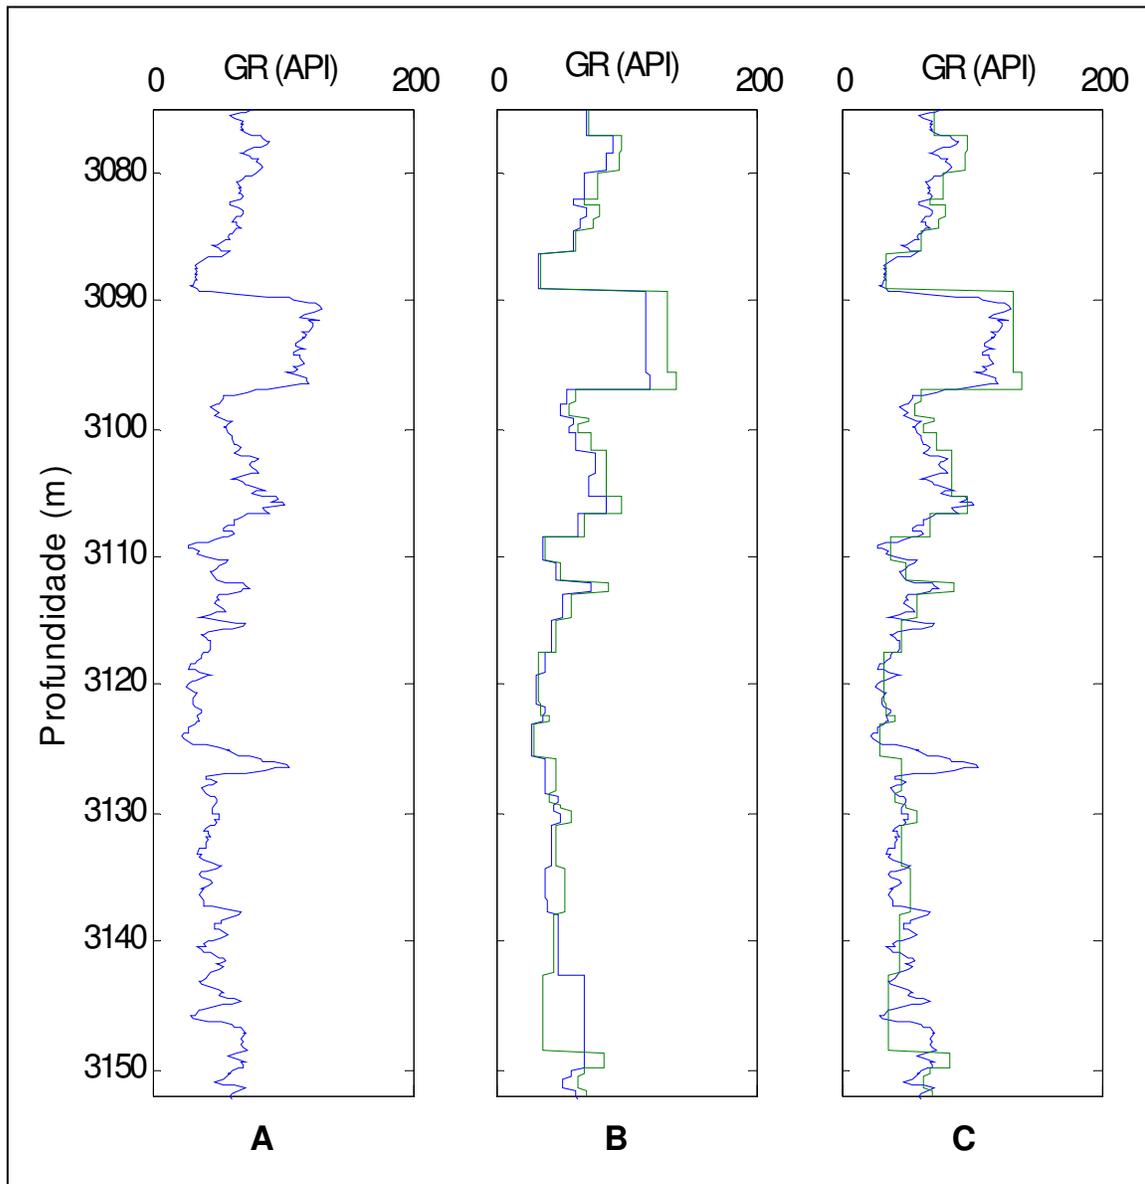


Figura 5.10: Primeira forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil quadrado (linha azul) e perfil processado através da rede neural recorrente (linha verde). C) Perfil de raio gama natural (linha azul) e o perfil obtido pelo processamento (linha verde).

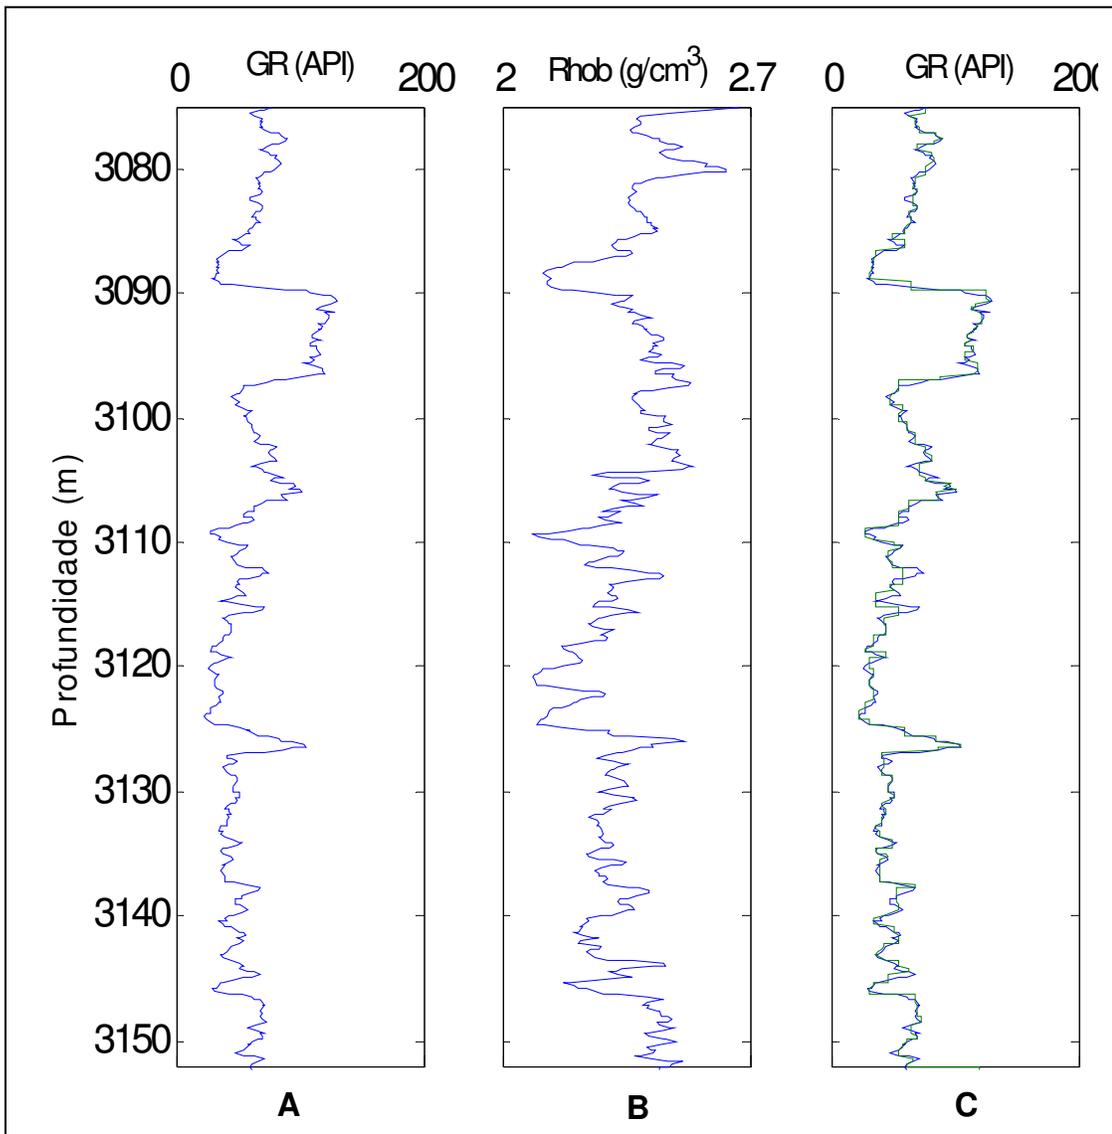


Figura 5.11: Segunda forma de processamento para o perfil real: A) Perfil de raio gama natural (GR). B) Perfil de densidade. C) Diferença entre o valor da propriedade medida pela ferramenta e o valor recuperado (linha verde).

5.1 APLICAÇÃO NA AVALIAÇÃO DE FORMAÇÃO

O óleo e gás estão contidos nos poros de rochas reservatórios, como os carbonatos e arenitos. Para avaliar um possível reservatório de hidrocarboneto, a porosidade e a saturação precisam ser conhecidas, pois definem a quantidade de hidrocarboneto por volume unitário de rocha. É preciso corrigir a porosidade e a saturação de água pelo volume de argila o qual é um indicador da qualidade do reservatório. Baixo conteúdo de argila normalmente indica um bom reservatório. A argilosidade ou volume de argila (V_{SH}) é obtida a partir do perfil de raio gama natural é expressa por

$$V_{SH} = \frac{Gr - Gr_{min}}{Gr_{max} - Gr_{min}} \quad (5.1)$$

Na expressão (5.1), Gr é o valor do raio gama natural lido no perfil; Gr_{max} é o valor representativo da radiação gama natural nos folhelhos e Gr_{min} é o valor representativo da radiação gama natural nos arenitos limpos.

O volume de argila pode ser obtido por vários métodos. Através do perfil de raio gama natural (GR), perfil de potencial espontâneo (SP) e através da combinação dos perfis de porosidade densidade-neutrônico, que é o método mais comum. Destes valores para o volume de argila, a melhor escolha de um valor representativo é utilizar o método que gera os valores mínimos para o volume de argila (Ellis, 1987).

As Figuras 5.12 e 5.13 mostram os resultados do cálculo de volume de argila do perfil GR sem e com o método de processamento aqui apresentado. Em ambos os casos, nota-se que os menores valores para o volume de argila são produzidos pelo perfil de GR processado. A figura 5.12-A mostra os perfis de raio gama natural (azul) e o obtido pelo processamento da rede (verde), utilizando como primeira aproximação para o perfil ideal o quadratizado, na figura 5.12-B tem-se a argilosidade obtida utilizando a equação (5.1) e adotando-se para Gr o perfil processado. Na figura 5.13-A tem-se o perfil de raio gama natural (azul) e o perfil processado, agora, utilizando o perfil de alta resolução como primeira aproximação para o perfil ideal. Na figura 5.13-B tem-se a argilosidade obtida utilizando a equação (5.1) e adotando-se para GR o perfil processado.

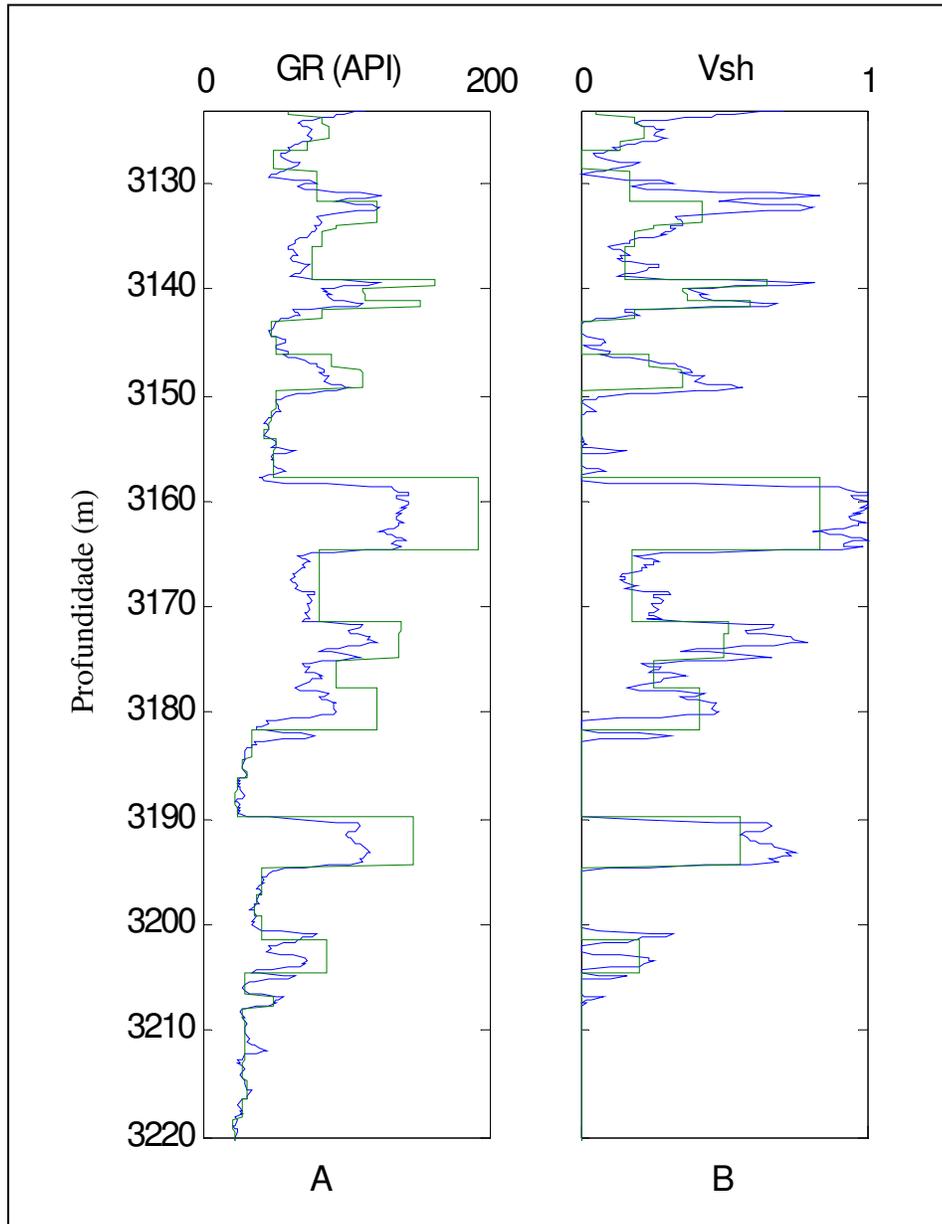


Figura 5.12: A) Perfil de raio gama natural (azul) e perfil processado com o quadratizado (verde). B) Volume de argila sem o processamento (azul), volume de argila com o processamento (verde).

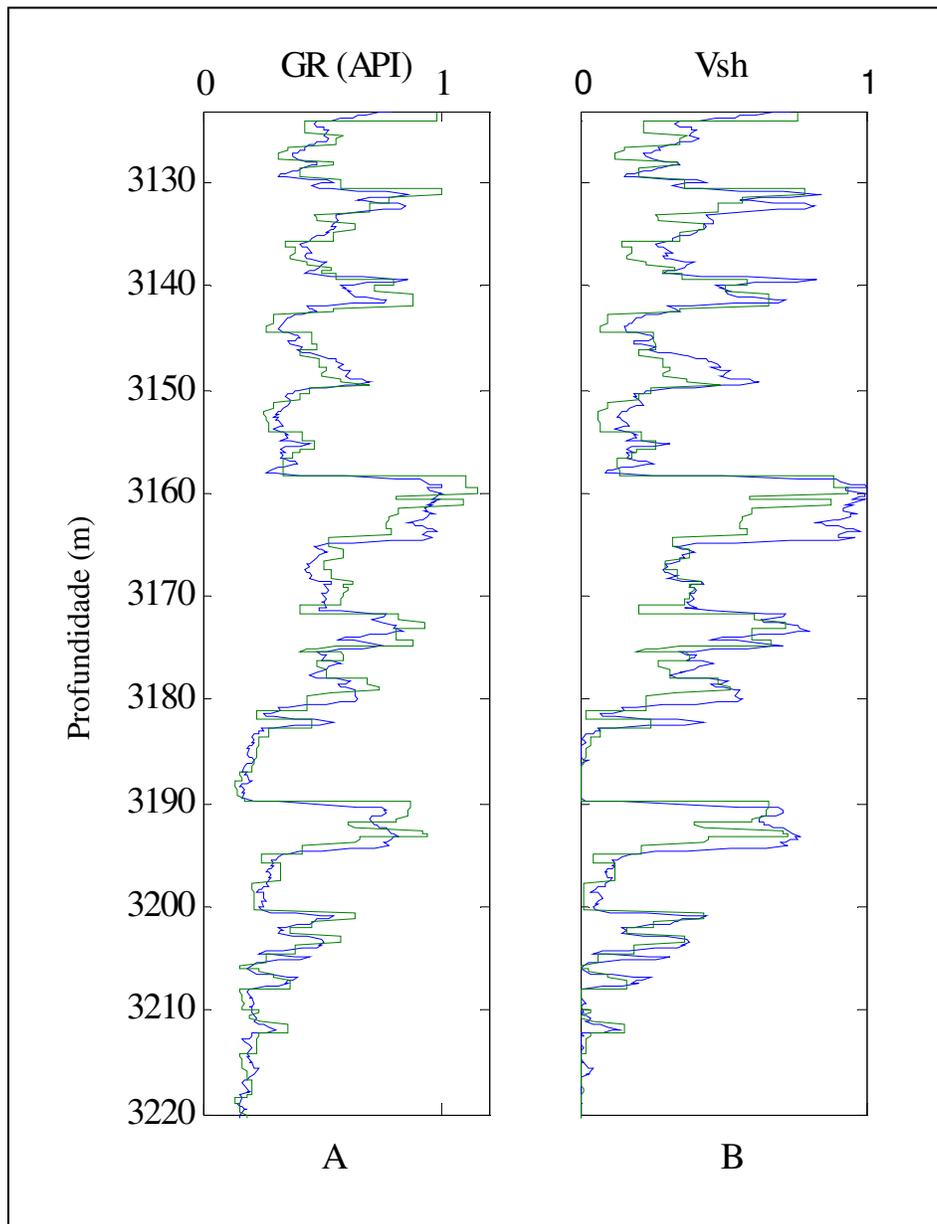


Figura 5.13: A) Perfil de raio gama natural (azul) e perfil processado com o perfil de densidade (verde), B) Volume de argila sem o processamento (azul), volume de argila com o processamento (verde).

6 - CONCLUSÃO

A redução no tempo de processamento dos dados de perfil de poço, a retirada autônoma de informações destes dados e a busca pela melhor representação da subsuperfície são necessidades imediatas da indústria do petróleo e tem absorvido elevado custo computacional e econômico tanto nas empresas quanto nas universidades.

Apresentamos, nesta dissertação, uma nova visão do problema da deconvolução aplicada aos perfis geofísicos de poço, introduzindo uma particular rede neural recorrente, que por suas características intrínsecas melhoram a resolução vertical e os valores das propriedades físicas retratadas pelos perfis, com redução do tempo de processamento computacional. Atualmente, este tipo de problema tem despertado a atenção das indústrias petrolíferas da América do Sul devido ao aumento do interesse na reavaliação de poços em antigos campos de petróleo.

A aplicação do método aqui apresentado, para a melhoria da qualidade dos perfis de poço em dados sintéticos mostrou-se eficiente, sendo possível a recuperação do perfil ideal. A sua aplicação aos dados reais de poços 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. No entanto, esta metodologia não restringe a sua aplicação somente a esses perfis, uma vez que nenhuma premissa foi assumida sobre a propriedade física.

Este método propiciou uma melhoria na qualidade dos dados reais e conseqüentemente, valores mais realistas foram produzidos pela sua utilização na avaliação de formação, como mostrado para o cálculo do volume de argila, pelo método monoperfil utilizando o perfil de raio gama natural.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANDRADE, A., 1992. *Deconvolução de perfis de poço*, Belém, Universidade Federal do Pará, Centro de Geociências. (Dissertação de Mestrado).
- ANDRADE, A. & LUTHI, S.M., 1993. Deconvolution of wireline logs using point-spread function. *In: CONGRESSO INTERNACIONAL DA SOCIEDADE BRASILEIRA DE GEOFÍSICA*, 3., Rio de Janeiro, *Resumo expandido*. Rio de Janeiro, SBGf.
- ANDRADE, A.; LUTHI, S.M.; GUERRA, C.E., 1995. Determinação de Interfaces em Perfis através de Rede Neural de Hopfield, *In: CONGRESSO INTERNACIONAL DA SOCIEDADE BRASILEIRA DE GEOFÍSICA*, 4., São Paulo, *Resumo expandido*. São Paulo, SBGf.
- CRAIN, E.R., 1986. *The Log Analysis Handbook: Quantitative log analysis methods*, Tulsa, Pennwell Books. v.1.
- BARBER, T.D., 1988. Induction vertical resolution enhancement: Physics and limitations. *In: SPWLA ANNUAL LOGGING SYMPOSIUM*, 29., San Antonio, paper O. San Antonio, SPWLA.
- DOVETON, J.H. 1986. *Log analysis of subsurface geology: Concepts and computer methods*. New York, John-Wiley & Sons. 273p.
- ELLIS, D.V., 1987. *Well logging for earth scientists*. New York, Elsevier, 532p.
- FISCHETTI, A.I. & ANDRADE, A., 2002. Porosity images from well logs. *Journal of Petroleum Science and Engineering*, **36**:149-158.
- FLEXA, R.T.; FISCHETTI, A.I.; ANDRADE, A., 2001. Determinação estatística do contato óleo-água em perfis de poço. *In: CONGRESSO INTERNACIONAL DA SOCIEDADE BRASILEIRA DE GEOFÍSICA*, 7., Salvador, *Resumo expandido*. Salvador, SBGf.
- HOPFIELD, J.J., 1982. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, **79**:2554-2558.
- HOPFIELD, J.J. & TANK, D.W., 1985. Neural computations of decisions in optimization problems. *Biological Cybernetics*, **52**:141-152.
- LUTHI, S.M., 2001. *Geological well logs: Their use in reservoir modeling*. Berlin, Springer-Verlag, 367 p.
- MACÍAS, C.C.; SEN, M.K.; STOFFA, P.L., 1997. Hopfield neural network and mean field annealing for seismic deconvolution and multiple attenuation. *Geophysics*, **62**: 992-1002.

- MCCULLOH, W.S. & PITTS, W. 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, **5**: 115-133.
- NIKRAVESH, M., 2004. Soft computing-based computational intelligent for reservoir characterization. *Expert Systems with Applications*, **26**:19-38.
- NOSAL, E.A., 1983. Statistical determination of geophysical well log response function. *Geophysics*, **48**: 1525-1535.