

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

APLICAÇÃO DE REDES NEURONAIS ARTIFICIAIS
AO TRATAMENTO E INTERPRETAÇÃO DE
PERFIS GEOFÍSICOS DE POÇO ABERTO

TESE APRESENTADA POR
ANDRÉ JOSÉ NEVES ANDRADE

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

Data de Aprovação : 13/02/1997

COMITÊ DE TESE:

S. Luthi

Dr. Stefan Moritz Luthi (Orientador)
Luiz Rijo

Dr. Luiz Rijo
Laurenildo

Dr. Lourenildo Williame Barbosa Leite
Edilberto

Dr. Edilberto Pereira Teixeira
Ubiratan

Dr. Ubiratan Holanda Bezerra

BELÉM

1997

ANDRADE, André José Neves. Aplicação de redes neuronais artificiais à interpretação de perfis de poço aberto. Belém, Universidade Federal do Pará. Centro de Geociências, 1997. 127p.

Tese (Doutorado em Geofísica) - Curso de Pós-Graduação em Geofísica, Centro de Geociências, UFPA, 1997.

1. GEOFÍSICA DE POÇO. 2. REDES NEURONAIS. 3. INTERPRETAÇÃO GEOLÓGICA. I. Título.

SUMÁRIO

LISTA DE ILUSTRAÇÕES	iv
RESUMO	1
ABSTRACT	2
1 - INTRODUÇÃO	3
2 - PERFILAGEM GEOFÍSICA DE POÇO ABERTO	7
2.1 INTRODUÇÃO	7
2.2 BREVE HISTÓRICO	8
2.3 O PERFIL DE POÇO	10
2.4 APLICAÇÕES GEOLÓGICAS	11
2.5 PERFIL DE ESPECTROMETRIA DE RAIOS GAMA NATURAL	11
2.5.1 Radioatividade Natural das Rochas	13
2.5.2 Perfil de Espectrometria de Raios Gama Natural	13
2.5.3 O Modelamento Numérico do Perfil de Espectrometria de Raios Gama Natural	14
3 - REDES NEURONAIS ARTIFICIAIS	15
3.1 INTRODUÇÃO	15
3.2 REDES NEURONAIS ARTIFICIAIS	16
3.2.1 O Neurônio Artificial	22
3.2.2 As Funções de Ativação	24
3.2.3 Generalização	28
3.3 REDE NEURONAL DIRETA MULTICAMADAS	29
3.3.1 Aprendizagem por Retro-propagação do Erro	34
3.3.1.1 Algoritmo Retro-Propagação do Erro	35
3.3.2 Aproximação de Funções	41
4 - DETERMINAÇÃO DE INTERFACES COM A REDE NEURONAL DIRETA MULTICAMADA	43
4.1 INTRODUÇÃO	43

4.2	INTERFACES NO PERFIL	43
4.3	A REDE NEURONAL DIRETA MULTICAMADAS	45
4.3.1	Arquitetura da Rede Neuronal	45
4.3.2	Conjunto de Treinamento	50
4.3.3	Algoritmo de Treinamento	51
4.3.3.1	Termo de Momento e Adaptação do Parâmetro de Aprendizagem	51
4.4	RESULTADOS	52
4.4.1	Resultados sobre dados sintéticos	52
4.4.1.1	Resultados do modelo convolucional	52
4.4.1.2	Resultados do modelo numérico	53
4.4.2	Resultados sobre dados reais	59
4.5	CONCLUSÕES	63
5	- DETERMINAÇÃO DE INTERFACES COM A REDE NEURONAL DE HOPFIELD	71
5.1	INTRODUÇÃO	71
5.2	REDE NEURONAL RECORRENTE DE HOPFIELD	71
5.2.1	Rede Binária de HOPFIELD	72
5.2.2	Função Energia	74
5.3	SIMULAÇÃO ATRAVÉS DA REDE NEURONAL BINÁRIA DE HOPFIELD	74
5.3.1	Resposta Vertical da Ferramenta sob as Condições Atuais do Poço	78
5.4	RESULTADOS	79
5.4.1	Resultados sobre Modelos Convolucionais	79
5.4.2	Resultados sobre Modelos Numéricos	83
5.4.3	Resultado sobre Perfis Reais	88
5.5	CONCLUSÕES	88
6	- IDENTIFICAÇÃO DE LITOLOGIAS EM PERFIS	91
6.1	INTRODUÇÃO	91
6.2	O GRÁFICO M-N	92
6.3	REDES NEURONAIS COM CAMADA COMPETITIVA	95
6.4	MÉTODO	98
6.4.1	A Rede Neuronal	98
6.5	RESULTADOS	99
6.5.1	Resultados sobre Dados Reais	99
6.6	CONCLUSÃO	101

7 - CORRELAÇÃO ESTRATIGRÁFICA DE PERFIS	105
7.1 INTRODUÇÃO	105
7.2 MÉTODO	107
7.3 RESULTADOS	110
7.3.1 Resultados sobre Dados Sintéticos	110
7.3.2 Resultados sobre Dados Reais	115
8 - CONCLUSÃO	123
REFERÊNCIAS BIBLIOGRÁFICAS	127

LISTA DE ILUSTRAÇÕES

FIGURAS

Figura 2.1	Arranjo Schlumberger utilizado na perfilagem vertical. O equipamento de registro na superfície era desligado a cada deslocamento do arranjo com a profundidade. R_a é a resistividade aparente, K é uma constante que depende da geometria do arranjo, V_{mea} é a voltagem medida e I a intensidade de corrente. (Modificado de LABO, 1987).	9
Figura 2.2	Diagrama da aparelhagem de aquisição das medidas geofísicas realizadas em um poço.	12
Figura 3.1	Neurônio bioquímico, exemplificado por uma célula nervosa do tipo piramidal	17
Figura 3.2	Rede neuronal artificial típica.	19
Figura 3.3	Neurônio artificial típico.	23
Figura 3.4	Transformação afim, produzida pela presença de um valor limiar. . .	24
Figura 3.5	Função degrau-simples.	25
Figura 3.6	Função rampa.	26
Figura 3.7	Função logística.	27
Figura 3.8	Função tangente hiperbólica.	27
Figura 3.9	Exemplo de um ajuste suave com boa generalização	28
Figura 3.10	Arquitetura típica de uma rede neuronal artificial de múltiplas camadas	31
Figura 3.11	Tipos de sinal que percorrem a rede neuronal. sinal direto - linha cheia. sinal inverso - linha pontilhada	32
Figura 3.12	<i>Perceptron</i> : Mostrando o seu elemento processador.	33
Figura 3.13	<i>Adaline</i> : Mostrando o seu elemento processador.	34
Figura 3.14	Diagrama de localização dos neurônios nas camadas	39
Figura 4.1	Arquitetura da rede neuronal direta multicamada para a simulação da tomada de decisão do intérprete na determinação das interfaces no perfil.	49

Figura 4.2	Determinação de interfaces em modelos convolucionais. A figura mostra a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético (linha cheia) e as interfaces determinadas pela rede neuronal direta multicamadas, marcadas com círculos escuros. As profundidades estão marcadas em centímetros.	54
Figura 4.3	Instantes do treinamento da rede neuronal. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas esta marcado com cruze e a linha cheia representa a resposta da rede. (a) 50 épocas. (b) 250 épocas. (c) 750 épocas. (d) 1 000 épocas.	55
Figura 4.4	Determinação de interfaces em modelos numéricos. A figura mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal direta, marcadas com círculos escuros. . .	56
Figura 4.5	Instantes do treinamento da rede neuronal. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas esta marcada com cruze e a linha cheia, representa a resposta da rede. (a) 50 épocas. (b) 250 épocas. (c) 750 épocas. (d) 1 500 épocas.	57
Figura 4.6	Determinação de interfaces em modelos numéricos com ruído. A figura mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal direta, marcadas com círculos escuros. . .	58
Figura 4.7	Determinação de interfaces em modelos numéricos. A figura mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal direta, marcadas com círculos escuros. . .	60

Figura 4.8	Instantes do treinamento da rede neuronal. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas esta marcada com cruze e a linha cheia, representa a resposta da rede. (a) 50 épocas. (b) 250 épocas. (c) 500 épocas. (d) 800 épocas.	61
Figura 4.9	(a) Perfil utilizado na fase de treinamento da rede. (b) Perfil utilizado na fase de operação da rede. As interfaces determinadas pela rede estão marcadas com círculos escuros.	62
Figura 4.10	Instantes do treinamento da rede neuronal para o poço w991. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas esta marcada com cruze e a linha cheia, representa a resposta da rede. (a) 50 épocas. (b) 1 000 épocas. (c) 2 500 épocas. (d) 5 000 épocas. .	64
Figura 4.11	Determinação de interfaces em um perfil do poço w991. A figura mostra o perfil de raio gama natural, as interfaces definidas a partir do intérprete, marcadas com asteriscos e as interfaces definidas pela rede neuronal, marcadas com círculos escuros	65
Figura 4.12	Instantes do treinamento da rede neuronal para o poço w1112 No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas esta marcada com cruze e a linha cheia, representa a resposta da rede. (a) 500 épocas. (b) 1 000 épocas. (c) 2 500 épocas. (d) 4 000 épocas.	67
Figura 4.13	Determinação de interfaces em um perfil do poço w1112. A figura mostra o perfil de raio gama natural, as interfaces definidas a partir do intérprete, marcadas com asteriscos e as interfaces definidas pela rede neuronal, marcadas com círculos escuros	68
Figura 4.14	(a) Perfil utilizado na fase de treinamento da rede (w1112). (b) Perfil utilizado na fase de operação da rede (w991). As interfaces determinadas pela rede estão marcadas com círculos escuros.	69
Figura 5.1	Arquitetura básica da rede neuronal de HOPFIELD.	73

Figura 5.2	Determinação de interfaces em modelos convolucionais. (a) Mostra a distribuição ideal da propriedade petrofísica (linha tracejada) e o perfil petrofísico sintético (linha cheia). (b) Mostra a a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético convolucional (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.	80
Figura 5.3	Determinação de interfaces em modelos convolucionais com ruído. (a) Mostra a distribuição ideal da propriedade petrofísica (linha tracejada) e o perfil petrofísico sintético com ruído (linha cheia). (b) Mostra a a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético com ruído (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros. . .	81
Figura 5.4	Determinação de interfaces em modelos convolucionais. (a) Mostra a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha tracejada) e o perfil sintético de alta resolução vertical (linha cheia). (b) Mostra a a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.	84
Figura 5.5	Determinação de interfaces em modelos convolucionais. (a) Mostra a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha tracejada) e o perfil sintético de alta resolução vertical (linha cheia). (b) Mostra a a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.	85
Figura 5.6	Determinação de interfaces em modelos numéricos. (a) Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de porcentagem de potássio (linha pontilhada) e perfil de contagem total de raios gama natural (linha cheia). (B) - Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.	86

Figura 5.7	Determinação de interfaces em modelos numéricos. (a) Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de porcentagem de potássio (linha pontilhada) e perfil de contagem total de raios gama natural (linha cheia). (b) - Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.	87
Figura 5.8	Determinação de interfaces em perfil real. (a) - Mostra o perfil de alta resolução vertical - R_{xo} (linha traço-pontilhada) e o perfil de baixa resolução vertical - R_T (linha cheia). (b) - Mostra o perfil de baixa resolução vertical - R_T , as interfaces definidas pelo interprete, marcadas com asteriscos e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos.	89
Figura 6.1	Representação gráfica idealizada do perfil de densidade versus o perfil sônico	92
Figura 6.2	Representação gráfica idealizada do perfil de densidade versus o perfil neutrônico	93
Figura 6.3	Gráfico M-N (modificado, SCHLUMBERGER, 1988)	94
Figura 6.4	Rede neuronal direta com camada competitiva, mostrando as conexões laterais inibitórias para um dos neurônios desta camada	96
Figura 6.5	Função tipo chapéu mexicano das conexões laterais.	97
Figura 6.6	Rede neuronal direta, com camada competitiva, para a simulação do comportamento do intérprete na análise do gráfico M-N. Mostra-se as conexões laterais apenas para o neurônio de número 5.	100
Figura 6.7	Gráfico M-N, sobre o qual a rede neuronal realizará a sua classificação.	102
Figura 6.8	(A) - Perfil de raios gama natural. (B) Análise de testemunhos. (C) - Classificação mineralógica realizada pela rede neuronal.	103
Figura 7.1	Arquitetura de rede neuronal artificial para a determinação de um datum em um perfil de poço. (LUTHI et al, 1995)	107
Figura 7.2	Arquitetura de rede neuronal para a correlação poço-a-poço de uma camada.	109
Figura 7.3	Modelo geológico sintético I, perfilado nos poços I, II e III. (modificado de PANTUZZO, 1996)	111

Figura 7.4	Treinamento da rede neuronal. Nesta figura, no eixo horizontal estão marcadas as profundidades do intervalo de perfil adotado para o treinamento e no eixo vertical mostra-se a resposta da rede. O trecho do perfil de treinamento é marcado com linha tracejada, a resposta desejada esta marcada com cruces e a resposta da rede é marcada com a linha cheia. (a) 50 épocas. (b) 750 épocas. (c) 1 500 épocas. (d) 2 500 épocas.	112
Figura 7.5	Simulação da correlação poço-a-poço dos perfis de raio gama obtidos nos poços I (a), II (b) e III (c). Os círculos escuros no perfil (a) mostram as interfaces utilizadas para o treinamento da rede.	113
Figura 7.6	Simulação da correlação poço-a-poço dos perfis de raio gama contaminados com ruído, obtidos nos poços I (a), II (b) e III (c). Os círculos escuros no perfil (a) mostram as interfaces utilizadas para o treinamento da rede.	114
Figura 7.7	Modelo geológico sintético II, perfilado nos poços I, II e III. (modificado de PANTUZZO, 1996)	116
Figura 7.8	Treinamento da rede neuronal. Nesta figura, no eixo horizontal estão marcadas as profundidades do intervalo de perfil adotado para o treinamento e no eixo vertical mostra-se a resposta da rede. O trecho do perfil de treinamento é marcado com linha tracejada, a resposta desejada esta marcada com cruces e a resposta da rede é marcada com a linha cheia. (a) 50 épocas. (b) 750 épocas. (c) 1 500 épocas. (d) 3000 épocas.	117
Figura 7.9	Simulação da correlação poço-a-poço dos perfis de raio gama obtidos nos poços I (a), II (b) e III (c). Os círculos escuros no perfil (a) mostram as interfaces utilizadas para o treinamento da rede.	118
Figura 7.10	Treinamento da rede neuronal. Nesta figura, no eixo horizontal estão marcadas as profundidades do intervalo de perfil adotado para o treinamento e no eixo vertical mostra-se a resposta da rede. O trecho do perfil de treinamento é marcado com linha tracejada, a resposta desejada esta marcada com cruces e a resposta da rede é marcada com a linha cheia. (a) 50 épocas. (b) 750 épocas. (c) 2 500 épocas. (d) 4 500 épocas.	120
Figura 7.11	Simulação da correlação poço-a-poço dos perfis reais de volume de argila dos poços w1112, w991, w866. (LUTHI et al, 1995)	121
Figura 7.12	Simulação da correlação poço-a-poço dos perfis reais de volume de argila dos poços w1112, w893, w706. (LUTHI et al, 1995)	122

Figura 8.1 Fluxograma, que mostra a associação em série das redes neuronais para a produção de uma primeira aproximação para o modelo do reservatório.126

TABELAS

Tabela 4.1	Comparação das profundidades (em metros) das interfaces determinadas pelo interprete e pela rede neuronal direta para o poço w991 . . .	66
Tabela 4.2	Comparação das profundidades (em metros) das interfaces determinadas pelo interprete e pela rede neuronal direta para o poço w1112. . .	70
Tabela 5.1	Comparação das profundidades (em metros) das interfaces determinadas pelo interprete e pela rede neuronal de HOPFIELD para o poço w1112.	90
Tabela 6.1	Pontos fixos no gráfico M-N, representativos de cada neurônio da camada competitiva.	101
Tabela 6.2	Associação de números à minerais utilizada pela rede neuronal. . . .	101
Tabela 7.1	Comparação das profundidades (em metros) para a correlação poço-a-poço entre o interprete e a rede neuronal	119
Tabela 8.1	Comparação das profundidades (em metros) das interfaces determinadas pelo intérprete, pela rede neuronal direta multicamadas e rede neuronal de HOPFIELD para o poço w1112.	124

RESUMO

A análise dos perfis petrofísicos de poço aberto possui um papel de fundamental importância para os estudos geológicos e geofísicos, no que se refere a obtenção de um maior conhecimento da subsuperfície, bem como para a identificação e exploração de depósitos minerais e petrolíferos.

Alguns tópicos importantes da interpretação geológica dos perfis como a determinação de interfaces, a identificação mineralógica e a correlação poço-a-poço são extremamente tediosos e dispendem na sua execução uma grande carga horária. A automação destes procedimentos é em princípio bastante complicada, mas necessária, pois permitirá um melhor aproveitamento do tempo de trabalho do geólogo de produção e do interprete de perfis.

As redes neuronais artificiais apresentam uma boa performance para a solução destes tipos de problema, inclusive nos casos nos quais os algoritmos sequenciais apresentam dificuldades.

Mostrar-se-a nesta tese que as redes neuronais artificiais podem ser utilizadas eficientemente para a automação desses procedimentos da interpretação geológica dos perfis. Apresentamos detalhadamente as novas arquiteturas e as aplicações sobre dados sintéticos e perfis reais.

ABSTRACT

The analysis of openhole wireline logs is of great importance for the subsurface mapping of geological layers and the identification and quantification of hydrocarbon and mineral deposits. An important aspects are the determination of geological boundaries, the mineralogical identification and the well-to-well correlation, which can be a tedious and time-consuming task for the geologist.

Automating this procedure is complicated but potentially rewarding because it may save the production geologist and log analyst substantial amounts of time.

Artificial neural networks have been shown to handle this task efficiently including in cases where sequential algorithms have problems.

We show in this thesis that neural networks can be used to determine layer boundaries, the mineralogical identification and the well-to-well correlation, on well logs, and we present the new networks architectures. These procedures are tested on synthetic as well as actual field data.

1 - INTRODUÇÃO

A análise dos perfis petrofísicos de poço aberto (não revestido) possui um papel de fundamental importância para os estudos geológicos e geofísicos, no que se refere a obtenção de um maior conhecimento da subsuperfície, bem como para a identificação e exploração de depósitos minerais e petrolíferos.

O intenso avanço tecnológico experimentado nos últimos anos pela perfilagem de poço devido ao incremento do número de sensores nas ferramentas, à melhoria das técnicas de aquisição e da qualidade dos dados de perfil, possibilitou que a perfilagem de poço viesse a suprir as necessidades de informações de subsuperfície, requisitadas principalmente pela indústria do petróleo. Por outro lado, a disponibilidade de um grande volume de dados ocasionou, que a tarefa da interpretação geológica dos perfis se tornasse expressivamente lenta e onerosa. Isto resulta em uma subutilização dos dados de perfil disponíveis, da feita que a interpretação geológica dos perfis é realizada visualmente, resultando na necessidade de que a tomada de decisão sobre um evento de natureza geofísico-geológico, mesmo nas situações mais simples, fosse realizada exclusivamente a partir de um intérprete altamente especializado, dotado de profundo conhecimento geológico da área em questão.

A expressão *tomada de decisão* será aqui entendida como sendo o estabelecimento da correspondência existente entre o dado geofísico registrado no perfil de um poço e o evento geológico em subsuperfície que o originou. Este processo é o cerne da interpretação geológica dos perfis petrofísicos, sendo de natureza essencialmente empírica, envolvendo naturalmente um processo mental de decisão do intérprete, em função do seu conhecimento e da sua visão geológica. Sob outro ponto de vista, a tomada de decisão do intérprete de perfis pode ser entendida como um caso particular de um problema de decisão mais geral que é o de reconhecimento de padrão (*pattern recognition*), o qual por sua vez é cotidianamente realizado de forma rotineira pelo sistema visual humano; por exemplo, a identificação da presença de uma certa pessoa conhecida na multidão, a leitura de uma carta ou a interpretação de perfis petrofísicos. Todavia, essas tarefas simples apresentam inúmeras dificuldades para a sua execução automática através do processamento sequencial nos computadores digitais.

Alguns autores têm se interessado pela formulação de estratégias que possibilitem uma simulação computacional do sistema visual humano para a execução do reconhecimento de padrões aplicados particularmente para a interpretação geológica dos perfis, estabelecidas em

duas linhas de pesquisa distintas, que são:

1. A inteligência artificial, por meio dos sistemas especialistas
2. A computação conexionista, por meio das redes neuronais artificiais.

Os sistemas especialistas são formados por um extenso banco de dados e um conjunto finito de regras na forma de um programa heurístico, que segue um processo dedutivo com base nas informações contidas no banco de dados, seguindo o direcionamento das regras pré-estabelecidas, ou ditas, de bom julgamento. Similar ao especialista humano, no qual o sistema é inspirado, não há garantias *a priori* da exatidão dos seus resultados. KUO & STARTZMAN (1987) desenvolveram um sistema especialista aplicado a perfilagem de poço, o qual efetua um zoneamento ou uma divisão do perfil em seções (janelas), que apresentam diferenças em relação a sua vizinhança, com base em um banco de dados composto por um conjunto de formas geométricas conhecidas de perfil e a partir de regras de semelhança estabelecidas por um intérprete, estas janelas serão posteriormente associadas às camadas geológicas atravessadas pelo poço.

No campo da computação conexionista, através das redes neuronais artificiais, os trabalhos realizados mostraram que as redes neuronais apresentam uma boa adaptação para a solução de problemas envolvendo o reconhecimento de padrões aplicados à perfilagem de poço. BALDWIN et al (1989a) desenvolveram uma arquitetura de rede neuronal para a obtenção da análise mineralógica das camadas geológicas através dos dados de perfis, baseada no paradigma da organização própria (*self organization paradigm*). BALDWIN et al (1989b) apresentaram uma arquitetura de rede neuronal, desenhada sob o paradigma da organização própria, aplicada à correlação das curvas geradas pela ferramenta medidora de mergulho (*dipmeter*) e pela ferramenta sônica com registro completo da onda compressional. BALDWIN et al (1989c) mostraram uma arquitetura de rede neuronal, projetada sob o paradigma da organização própria, para a determinação da densidade da matriz e da porosidade das rochas a partir das informações do perfil. BALDWIN (1991) utilizou uma rede neuronal associativa bidirecional (BAM) para a identificação de facies litológicas em perfis obtidos em uma seqüência deposicional siliciclástica. BUCHEB (1991) utilizou uma rede neuronal associativa bidirecional (BAM) sobre dados sintéticos de perfil para a identificação de eletrofácies. RUI-LIN et al (1992) utilizaram uma arquitetura de rede em cascata, sob o paradigma da retro-propagação do erro (*error back-propagation*), adotando para o treinamento da rede de uma janela móvel ao longo do perfil, com o objetivo de promover uma classificação litológica do trecho de perfil em estudo. WANG et al. (1994) apresentaram uma arquitetura com três camadas de elementos processadores treinados sob o paradigma

da retro-propagação do erro para a identificação de intervalos dos perfis de poço em função da litologia da rocha. ZHOUBO et al. (1994) utilizaram uma arquitetura de rede neuronal direta com três camadas de elementos processadores treinados sob o paradigma da retro-propagação do erro a partir da determinação a priori de funções probabilísticas da presença de zonas fraturadas, com base na resposta de diversos perfis, para a determinação da presença de fraturas em rochas metamórficas. ANDRADE & LUTHI (1995) apresentaram uma arquitetura de rede neuronal, tipo Hopfield, para a determinação de interfaces em perfis. GONÇALVES et al. (1995) utilizaram uma arquitetura de rede neuronal direta treinada sob o paradigma da retro-propagação do erro, para a caracterização da crosta oceânica. LUTHI et al. (1995) utilizaram uma arquitetura de rede neuronal direta treinada sob o paradigma da retro-propagação do erro, para a correlação estratigráfica automática de perfis a partir do treinamento da rede neuronal sobre um marco estratigráfico definido previamente pelo intérprete em um poço tomado como referência, com a posterior aplicação da rede treinada para a identificação deste marco nos perfis dos outros poços da área.

O objetivo do presente trabalho se insere neste contexto, que é o de buscar um método eficiente, tal que possibilite a simulação computacional do comportamento visual do intérprete de perfil através da automação do seu processo de tomada de decisão em situações simples da interpretação geológica dos perfis petrofísicos, visando em última análise preservar o conhecimento especializado do intérprete para os casos complexos, nos quais o seu conhecimento será, efetivamente, melhor aproveitado. O método aqui apresentado se baseia na aplicação de um processo computacional, relativamente novo, conhecido como redes neurais artificiais, estabelecendo-se para cada caso uma arquitetura de rede conveniente e que viabilize a sua utilização sobre os dados de perfil para a automação dos processos de tomada de decisão do intérprete; entendido aqui como um processo de reconhecimento de padrões, para algumas das atividades que fazem parte do cotidiano da interpretação dos perfis petrofísicos.

Neste sentido, apresenta-se no CAP. I um breve resumo sobre a perfilagem geofísica de poço aberto, donde se originam os perfis petrofísicos de poço, que são os dados objeto da aplicação dos métodos aqui apresentados. Nos deteremos em um perfil particular, gerado pela ferramenta de espectrometria de raios gama natural, mostrando os seus fundamentos físicos e um resumo do seu modelamento numérico, uma vez que este é o perfil sintético sobre o qual as arquiteturas de redes neurais aqui propostas foram analisadas e testadas.

No CAP. II apresenta-se um resumo da computação conexionista por meio das redes neurais artificiais, com ênfase em um tipo particular de rede neuronal, que tem sido especialmente utilizada para o reconhecimento de padrões, conhecida por rede neuronal direta multicamadas, treinada com o algoritmo da retro-propagação do erro.

No CAP. III mostra-se a primeira aplicação da automação da tomada de decisão do intérprete de perfis, que é a determinação em profundidade dos contatos litológicos, referidos aqui como *interfaces*, tomadas como superfícies fictícias planas, de separação entre dois eventos vizinhos, com diferentes significados geofísico-geológicos. Apresenta-se a automação do processo de tomada de decisão do intérprete para a determinação das interfaces, por meio de uma rede neuronal do tipo direta multícadas treinada com o algoritmo da retro-propagação do erro. Neste caso, estabelece-se uma arquitetura de rede neuronal, a qual denominou-se de arquitetura na forma vetorizada, visando a otimização do processo de treinamento da rede neuronal.

No CAP IV realiza-se um outro experimento com as redes neuronais artificiais para a automação da tomada de decisão do intérprete para a determinação das interfaces, desta feita, apresenta-se uma rede neuronal do tipo recorrente, conhecida por rede neuronal de Hopfield. Realiza-se a sua utilização a partir da definição de uma função objeto, característica do problema, associada com a função energia, que descreve o comportamento dinâmico da rede neuronal.

No CAP. V apresenta-se uma segunda aplicação em outra situação bastante comum da interpretação geológica dos perfis, que é a identificação de litologias a partir da determinação do mineral essencial, ou o principal componente mineralógico de uma unidade rochosa atravessada pelo poço. Para tanto, mostra-se uma arquitetura de rede neuronal caracterizada pela presença de uma camada competitiva (*competitive layer*) associada a um processo gráfico bastante utilizado pelos intérpretes para a determinação de litologias, conhecido por gráfico M-N (*M-N plot*).

No CAP. VI apresenta-se uma terceira aplicação das redes neuronais artificiais na interpretação geológica dos perfis, que é a correlação estratigráfica poço-a-poço, a partir da identificação de uma sequência de interfaces (*datuns*) em um poço tomado como referência e, posteriormente, a indentificação desses datuns em outros poços da bacia sedimentar por meio de um rede neuronal direta multícada, treinada com o algoritmo da retro-propagação do erro, apresentando a mesma arquitetura de rede na forma vetorial, apresentada no CAP.III, mas com um diferente conjunto de treinamento. Para esta tarefa da interpretação de perfis, devido à sua complexidade em termos geológicos, somente tratamos da possibilidade de automação desse procedimento para casos bastante simples.

No CAP. VII efetua-se uma análise geral do método apresentado, enfatiza-se a sua aplicabilidade prática no auxílio ao intérprete e sugeriu-se ainda alguns avanços e trabalhos futuros.

2 - PERFILAGEM GEOFÍSICA DE POÇO ABERTO

Neste capítulo procura-se fornecer uma visão geral sobre a perfilagem geofísica de poço aberto. Apresenta-se um breve histórico e mostra-se a forma de obtenção do dado geofísico de poço ou dado de perfil. Enfatiza-se os conceitos de sonda e perfil e as suas aplicações geológicas. A última seção é devotada ao perfil de espectrometria de raio gama natural (*spectral natural gamma-ray*), uma vez que este perfil será utilizado nos demais capítulos, como dado sintético obtido através de modelamento numérico.

2.1 INTRODUÇÃO

Na maioria das vezes, mesmo após a perfuração de um poço, é bastante difícil a constatação direta da presença de hidrocarbonetos nas camadas rochosas em subsuperfície atravessadas pelo poço. Para a identificação dos vários tipos de rochas perfuradas, localizar aquelas possíveis armazenadoras de hidrocarbonetos e avaliar o seu significado econômico, necessita-se de várias e precisas informações que podem ser adquiridas de muitas maneiras, como resumido abaixo:

1. A natureza dos fluidos de subsuperfície pode ser investigada através da análise do fluido de perfuração. Este procedimento recebe o nome de perfilagem de lama (*mud logging*), sendo especialmente indicado para a informação da presença de gás ou óleo.
2. Amostras das rochas cortadas pela broca de perfuração, durante as operações de construção do poço, são recuperadas na superfície por meio da circulação da lama (*mud logging*), fornecendo informações sobre as litologias atravessadas e presença de hidrocarboneto.
3. A retirada direta de amostras cilíndricas da rocha intacta, operação chamada de testemunhagem, a qual produz a informação sobre a litologia e textura das rochas perfuradas e também sobre a ocorrência de hidrocarboneto.

A perfilagem geofísica de poço aberto (*well logging, borehole geophysics*) produz um conjunto contínuo de medidas físicas da formação rochosa, apresentando as vantagens de menor custo, maior precisão e maior rapidez de operação do que a testemunhagem. Além disso,

se considerarmos as ocorrências de rochas inconsolidadas, onde é impossível a obtenção de testemunhos, os perfis são a única forma de obtenção de informação sobre a presença e principalmente sobre a quantificação de hidrocarboneto nas rochas em subsuperfície. Desse modo, a perfilagem geofísica de poço aberto é capaz de produzir com boa qualidade de detalhes as variações físicas ocorridas ao longo das formações rochosas atravessadas pelo poço, definindo ainda os potenciais intervalos em profundidade, constituídos por rochas armazenadoras de hidrocarbonetos e indicando a sua potencialidade econômica.

2.2 BREVE HISTÓRICO

A perfilagem geofísica de poço aberto teve seu início a partir da ideia pioneira de Conrad Schlumberger de utilizar técnicas convencionais da geofísica de superfície para a detecção de corpos metálicos em poços perfurados. Em 1927, na cidade de Pechelbronn, França, foi pela primeira vez utilizado o conceito de eletrorresistividade aparente em poços, a partir da utilização de um arranjo de eletrodos (arranjo Schlumberger) utilizado originalmente para a realização de caminhamentos elétricos em superfície (na horizontal), como mostrado na Figura 2.1. O resultado das suas medições de eletrorresistividade foram apresentadas a cada metro, na forma de uma curva discreta com a profundidade, produzindo, então, o primeiro perfil elétrico realizado em um poço.

A medida que as pesquisas de hidrocarbonetos se desenvolveu foram introduzidas novas ferramentas. Assim, em meados dos anos cinquenta, a perfilagem com sondas elétricas chegou a sua maturação. A introdução da ferramenta de indução (DOLL, 1949), utilizada para poços perfurados com lamas resistivas, das de microresistividade (DOLL, 1950), que possuíam dispositivos de medição que permanecem extremamente próximos a parede do poço efetuando medidas de resistividade rasa. Logo após foram introduzidas as sondas focalizadas (DOLL, 1951), que produziam uma melhor definição dos limites das camadas. Culminando com o lançamento dos trabalhos de ARCHIE de 1942 que estabeleceram a dependência entre a resistividade da rocha virgem (R_t) e a sua porosidade (ϕ) com a sua saturação de água (S_w), sintetizados na expressão

$$R_t = \frac{a}{\phi^m} \frac{R_w}{S_w^n} \quad (2.1)$$

Na equação 2.1, conhecida como *formula de Archie*, R_w é a resistividade da água da formação, a é chamado de coeficiente litológico, m é o coeficiente de cimentação, e n é o coeficiente de saturação geralmente igual a 2.

Os métodos radioativos e acústicos se desenvolveram a partir dos anos quarenta e se tornaram aceitos na indústria do petróleo nos anos cinquenta. A detecção da radiação gama

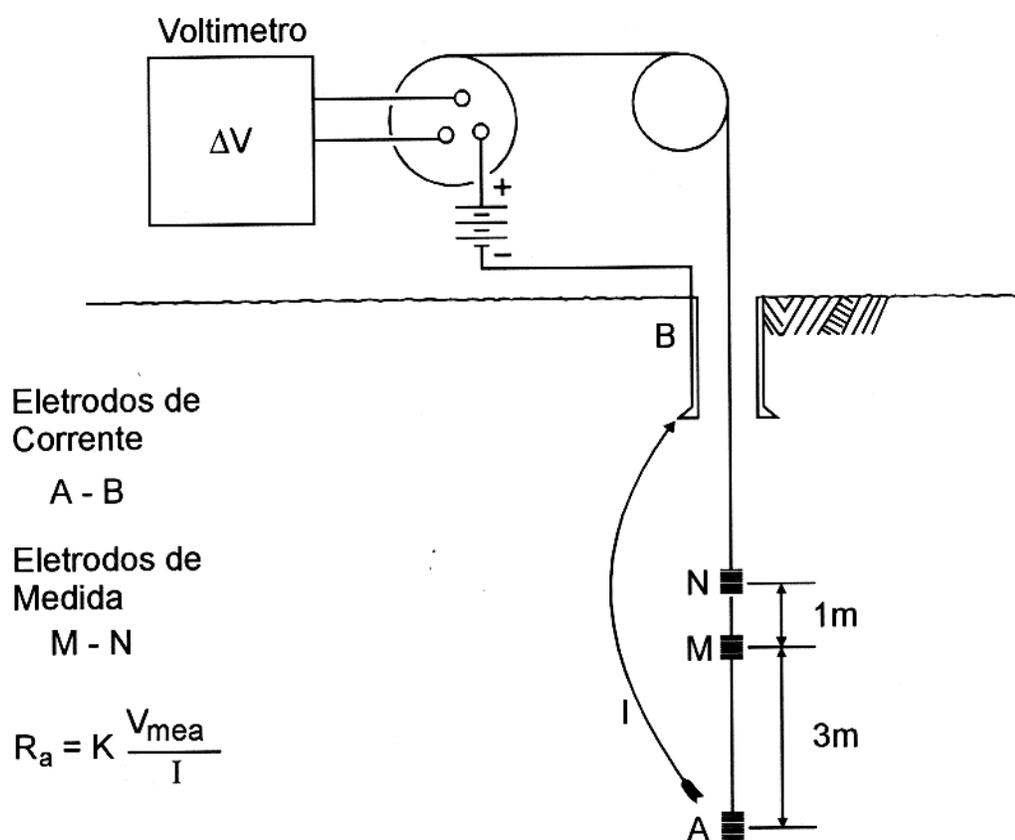


Figura 2.1 - Arranjo Schlumberger utilizado na perfilagem vertical. O equipamento de registro na superfície era desligado a cada deslocamento do arranjo com a profundidade. R_a é a resistividade aparente, K é uma constante que depende da geometria do arranjo, V_{mea} é a voltagem medida e I a intensidade de corrente. (Modificado de LABO, 1987).

(γ - ray), natural ou induzida, foi utilizada para a avaliação do conteúdo radioativo, da densidade da matriz e da porosidade das rochas. A velocidade de ondas acústicas compressionais foi utilizada para a avaliação da porosidade das rochas.

A perfilagem de poço foi inicialmente desenvolvida para a indústria do petróleo, mas os seus métodos vem sendo aplicados em outras atividades, como avaliações geológicas, indústria do urânio e minerais radioativos, na indústria do carvão mineral e na água subterreânea. Aplicações para a mineração e geotécnia apresentam ainda algumas limitações (ELLIS, 1987).

2.3 O PERFIL DE POÇO

A obtenção de um perfil de poço (*wireline log or well log*), ou a medição dos parâmetros físicos da rocha (petrofísicos), se inicia a partir da descida até o fundo do poço de uma complexa aparelhagem, chamada sonda de perfilagem, que é a responsável pela realização das medidas quando se desloca em movimento ascensional.

Os fenômenos físicos mensurados podem ser passivos ou naturais, como a radiatividade natural, o potencial espontâneo e a temperatura, ou causados diretamente pela presença da sonda, que interfere diretamente no estado natural da rocha, através da indução de uma perturbação de natureza física e o posterior registro da resposta da formação a essa perturbação, como a eletrorresistividade, o tempo de trânsito de ondas mecânicas, a densidade e a quantidade de hidrogênio.

Os sinais captados pelos sensores são enviados à superfície por meio de um sistema telemétrico. Esses sinais são posteriormente captados por equipamentos de registro e processamento localizados em um caminhão laboratório, como mostrado na Figura 2.2. Os parâmetros petrofísicos são, então, lançados em um gráfico de profundidade, dando origem ao perfil geofísico de poço aberto.

Em função do volume de rocha investigado pela sonda de perfilagem, os perfis geofísicos podem ser classificados como:

1. Perfil de Baixa Resolução vertical: Produzido por uma sonda de investigação profunda, na qual o volume de rocha investigado fica em torno de três metros cúbicos da formação rochosa que envolve a sonda. Esta aparelhagem busca medir os parâmetros físicos da rocha virgem, ou seja aquela cujos fluidos contidos em seus poros não foram contaminados pela lama de perfuração. Em consequência, ela produz um perfil com fraca definição dos contatos litológicos.

2. Perfil de Alta resolução Vertical: É aquele gerado por uma sond de investigação rasa, na qual o seu volume de investigação é expressivamente menor, da ordem de dezenas de centímetros cúbicos. Neste caso se intensiona mensurar as propriedades da região próxima ao poço, contaminada pela lama de perfuração (zona invadida) e com isto produzindo um perfil com boa definição dos contatos litológicos.

2.4 APLICAÇÕES GEOLÓGICAS

Os perfis de poço são comumente utilizados na interpretação geológica de subsuperfície. Inicialmente os perfis foram utilizados apenas de forma qualitativa para a confecção de seções geológicas, correlacionando padrões similares nas curvas de resistividade elétrica e de raios gama natural de poços vizinhos (HEARST & NELSON, 1985; DOVETON, 1986). Com o avanço tecnológico das técnicas de transmissão e processamento de dados e com o desenvolvimento das ferramentas de perfilagem, várias outras aplicações foram sendo realizadas, principalmente aquelas de caráter quantitativo (ELLIS, 1987), aplicadas diretamente à avaliação de formação que é a determinação do potencial de produção de hidrocarbonetos de uma determinada camada.

De forma bastante simplificada podemos resumir a avaliação de formação analisando a expressão 2.1, aplicando-a a um intervalo de profundidades onde a rocha armazene alguma quantidade de hidrocarboneto, expresso pela sua saturação $S_o = 1 - S_w$. A expressão 2.1 fornece diretamente a saturação de água da formação nesta profundidade, a partir do conhecimento da resistividade da formação não afetada pela existência do poço (zona virgem), R_t . Esta informação é fornecida por um perfil gerado por uma ferramenta elétrica de investigação profunda. A informação da resistividade da água, R_w , em um intervalo totalmente saturado por água é obtida em testes de laboratório com a água colhida diretamente da rocha nos testes de formação. A informação de porosidade, ρ , pode ser fornecida por um dos três perfis de porosidade (sônico, densidade ou neutrônico). Os parâmetros a , m e n , serão obtidos em laboratório, da experiência sobre a área, ou através dos próprios perfis (NERI, 1990).

2.5 PERFIL DE ESPECTROMETRIA DE RAIOS GAMA NATURAL

A maioria dos elementos são encontrados na natureza em uma variedade de isótopos. Muitos destes isótopos são instáveis e decaem para uma forma mais estável através da emissão de várias formas de radiação. As partículas- α (núcleo do He) e a radiação β (eletron) possuem uma pequena distância de penetração; por isto, apenas apresentam interesse acadêmico para

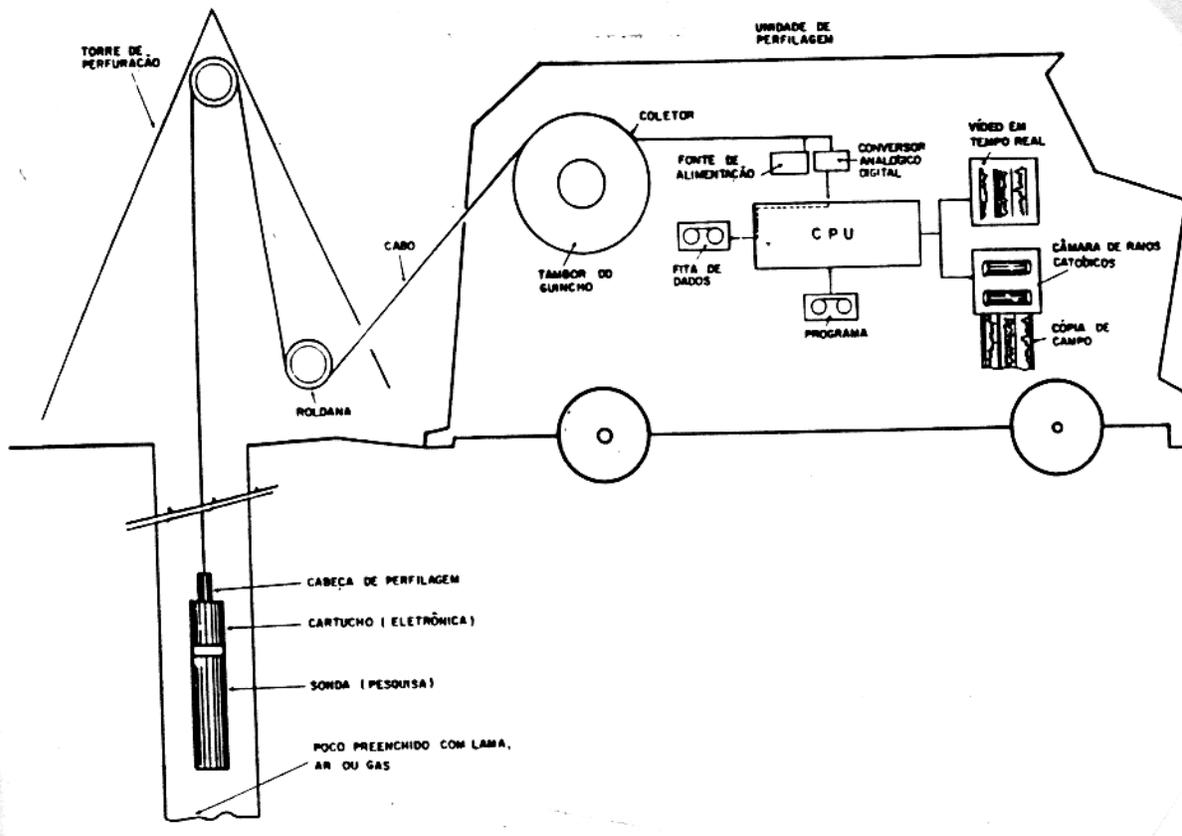


Figura 2.2 - Diagrama da aparelhagem de aquisição das medidas geofísicas realizadas em um poço.

a perfilagem de poço (DOVETON, 1986). No entanto os raios gama (γ - ray), que possuem uma grande profundidade de penetração, são de grande interesse comercial (ELLIS, 1987).

2.5.1 Radioatividade Natural das Rochas

De modo geral, a radioatividade das rochas depende da quantidade de elementos radioativos presentes na sua constituição. Existem três séries, ou famílias, de elementos radioativos de interesse, onde cada um desses elementos emitem radiação gama com contagem e energia distintos. Estas famílias são as seguintes:

1. Urânio-Rádio: Elemento Bismuto (Bi^{214} ; 1,765 MeV) filho da desintegração do Urânio (U^{238}).
2. Tório: Elemento Tálío (Tl^{208} ; 2,62 Mev) filho da desintegração do Tório (Th^{232}).
3. Potássio: K^{40} com energia de 1,46 Mev.

Qualquer elemento radioativo ocorre originalmente nas rochas ígneas, os quais durante os processos de erosão e transporte dos fragmentos, são espalhados e posteriormente depositados na água do mar ou como constituintes das rochas sedimentares. As rochas sedimentares que apresentam o maior acúmulo de elementos radioativos são as argilas e/ou folhelhos, devido à sua capacidade de reter ions metálicos (Urânio e o Tório) e apresentarem naturalmente em sua composição uma grande quantidade de Potássio.

2.5.2 Perfil de Espectrometria de Raios Gama Natural

O perfil de espectrometria de raios gama natural permite o registro individual das concentrações de cada elemento radioativo, componente da radiação gama total emitida pela rocha. Para um tipo de ferramenta, a relação entre as concentrações de cada um dos elementos radioativos e a radiação gama total em unidades API é dada aproximadamente (ELLIS, 1987) por

$$\gamma_{API} = 4Th + 8U + 16K, \quad (2.2)$$

aonde o U e o Th são medidos em ppm e o K em porcentagem por peso. A expressão 2.2 mostra, por exemplo, que um arenito argiloso contendo um mineral rico em potássio, como a mica ($K(Mg, Fe)_3(AlSi_3O_{10})(OH_2)$), poderia ter o seu conteúdo de argila, estimado pelo perfil de raio gama natural, interpretado erroneamente. Um falso volume de argila seria

interpretado como resultado do valor de raios gama adicional proporcionado pela presença da mica. Neste caso o perfil de espectrometria de raios gama natural, daria a informação correta a respeito do excesso de potássio o que por sua vez é indicativo da presença de um mineral rico neste elemento.

2.5.3 O Modelamento Numérico do Perfil de Espectrometria de Raios Gama Natural

Para simular as resposta da ferramenta de espectrometria de raios gama natural, SILVA (1993) desenvolveu um algoritmo de elementos finitos, que calcula o transporte da radiação gama na forma de fluxo escalar $2\ 1/2D$, a partir da solução numérica da aproximação de difusão para multigrupos da equação de transporte de Boltzmann, onde a variável direção é expandida em termos dos polinômios ortogonais de Legendre. Desta forma, o fluxo dependerá apenas da variável espacial e das propriedades físicas da formação, segundo o modelo denominado convolucional, dado por

$$n(\hat{E}) = \int_{\Delta\hat{E}} G(\hat{E}, E) \Phi(E) dE. \quad (2.3)$$

Na expressão 2.3, $\Phi(E)$ é o fluxo escalar da radiação para a energia E , $G(\hat{E}, E)$, representa a função resposta do detector do canal correspondente à energia \hat{E} devido a uma fonte monoenergética E distante aproximadamente de um livre percurso médio da face lateral do detector e $n(\hat{E})$ é o espectro de altura de pulso do arranjo considerado.

O método de soluções por elementos finitos implica em dividir o domínio da solução em um número finito de subdomínios mais simples, dispostos na forma de uma malha em que cada subdomínio é representado por um elemento dessa malha interligados por nós e utilizar conceitos variacionais para construir uma boa aproximação da solução sobre essa malha.

O algoritmo de SILVA (1993) calcula o fluxo escalar de raios gama, descrito na equação 2.3 ao longo de cada modelo, utilizando uma única malha de elementos triangulares. A função do fluxo escalar é aproximada no interior de cada elemento, em termos de uma função de interpolação na forma de funções base, adotando a estratégia de Galerkin.

Para a simulação dos perfis de K , U e Th por esse algoritmo é necessário informar sobre a geometria das camadas atravessadas pelo poço (espessura e profundidade) e sobre as frações volumétricas mineralógicas.

3 - REDES NEURONAIS ARTIFICIAIS

3.1 INTRODUÇÃO

A computação conexionista através das redes neuronais tem sido motivada pelo reconhecimento de que o cérebro humano opera de maneira inteiramente diferente dos computadores digitais convencionais. Assim, a idéia fundamental envolvida com as redes neuronais artificiais é a de simular, através de algoritmos, o comportamento do cérebro humano, quando este opera na solução de problemas triviais, que por sua vez apresentam um tratamento bastante complexo e oneroso nos computadores convencionais, operando sob o paradigma de von Neumann.

O cérebro pode ser compreendido como um sistema de tratamento de informações altamente complexo, não linear e paralelo. Ele possui a capacidade de organização dos seus neurônios de forma a realizar certos processos (reconhecimento de padrões, percepção visual e auditiva, controle motor) muitas vezes mais rápido e melhor do que o mais moderno dos computadores (HAYKIN, 1994). Uma típica célula nervosa, o *neurônio*, é cinco ou seis ordens de grandeza mais lento do que um *chip* de silício, onde os eventos ocorrem na ordem de 10^{-9} segundos, enquanto um evento nervoso é da ordem 10^{-3} segundos. No entanto, o cérebro, apesar da aparente lentidão de operação de um neurônio, contorna esta deficiência através de sua estrutura extremamente eficiente, baseada em uma intensa interconexão dos neurônios. Estima-se, que o cérebro humano possua da ordem de uma dezena de bilhões de neurônios, interligados por sessenta trilhões de conexões (SHEPHERD & KOCH, 1990).

O neurônio é a unidade celular fundamental do sistema nervoso e em particular do cérebro humano (Figura 3.1). Seu núcleo é composto por uma simples unidade processadora, a qual recebe e combina sinais oriundos de muitos outros neurônios através de ligações chamadas dendritos (caminhos de entrada). Se o sinal é forte o suficiente, ele ativa o neurônio, o qual produz um sinal de saída. O caminho do sinal de saída é chamado de axônio. Toda essa transferência de informação é de natureza eminentemente eletroquímica e capaz de produzir correntes elétricas mensuráveis. O axônio (caminho de saída) de um neurônio se divide inúmeras vezes e conecta-se aos dendritos dos outros neurônios através de conexões chamadas sinapses. A transmissão através dessa junção é de natureza química e a quantidade de informação transferida depende unicamente da força desta ligação. A força da ligação

sináptica é exatamente o que é modificado quando o cérebro aprende, no sentido de adquirir uma melhor compreensão a respeito do seu meio exterior. Assim, as sinapses podem ser consideradas como as unidades básicas de memória do cérebro (AMAREL, 1968) e são as responsáveis pela mediação das interações entre os neurônios. A operação normal das sinapses ocorre por meio de dois processos. No primeiro, chamado pré-sináptico, é liberada uma substância transmissora, que se difunde através da junção entre os neurônios e atua então, sobre o segundo processo (pós-sináptico). Desta forma, a sinapse converte um sinal elétrico pré-sináptico em um sinal químico e após isto ocorre a conversão do sinal químico novamente em um sinal elétrico pós-sináptico (SHEPHERD & KOCH, 1990).

3.2 REDES NEURONAIS ARTIFICIAIS

A capacidade cerebral de pensar, relembrar e solucionar problemas tem inspirado em muitos cientistas o desejo de modelar artificialmente essas operações nos convencionais computadores digitais. O modelo computacional que imita o comportamento cerebral, de um modo extremamente simplificado, resulta no estudo das redes neuronais artificiais.

Poderia se conceituar uma rede neuronal artificial (ALEKSANDER & MORTON, 1990) na forma:

Uma rede neuronal é um processamento distribuído e paralelo, que possui uma propensão natural para armazenar conhecimento e tornar-lo passível de utilização. Estas características lembram vagamente o cérebro humano em dois aspectos:

- 1. A aquisição de conhecimento é realizada através de um processo de aprendizagem.*
- 2. A força das conexões interneurônios, conhecidas como pesos sinápticos, são utilizadas para o armazenamento do conhecimento.*

Em uma rede neuronal artificial, a unidade análoga ao neurônio bioquímico é referida como o neurônio artificial (ou simplesmente neurônio ou elemento processador). Um neurônio característico possui inúmeros caminhos de entrada e, normalmente, um único caminho de saída. O seu funcionamento básico é o de promover uma combinação linear dos sinais de entrada, que posteriormente serão modificados por meio de uma função, referida como a função de ativação. O valor de saída desta função é geralmente passado diretamente para o caminho de saída do neurônio. As redes neuronais artificiais expressam o impulso elétrico de saída em um neurônio natural, como um simples número, representando a atividade do neurônio. O caminho de saída de um neurônio pode se conectar aos caminhos de entrada de

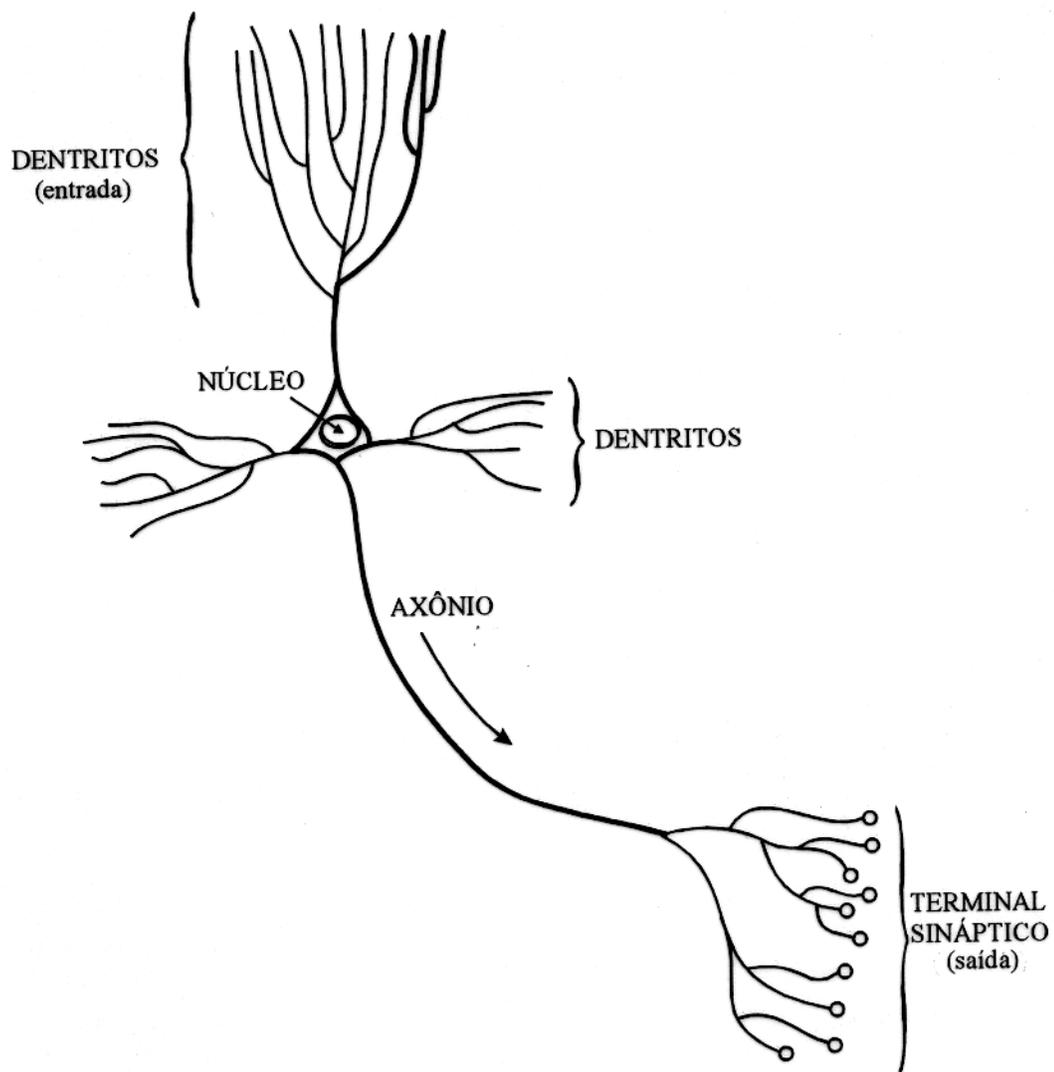


Figura 3.1 - Neurônio bioquímico, exemplificado por uma célula nervosa do tipo piramidal

outros neurônios, estas conexões são chamadas sinapses artificiais (ou sinapses). A função da sinapse é modelada por um valor de peso modificável, o qual é associado a cada conexão. Deste modo, a arquitetura das redes neuronais artificiais não reflete a detalhada e complexa geometria dos dendritos e axônios biológicos (AMAREL, 1968).

Uma rede neuronal artificial, como na Figura 3.2, consiste de um grande número de neurônios que são arranjados em grupos e que recebem a designação de *camadas*. As camadas são dispostas de forma ordenada, segundo o sentido do fluxo de informações. Os neurônios pertencentes a uma determinada camada podem se conectar a todos ou aleatoriamente a alguns dos neurônios da camada vizinha. A camada aonde chegam as informações externas é chamada de *camada de entrada*. A camada que libera informações do interior da rede para o exterior é conhecida por *camada de saída*. As camadas intermediárias, isto é, que se encontram entre as duas anteriores, recebem a designação genérica de *camadas escondidas ou camadas ocultas*, uma vez que os estados dos neurônios que as constituem não são visualizados do exterior.

Para a construção das redes neuronais artificiais deve-se determinar como os neurônios serão interligados e definir os valores dos pesos sinápticos adequadamente. Estes determinarão como um neurônio influenciará em todos os demais a ele conectados. O comportamento das redes neuronais artificiais depende tanto dos pesos sinápticos como da função de ativação, que é a responsável pela manutenção do valor do sinal de saída dos neurônios no interior de um intervalo definido. A função de ativação pode ser específica para cada neurônio ou para cada grupo de neurônios.

Existem duas fases principais na computação de uma rede neuronal, que são a de *treinamento* ou *aprendizagem* e a de *operação*. Na fase de *aprendizagem* se processa a adaptação dos seus pesos sinápticos em resposta a um estímulo externo apresentado à sua camada de entrada e a resposta desejada mostrada à camada de saída. Neste caso, a fase de treinamento é dita supervisionada, uma vez que é necessário a presença de um agente externo que forneça a resposta desejada da rede. Se a saída desejada é diferente da entrada, a rede neuronal é referida como heteroassociativa. Se para todo o conjunto de treinamento a resposta desejada é igual à entrada, a rede neuronal é dita autoassociativa. Se a resposta desejada não é apresentada à camada de saída, a rede neuronal é dita de aprendizagem não supervisionada. Independente do tipo de treinamento, uma característica essencial de qualquer rede neuronal é sua regra de aprendizagem, a qual especifica como os pesos sinápticos serão adaptados em resposta a um exemplo do conjunto de dados de treinamento. Sempre, o treinamento requer a apresentação de muitos exemplos à rede neuronal um grande número de vezes.

A fase de *operação* se refere à maneira como a rede neuronal globalmente processa os

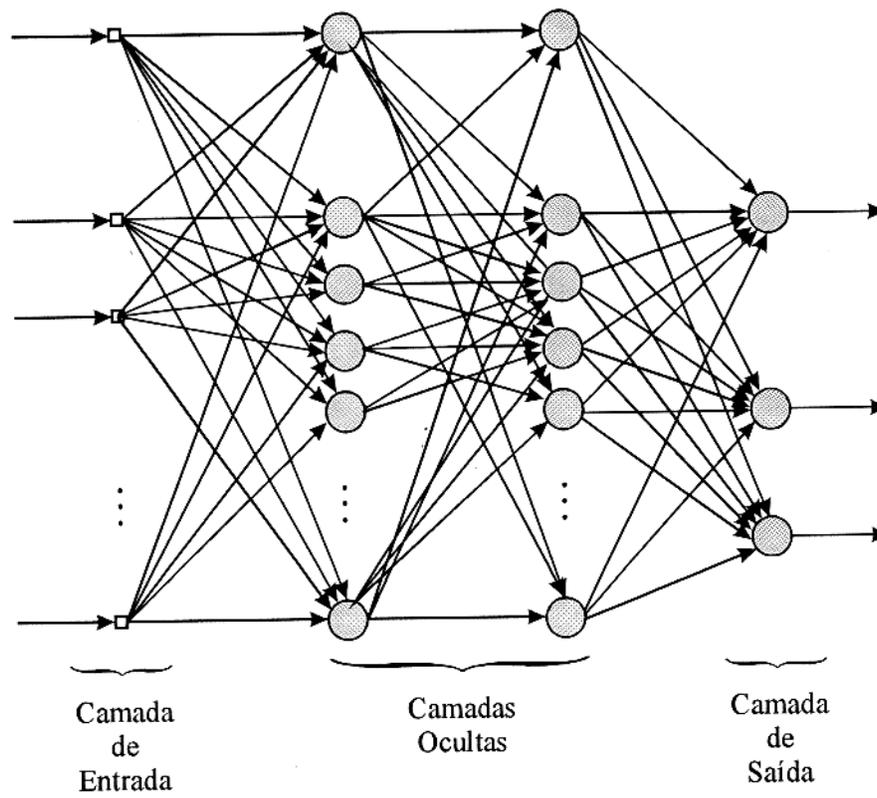


Figura 3.2 - Rede neuronal artificial típica.

estímulos apresentados à sua camada de entrada e cria uma resposta na sua camada de saída. A forma mais simples de operação de uma rede neuronal é aquela onde o sinal apresentado à camada de entrada segue de forma direta passando pelas camadas ocultas até a camada de saída, camada por camada. Tal tipo de rede é conhecida pelo nome de rede neuronal direta (*feedforward neural network*). Se existem conexões de retorno, que ligam camadas posteriores a camadas anteriores, a informação reverbera entre as camadas, até que alguma convergência seja encontrada e a informação é, então, passada para a camada de saída. Tais redes são chamadas de recorrentes (*recurrent neural network*).

Outra consideração importante no comportamento de uma rede neuronal é o seu modo de operação, se sincronizado ou não sincronizado. O comportamento sincronizado significa que todos os neurônios produzem uma resposta simultânea a cada instante de tempo. O comportamento assíncrono significa que cada neurônio em uma camada produz o seu sinal de saída independente dos demais.

A fase de aprendizagem ou treinamento de uma rede neuronal artificial é realizada a partir de um conjunto de regras particulares que adaptam os pesos sinápticos da rede em resposta a um conjunto de estímulos do ambiente (HAYKIN, 1994). As redes neuronais geram suas próprias regras através da aprendizagem por meio de exemplos; ou seja, elas permitem que os dados falem por si próprios. De forma diferente que os tradicionais sistemas especialistas, onde o conhecimento é feito de maneira explícita na forma de regras bem definidas.

Na aprendizagem não supervisionada somente os estímulos do ambiente são apresentados à rede neuronal e ela se organiza internamente, de tal forma que cada neurônio responda fortemente a um novo estímulo muito próximo do valor de um estímulo anteriormente apresentado. Os estímulos apresentados à rede, são representados por nuvens (*clusters*) no espaço de estímulos, o qual normalmente representa distintos conceitos reais.

Na aprendizagem supervisionada cada estímulo de entrada é apresentado com a correspondente resposta desejada, na forma de um par estímulo-resposta. O conjunto de pares estímulos-respostas formam o conjunto de treinamento. A rede neuronal gradualmente se configura internamente para produzir um mapeamento do espaço de estímulos sobre o espaço de respostas desejadas. Tal aprendizagem é normalmente uma variação de um dos três tipos básicos de regras de aprendizagem:

1. Regra de Hebb: Nesta o peso de uma conexão sináptica na entrada de um neurônio é incrementada se o estímulo e a resposta desejada neste neurônio são altas. Em termos biológicos isto significa que uma conexão é fortalecida toda vez que é utilizada.
2. Regra do Delta: A aprendizagem é realizada a partir de um processo contínuo de

redução do erro existente entre a resposta atual de um neurônio a um estímulo e a sua correspondente resposta desejada.

3. Regra da Competição: Na qual cada neurônio compete com todos os outros até que um único vença ou produza a maior resposta a um dado estímulo.

A essência do treinamento de uma rede neuronal é a de formular uma codificação funcional da relação estímulo-resposta e conseqüentemente possibilitar uma boa generalização, a qual pode ser interpretada, na forma: *Uma rede neuronal é dita como sendo bem treinada, no sentido em que se ela conhece bem o passado ela poderá então estimar o futuro convenientemente* (HAYKIN, 1994). Mais especificamente, o treinamento pode ser visto como um problema da escolha da melhor codificação, dentro de um conjunto de possíveis codificações aceitáveis. Neste sentido, podemos lançar mão de uma técnica estatística bastante conhecida, que é a validação cruzada (*cross-validation*), a qual serve como guia (JANSEN et al., 1988). A validação cruzada estabelece um procedimento padrão a ser utilizado no treinamento e na aplicação da rede neuronal, na forma:

1. O conjunto de dados disponível é aleatoriamente particionado em dois conjuntos,
 - conjunto de treinamento,
 - conjunto de teste.
2. O conjunto de treinamento é novamente particionado em dois novos sub-conjuntos,
 - um, utilizado para a estimativa da melhor codificação,
 - o outro, utilizado para a validação da codificação escolhida.

A motivação é otimizar a escolha da melhor codificação, sobre a qual é treinada a rede com todo o conjunto de treinamento. A aplicação da rede treinada será então realizada sobre o conjunto de teste.

Uma importante característica das redes neuronais é a maneira como ela armazena informações, ou em outras palavras, adquire conhecimento. No estudo das redes neuronais o conhecimento pode ser conceituado na forma (HAYKIN, 1994):

O conhecimento se refere à acumulação de informações ou modelos utilizados por uma pessoa ou máquina para interpretar, prever e apropriadamente responder ao ambiente exterior.

A memória de uma rede neuronal é distribuída e associativa, com os pesos das conexões modelando as unidades de memória. Os valores dos pesos sinápticos representam o estado atual de conhecimento da rede. Uma unidade de treinamento, representada por um par estímulo-resposta é distribuído por toda as unidades de memória na rede e divide com essas unidades todos os itens de conhecimento armazenados. A memória das redes neuronais é associativa: Uma vez que um estímulo incompleto ou deturpado é apresentado, ela buscará em sua memória um estímulo armazenado que melhor se ajuste ao apresentado, produzindo uma resposta que corresponda ao estímulo completo.

3.2.1 O Neurônio Artificial

O neurônio artificial é a unidade processadora fundamental para a computação das redes neuronais. A Figura 3.3 mostra um modelo de neurônio artificial típico, onde identifica-se três componentes básicos:

1. Um conjunto de sinapses é formado por um especificado conjunto de valores (pesos). A existência de uma conexão entre dois neurônios i e j é caracterizada por um peso w_{ij} , onde os subíndices i e j representam o ponto de partida e o ponto de chegada, respectivamente, de um sinal que percorre a rede. Podemos distinguir dois tipos de sinapses:
 - (a) Sinapse excitatória, onde $w_{ij} > 0,0$.
 - (b) Sinapse inibitória, onde $w_{ij} < 0,0$.
2. Um somador, responsável pela acumulação de todos os sinais de entrada ponderados pelos respectivos pesos sinápticos. O somador produz, na realidade, uma combinação linear entre os sinais de entrada e os pesos sinápticos.
3. Uma função de ativação responsável pela limitação da amplitude do sinal de saída do neurônio. Normalmente, a amplitude normalizada do sinal de saída de um neurônio é escrita no intervalo fechado $[0, 1]$ ou, alternativamente, no intervalo fechado $[-1, 1]$.

O modelo do neurônio artificial, inclui também um parâmetro externo θ_i , o qual é um valor limite ou valor limiar (*threshold*), que deve ser excedido para que o neurônio produza um sinal de saída eficaz.

Matematicamente, pode-se descrever o estado de um neurônio k , em um instante qualquer, através do seguinte par de equações

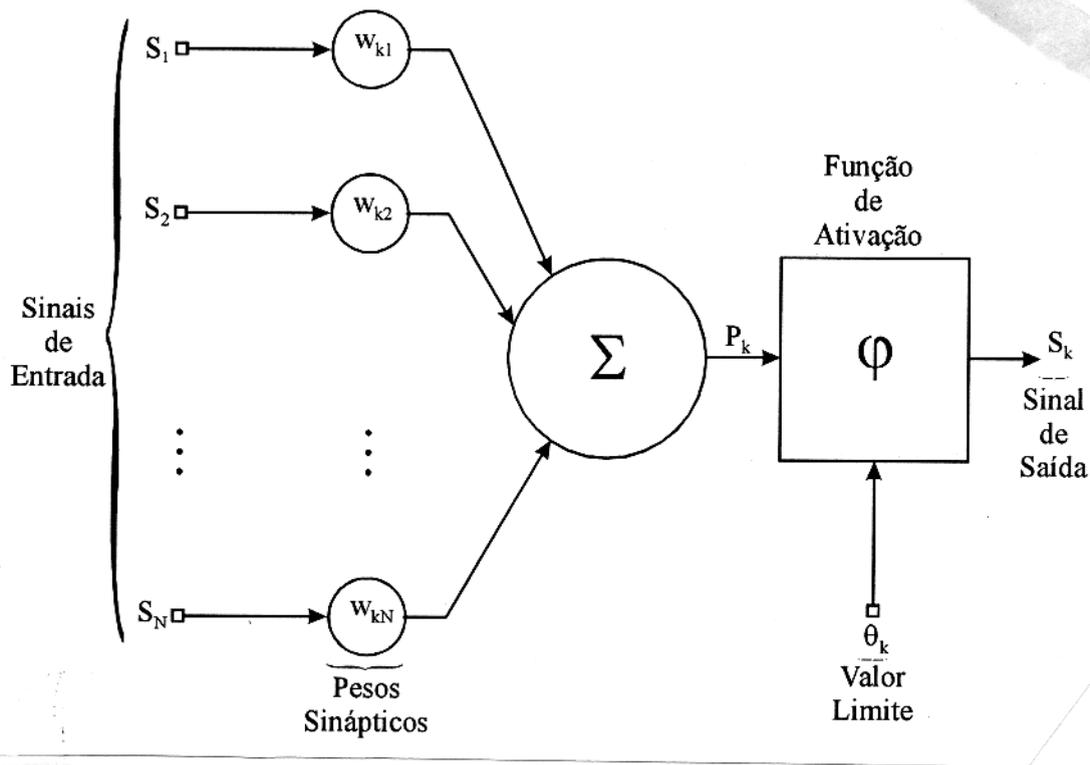


Figura 3.3 - Neurônio artificial típico.

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

e

$$S_k = \varphi(P_k - \theta_k) \quad (3.2)$$

onde, S_1, S_2, \dots, S_N são os sinais de saída (estados) de todos os N neurônios conectados ao neurônio k . $w_{k1}, w_{k2}, \dots, w_{kN}$ são os pesos sinápticos das conexões que chegam ao neurônio k . A quantidade P_k é chamada de potencial de ativação do neurônio k . θ_k é o valor limiar do neurônio k e $\varphi(P_k)$ é a função de ativação. S_k é o sinal de saída, ou estado do neurônio k .

A utilização de um valor limite, θ_k , possui o efeito de aplicar uma transformação afim sobre o nível de atividade P_k do neurônio k , como mostra a Figura 3.4, ou

$$V_k = P_k - \theta_k. \quad (3.3)$$

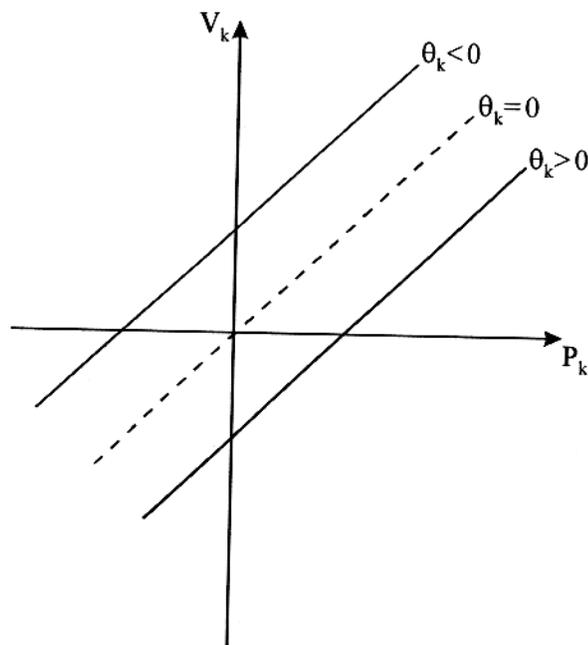


Figura 3.4 - Transformação afim, produzida pela presença de um valor limiar.

3.2.2 As Funções de Ativação

Uma função de ativação, define a saída de um neurônio dentro de um especificado intervalo, com base em seu nível de atividade. Identificaremos três tipos fundamentais de função de ativação:

1. *Função sinal ou degrau-simples (threshold function)*, mostrada na Figura 3.5, é descrita na forma

$$\varphi(P_k) = \begin{cases} 1,0 & \text{se } P_k \geq 0,0 \\ 0,0 & \text{se } P_k < 0,0 \end{cases} \quad (3.4)$$

Assim, a saída do neurônio k através desta função é dada por

$$S_k = \begin{cases} 1,0 & \text{se } P_k \geq 0,0 \\ 0,0 & \text{se } P_k < 0,0 \end{cases} \quad (3.5)$$

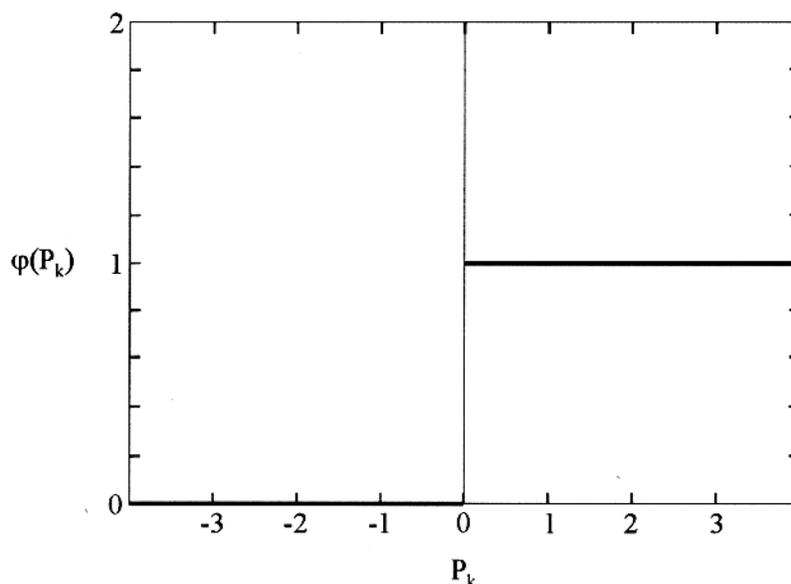


Figura 3.5 - Função degrau-simples.

Um neurônio descrito desta forma expressa o modelo neuronal de McCulloch-Pitts (MCCULLOCH & PITTS, 1943), onde um neurônio produz uma saída efetiva somente se o seu nível de atividade for maior que zero.

2. *Função rampa (piecewise-linear function)*, como mostrada na Figura 3.6, é representada pela expressão

$$\varphi(P_k) = \begin{cases} 1,0 & \text{se } P_k \geq 1 \\ P_k & \text{se } -1 < P_k < 1 \\ 0,0 & \text{se } P_k \leq -1 \end{cases} \quad (3.6)$$

Nesta é aplicado um fator unitário de amplificação dentro da região linear. Esta forma de função de ativação pode ser vista como uma aproximação de um amplificador não linear. A função rampa se reduz à função degrau se o fator de amplificação for tomado muito grande.

3. *Função sigmóide (sigmoid function)*, definida como uma função contínua, suave e extritamente crescente. É a função de ativação mais utilizada na construção das redes neurais artificiais, aparecendo, comumente, em duas formas:

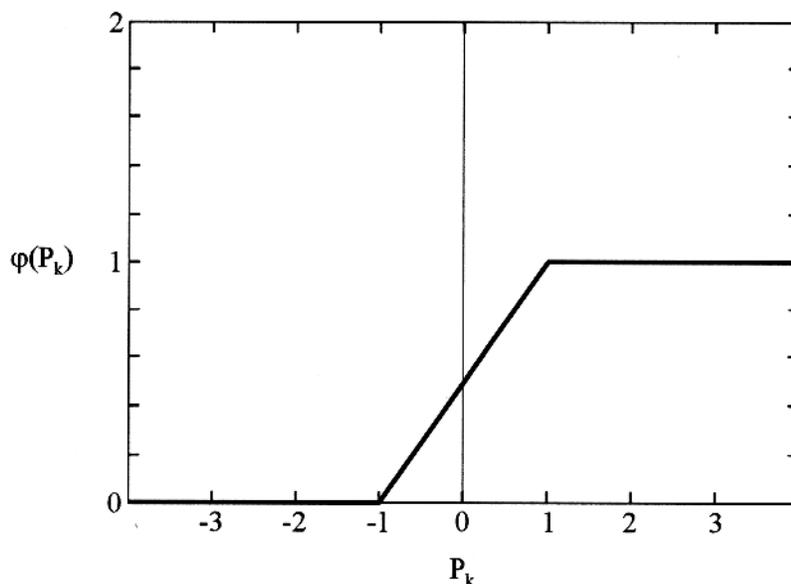


Figura 3.6 - Função rampa.

(a) *Função logística (logistic function)*, definida através da expressão

$$\varphi(P_k) = \frac{1}{1 + e^{(-\gamma P_k)}} \quad (3.7)$$

onde γ é o parâmetro de inclinação da curva. A variação deste parâmetro implica na obtenção de funções com diferentes inclinações (Figura 3.7). No limite, quando o parâmetro de inclinação tende a infinito, a função logística tenderá à função sinal. Enquanto que a função sinal pode assumir exclusivamente os valores 0 ou 1, a função logística pode assumir qualquer valor do intervalo fechado $[0, 1]$.

(b) *Função tangente hiperbólica (hyperbolic tangent function)*, definida por

$$\varphi(P_k) = \frac{1 - e^{(-\gamma P_k)}}{1 + e^{(-\gamma P_k)}} \quad (3.8)$$

A qual produz valores de saída do neurônio no intervalo fechado $[-1, 1]$, permitindo a existência de valores negativos (Figura 3.8), o que possui evidências neuropsicológicas de natureza experimental (EEKMAN & FREEMAN, 1986).

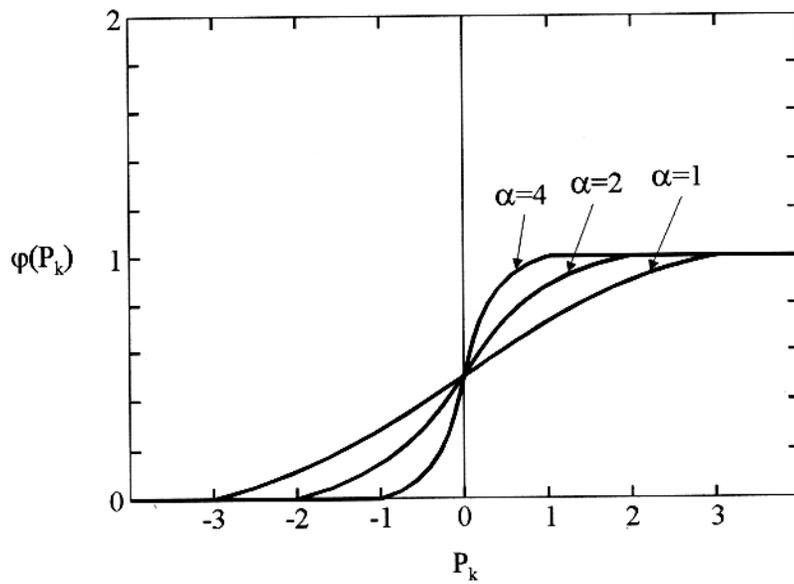


Figura 3.7 - Função logística.

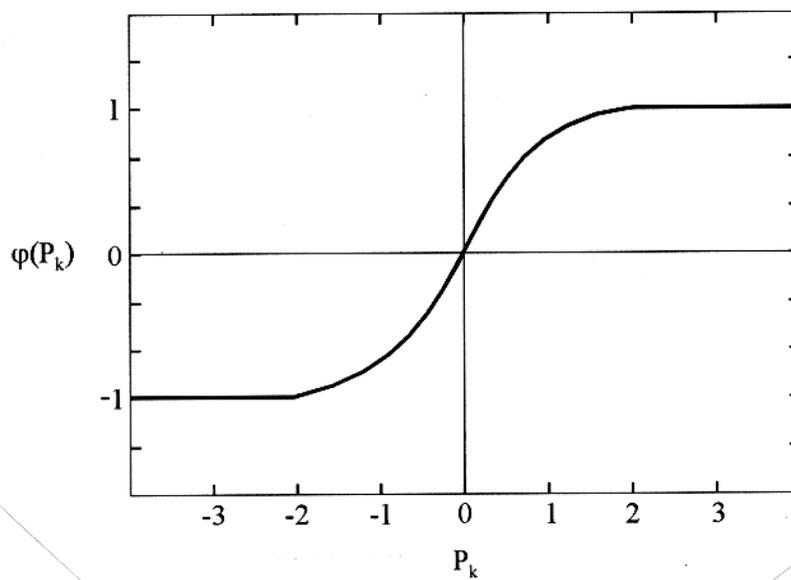


Figura 3.8 - Função tangente hiperbólica.

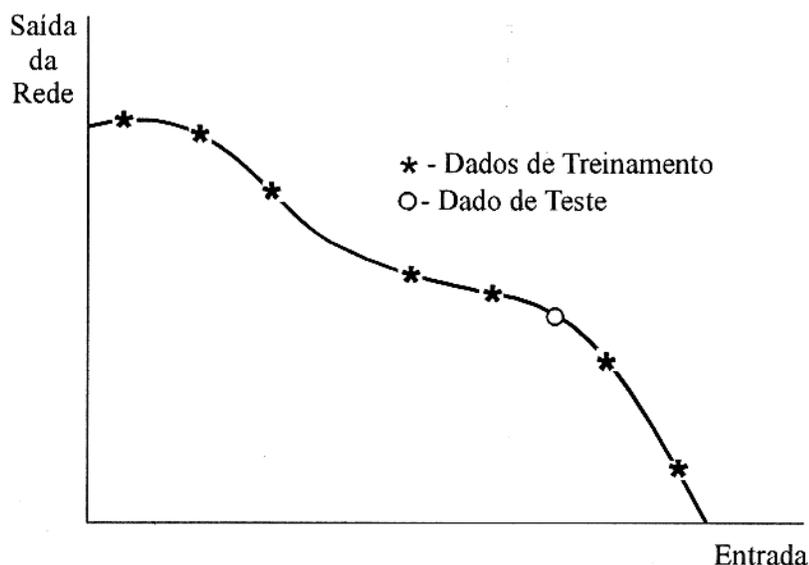


Figura 3.9 - Exemplo de um ajuste suave com boa generalização

3.2.3 Generalização

O que se espera de uma rede neuronal treinada é que ela seja capaz de *generalizar*. Uma rede é dita generalizar eficientemente, quando a relação estímulo-resposta, criada pela rede, a partir do conjunto de treinamento, se mostra correta (ou aproximadamente correta) quando aplicada a um novo par estímulo-resposta, não pertencente ao conjunto de treinamento (HAYKIN, 1994).

A generalização é a principal característica de uma rede neuronal e a responsável pela sua capacidade de solucionar problemas. Uma melhor compreensão da generalização, parte do entendimento do processo de aprendizagem da rede neuronal, visto como um problema de ajuste de curva e o processamento geral da rede neuronal, como o de um mapeamento não linear do espaço de estímulos no espaço de respostas desejadas. A generalização, seria então a avaliação de um novo ponto desta superfície.

A superfície, que representa o mapeamento estímulo-resposta desejada, deve ser suave, de modo a permitir que a rede seja capaz de classificar convenientemente um novo padrão (WIELAND & LEIGHTON, 1987).

Para um melhor entendimento da generalização, toma-se uma rede neuronal hipotética,

com três camadas. Na fase de aprendizagem é apresentado a rede um conjunto de pares estímulo-resposta, como mostrado com asteriscos, na Figura 3.9. O treinamento da rede consiste em dado um estímulo, através de um valor do eixo x , a resposta da rede deve se aproximar o melhor possível da resposta desejada, um valor correspondente lançado no eixo y . A curva mostrada na Figura 3.9, representa o mapeamento não linear executado pela rede neuronal, após a fase de treinamento, ou seja a determinação de uma função suave que mapeia o eixo x sobre o eixo y . A generalização, entendida como a interpolação de um novo ponto neste mapa é mostrada por meio do símbolo o , na Figura 3.9, que representa um novo estímulo (eixo- x) e a resposta da rede (eixo- y).

A generalização de uma rede neuronal artificial é influenciada, fundamentalmente, por três fatores que são

1. O tamanho do conjunto de treinamento.
2. A arquitetura da rede neuronal.
3. Complexidade do problema a ser tratado.

Assim, percebendo que em princípio, não existe controle sobre o terceiro fator, podemos tratar a construção de redes neuronais, que possibilitem uma boa generalização sob dois aspectos (HUSH & HORNE, 1993):

- A arquitetura da rede é fixa. O problema é determinar o tamanho do conjunto de treinamento.
- O conjunto de treinamento é fixo. O problema é determinar a melhor arquitetura da rede neuronal.

Embora os dois aspectos sejam, em teoria, relevantes na prática o primeiro caso é mais comumente encontrado e a determinação do tamanho do conjunto de treinamento será tratado particularmente para cada caso estudado neste trabalho.

3.3 REDE NEURONAL DIRETA MULTICAMADAS

A arquitetura típica deste tipo de rede neuronal é composta por um conjunto de camadas dispostas ordenadamente em função da direção de propagação do sinal no seu interior. A primeira camada, conhecida por *camada de entrada* é a responsável pelo recebimento das informações do meio exterior, ela é constituída por um conjunto de neurônios sem nenhuma

finalidade computacional e por isto são chamados de *unidades sensoriais*. Após a camada de entrada se colocam uma ou mais *camadas ocultas*, constituídas por neurônios processadores, responsáveis pelo processamento interno da rede. Por fim, aparece a *camada de saída*, formada por elementos processadores, aonde aparece o sinal de saída da rede.

A rede neuronal direta de múltiplas camadas, conhecida também como perceptrons de múltiplas camadas (*multilayer perceptron*), realiza um mapeamento não linear do espaço de estímulos (sinal de entrada) no espaço das respostas desejadas através de regras específicas de aprendizagem, a partir da apresentação de exemplos de treinamento compostos por pares estímulo-resposta. A aprendizagem se processa pela adaptação de todos os pesos sinápticos e de tal modo que a diferença entre o sinal de saída da rede e a resposta desejada seja a menor possível, na média de todo o conjunto treinamento.

Uma rede neuronal direta de múltiplas camadas, possui as seguintes características:

1. O modelo da rede inclui uma não linearidade (função de ativação) caracterizada por uma função contínua, suave e diferenciável. A função de ativação mais utilizada é a função logística (equação 3.7), reescrita abaixo na forma

$$\varphi(P_k) = \frac{1}{1 + e^{(-\gamma P_k)}}.$$

Esta expressão possui uma motivação de natureza neurobiológica, uma vez que ela contempla o que se denomina de fase refratária dos neurônios biológicos (PINEDA, 1988).

2. As camadas ocultas possibilitam o aprendizado de problemas complexos, extraindo progressivamente mais características significantes dos padrões de entrada.
3. A rede exhibe um alto grau de conectividade, determinado por suas sinapses. Uma variação na conectividade implica uma variação no número de sinapses ou no valor de seus respectivos pesos sinápticos.

Um sinal de entrada se propaga pela rede de uma forma dita direta (*sinal direto*); ou seja, a partir da camada de entrada, o sinal direto passa sucessivamente pelas camadas ocultas até retornar ao ambiente externo através da camada de saída. Assim para este tipo de rede neuronal e em função do tipo de algoritmo utilizado para o treinamento da rede, podemos identificar dois tipos de sinais (PARKER, 1987)

1. Sinal direto (*function signal*) são os estímulos externos que chegam à rede através da camada de entrada, fluem através de todas as camadas ocultas e emerge como sinal de resposta na camada de saída.

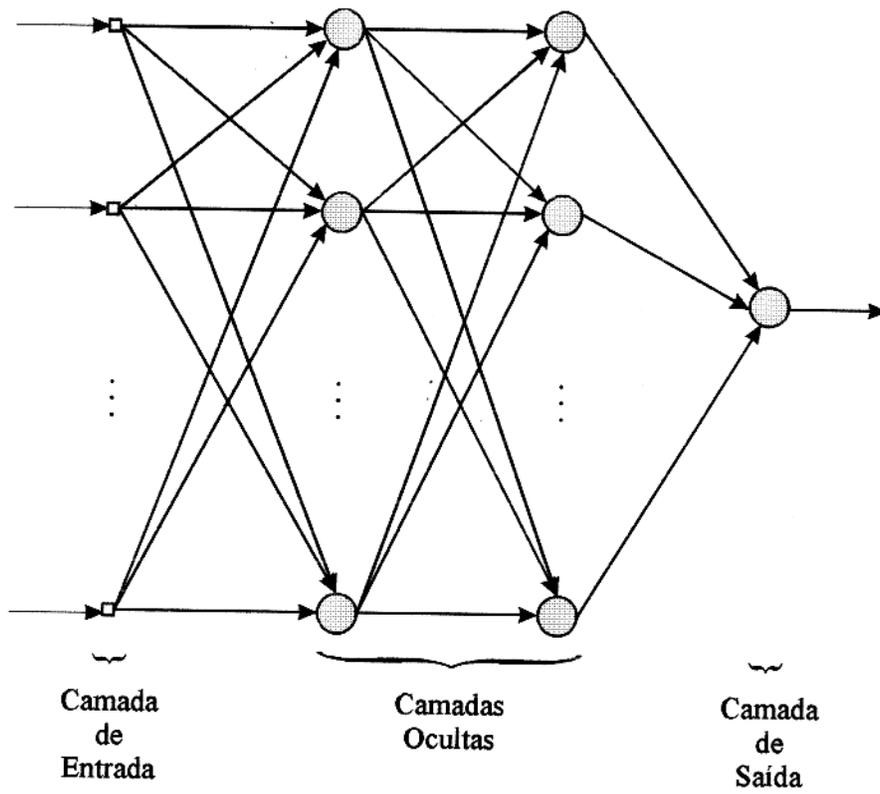


Figura 3.10 - Arquitetura típica de uma rede neural artificial de múltiplas camadas

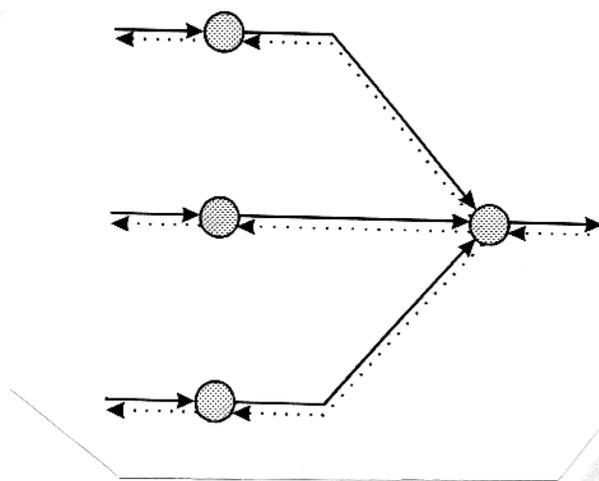


Figura 3.11 - Tipos de sinal que percorrem a rede neuronal. sinal direto - linha cheia. sinal inverso - linha pontilhada

2. Sinal inverso (*error signal*) são os sinais de erro originados a partir da camada de saída, durante a fase de aprendizagem e percorrem a rede neuronal na direção contrária (inversa) à dos sinais diretos.(Figura 3.11)

A conjugação destas características, combinadas à capacidade de aprender a partir da experiência, tornam este tipo de rede neuronal extremamente poderosa. No entanto, estas mesmas características são também responsáveis pelas suas deficiências. A presença de uma não-linearidade (função de ativação) distribuída por toda a rede e a utilização das camadas ocultas tornam bastante difícil a sua análise teórica, bem como a visualização do seu processo de aprendizagem. A fase de treinamento se torna muitas vezes bastante complicada uma vez que a pesquisa deve ser realizada sobre um espaço muito grande de possíveis funções suaves para o mapeamento estímulo-resposta desejada, além da busca de uma eficiente forma de representação dos padrões de entrada (HILTON & NOWLAN, 1987).

As pesquisas com as redes neuronais diretas multicamadas iniciaram com o trabalho sobre os *perceptrons* (ROSENBLATT, 1962), concebidos a partir de um modelo da retina ocular, constituído por um conjunto de sensores de luz distribuídos na forma de uma matriz, com o objetivo de simular a capacidade de reconhecimento de padrões do sistema visual humano. Os *perceptrons* (Figura 3.12) utilizam o neurônio de McCulloch-Pitts (MCCULLOCH & PITTS, 1943) e seu treinamento é realizado pela regra de Hebb. Apesar do grande interesse inicial, MINSKY & PAPERT em 1969 mostraram que existe um conjunto de pesos sinápticos tal que a resposta da rede coincide com a resposta desejada se, e somente se, o conjunto dos

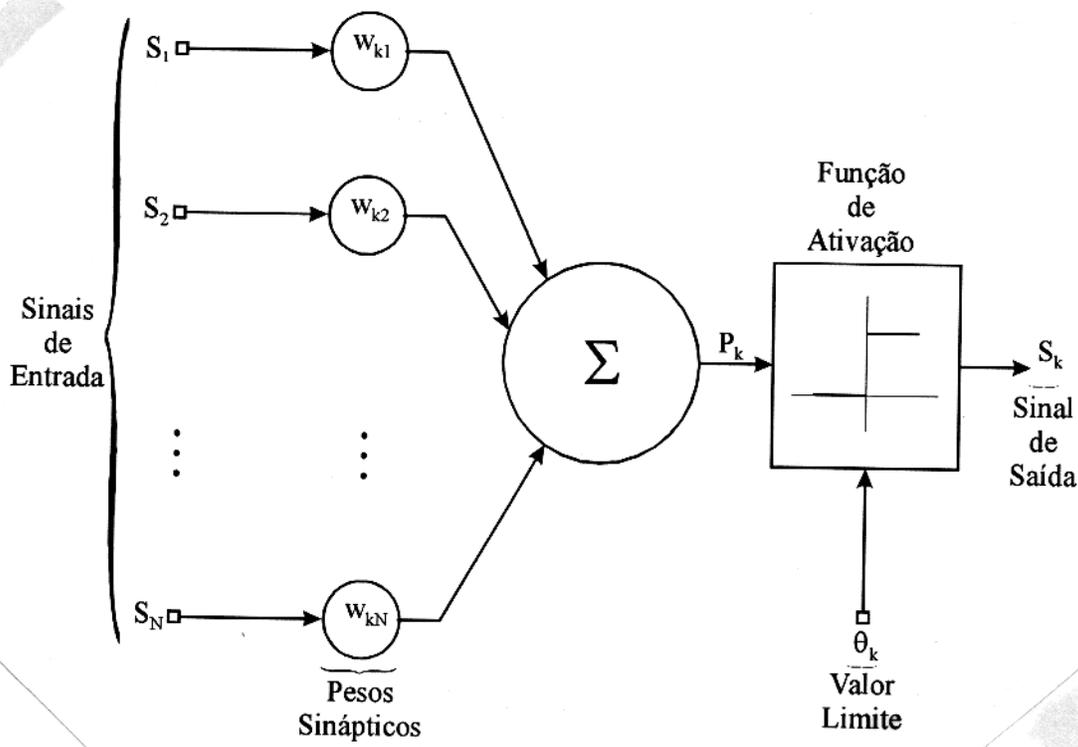


Figura 3.12 - *Perceptron*: Mostrando o seu elemento processador.

sinais de entrada são linearmente separáveis; ou seja, dado um espaço de todos os sinais de entrada, todos aqueles que pertencem a um dado conjunto ocuparão o mesmo lado de um hiperplano (MINSHY & PAPERT, 1969). Outra importante contribuição foi dada por WIDROW & HOFF em 1966, com a apresentação de uma arquitetura de rede neuronal conhecida como *Madaline* (Multiple Adaptive Linear neuron) construída a partir da associação de várias *Adalines* (Adaptive Linear neurons) que são elementos processadores inspirados nos *perceptrons* e nos filtros adaptativos lineares (Figura 3.13). O seu algoritmo de treinamento utiliza a regra do delta.

As primeiras redes neuronais diretas careciam entretanto de um melhor algoritmo de treinamento, que permitisse o tratamento de problemas não lineares, o que somente foi alcançado com a publicação do livro *Parallel Distributed Processing* por RUMELHART & MCCLELLAND em 1986, lançando o algoritmo de retro-propagação do erro (*error back-propagation*).

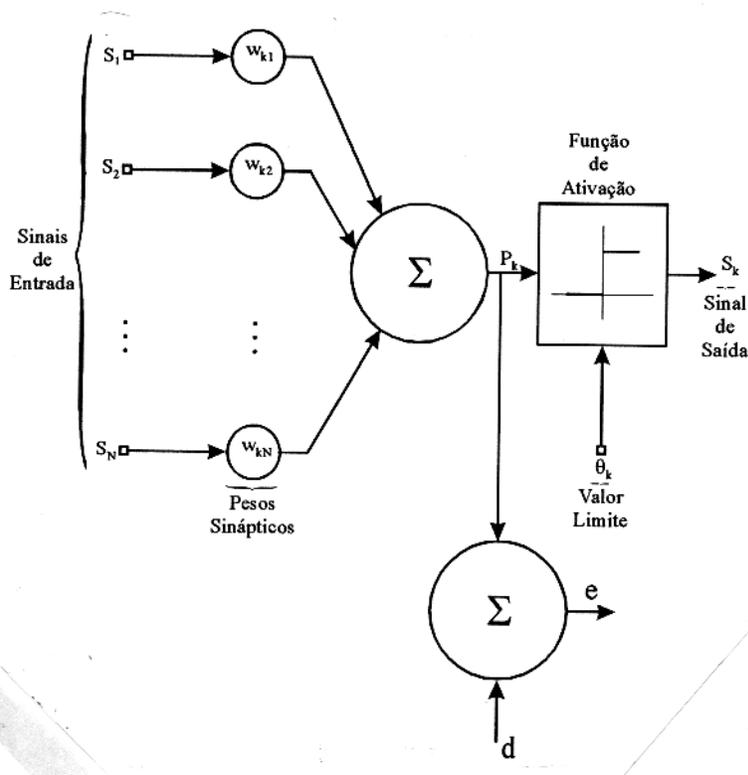


Figura 3.13 - *Adaline*: Mostrando o seu elemento processador.

3.3.1 Aprendizagem por Retro-propagação do Erro

A ideia básica do algoritmo de retro-propagação do erro (*error back-propagation*) foi formulada por WERBOS em 1974 para um caso geral dos sistemas conectivos, onde as redes neurais artificiais representam um caso particular. RUMELHART & MCCLELLAND (1986) popularizaram o método e de forma independente PARKER em 1985, desenvolveu uma formulação similar do algoritmo. Desde então, redes neurais diretas de múltiplas camadas tem sido aplicadas para a solução de diversos problemas.

O algoritmo de retro-propagação do erro é baseado na regra de aprendizagem de correção do erro ou regra do Delta. Basicamente, o algoritmo consiste de duas passagens do sinal através das camadas da rede neuronal

1. Passagem Direta é a passagem do sinal direto, na qual os pesos sinápticos permanecem inalterados.
2. Passagem Inversa, é a passagem do sinal inverso, na qual os pesos sinápticos são ajustados de acordo com a regra do Delta.

A aprendizagem de uma rede neuronal direta com múltiplas camadas, através do algoritmo de retro-propagação do erro, é inicializada, atribuindo-se valores iniciais para os seus *parâmetros livres* (pesos sinápticos e potenciais limites) que são tomados como aleatórios e uniformemente distribuídos no interior de um pequeno intervalo de valores (LEE et al., 1991). A partir da apresentação do *conjunto de treinamento*, composto pelos pares estímulo-resposta desejada, o algoritmo de retro-propagação do erro calcula os novos valores dos parâmetros livres da rede a partir da regra do delta, até que algum critério de parada pré-estabelecido seja alcançado. O critério de parada mais utilizado pode ser estabelecido na forma descrita a seguir (KRAMER & SANGIVANNI-VINCENTELLI, 1989).

O algoritmo de retro-propagação do erro é considerado terminado quando estabelece valores para os parâmetros livres, tal que:

1. *A derivada primeira da superfície de erro é próxima de zero, ou de um número positivo muito pequeno.*
2. *A soma ponderada pelo número de neurônios das funções que efetuam uma medida do erro em cada neurônio é próxima de zero, ou de um número positivo muito pequeno.*

O desenvolvimento do algoritmo de retro-propagação do erro é um marco no desenvolvimento das redes neuronais artificiais, uma vez que foi capaz de promover uma maneira computacional eficiente para o aprendizado das redes diretas de múltiplas camadas (HAYKIN, 1994).

3.3.1.1 Algoritmo Retro-Propagação do Erro

Para mostrar a dedução do algoritmo de retro-propagação do erro, admite-se uma rede neuronal direta com apenas três camadas; uma camada de entrada, uma oculta e uma de saída. O estado ou o valor do sinal direto (de saída) de um neurônio i ($S_i(t)$), pertencente à camada de saída da rede no instante t , isto é, na t -ésima apresentação de um mesmo par estímulo-resposta ou na apresentação do t -ésimo par estímulo-resposta, segue a equação

$$S_i(t) = \frac{1}{1 + e^{-P_i(t)}}, \quad (3.9)$$

na qual o parâmetro θ_i foi retirado e incluído na expressão do potencial de ativação P_i , incluindo-se um neurônio fictício 0, tal que, o seu estado em qualquer instante é unitário, $S_0 = -1,0$ e o seu peso sináptico com respeito ao neurônio i seja, $w_{0i} = \theta_i$. Assim a

expressão para o potencial de ativação, considerando-se um número de N conexões com o neurônio i fica

$$P_i = \sum_{j=0}^N w_{ij} S_j. \quad (3.10)$$

Sendo o neurônio i pertencente à camada de saída da rede, o seu estado $S_i(t)$ no instante t , caracteriza a resposta deste neurônio neste instante, ou seja, o sinal direto, que percorreu pela rede desde a camada de entrada até a saída deste neurônio. $S_j(t)$, representa os sinais diretos de todos os neurônios situados na camada imediatamente anterior, em relação à direção de propagação do sinal direto, que estão conectados ao neurônio i , ou seja, os sinais $S_j(t)$, provém da saída dos neurônios pertencentes à camada oculta imediatamente anterior.

O sinal inverso ou o sinal de erro, e_i , (erro local) calculado no neurônio i da camada de saída da rede, será dado por

$$e_i(t) = D_i - S_i(t), \quad (3.11)$$

nesta equação, D_i representa a resposta desejada para o particular neurônio i .

A partir da equação 3.11, define-se a função objeto ou função erro global (*cost function*) característica do algoritmo de retro-propagação do erro (RUMELHART & MCCLELLAND, 1986), para a camada de saída, supondo-se, por simplicidade, que apenas um par estímulo-resposta seja apresentado à rede na forma

$$E(t) = \frac{1}{2} \sum_{i=1}^M e_i^2(t), \quad (3.12)$$

Esta equação é interpretada como a soma quadrática média de todos os erros locais dos M neurônios que compoem a camada de saída da rede no instante de tempo t (HAYKIN, 1994). Ela é função de todos os *parâmetros livres* da rede, ou seja, dos pesos sinápticos, w_{ij} e dos potenciais limites, θ_i .

O objetivo básico do algoritmo de aprendizagem de retro-propagação do erro é ajustar os parâmetros livres da rede de modo a promover uma minimização da função objeto $E(t)$ (RUMELHART & MCCLELLAND, 1986). Assim, segundo as equações 3.9 e 3.10, necessita-se considerar somente o ajuste sobre os valores dos pesos sinápticos, que serão calculados de acordo com os respectivos erros a cada instante de tempo. O ajuste sobre o peso sináptico, $w_{ij}(t)$, que representa a conexão entre o neurônio i da camada de saída e o neurônio j da camada oculta, no instante t , a partir da regra do Delta, é expresso por

$$\Delta w_{ij}(t) = -\eta \frac{\partial E(t)}{\partial w_{ij}}. \quad (3.13)$$

O parâmetro η (*learning-rate parameter*) na equação 3.13 é constante e responsável pela velocidade do aprendizado. O sinal negativo significa a tomada da direção decrescente do gradiente no espaço de pesos sinápticos. Para a determinação de $\Delta w_{ij}(t)$ é necessário o cálculo da derivada parcial na equação 3.13 para o qual, utilizaremos a regra da cadeia do cálculo infinitesimal, obtendo,

$$\frac{\partial E(t)}{\partial w_{ij}} = \frac{\partial E(t)}{\partial e_i(t)} \frac{\partial e_i(t)}{\partial S_i(t)} \frac{\partial S_i(t)}{\partial P_i(t)} \frac{\partial P_i(t)}{\partial w_{ij}(t)}. \quad (3.14)$$

Desenvolvemos separadamente os termos da equação 3.14, inicia-se com a diferenciação da equação 3.12 com relação a $e_i(t)$

$$\frac{\partial E(t)}{\partial e_i(t)} = e_i(t). \quad (3.15)$$

Diferenciando os dois lados da equação 3.11 com relação a $S_i(t)$ e observando que a resposta desejada é constante durante todo o período de aprendizagem, temos que

$$\frac{\partial e_i(t)}{\partial S_i(t)} = -1. \quad (3.16)$$

Para a determinação do termo seguinte, deriva-se a equação 3.9 com relação a $P_i(t)$ na forma

$$\frac{\partial S_i(t)}{\partial P_i(t)} = \varphi'(P_i(t)). \quad (3.17)$$

O termo $\varphi'(P_i(t))$ na equação 3.17, representa a derivada da função de ativação em relação ao potencial de ativação do neurônio i no instante t . Diferenciando a equação 3.10 em relação ao peso sináptico $w_{ij}(t)$, temos que

$$\frac{\partial P_i(t)}{\partial w_{ij}(t)} = S_j(t); \quad (3.18)$$

Finalmente, substituindo as equações 3.15, 3.16, 3.17, 3.18 na equação 3.14, obtemos que

$$\frac{\partial E(t)}{\partial w_{ij}(t)} = -e_i(t) \varphi'(P_i(t)) S_j(t). \quad (3.19)$$

Com isto a equação 3.13 será escrita na forma

$$\Delta w_{ij}(t) = \eta e_i(t) \varphi'(P_i(t)) S_j(t). \quad (3.20)$$

Então, para os neurônios localizados na camada de saída da rede, obtemos o sinal inverso e calcula-se as modificações nos pesos sinápticos utilizando a equação 3.20.

Consideraremos agora o caso dos neurônios localizados na camada oculta. É claro que não existe uma resposta desejada pre-especificada para estes neurônios e portanto a determinação do sinal inverso não pode mais ser realizada diretamente utilizando-se a equação 3.11. O cálculo do sinal inverso para um neurônio j localizado em uma camada oculta será, então, realizado de forma recursiva, em função dos sinais inversos de todos os neurônios da camada imediatamente anterior, em relação ao sinal inverso, que é a camada de saída da rede, a única na qual se pode efetivamente calcular o sinal inverso.

Utilizaremos a equação 3.13, para a determinação da correção $\Delta w_{jk}(t)$ a ser aplicada ao peso sináptico $w_{jk}(t)$, que representa a conexão entre o neurônio j da camada oculta e o neurônio k da camada de entrada no tempo t , como mostrado na Figura 3.14. Reescrevemos a equação 3.13 mostrando os novos índices na forma

$$\Delta w_{jk}(t) = -\eta \frac{\partial E(t)}{\partial w_{jk}} \quad (3.21)$$

Agora a quantidade $E(t)$ é definida, para um neurônio j da camada oculta de forma semelhante ao caso anterior

$$E(t) = \frac{1}{2} \sum_i^M e_i^2 = \frac{1}{2} \sum_i^M \left[D_i - \frac{1}{1 + e^{-P_i(t)}} \right]^2 \quad (3.22)$$

Na equação 3.22, o subíndice i representa um neurônio i pertencente à camada de saída da rede.

A derivada parcial a direita na equação 3.21, a partir da regra da cadeia, pode ser escrita na forma

$$\frac{\partial E(t)}{\partial w_{jk}(t)} = \frac{\partial E(t)}{\partial S_j(t)} \frac{\partial S_j(t)}{\partial P_j(t)} \frac{\partial P_j(t)}{\partial w_{jk}(t)}. \quad (3.23)$$

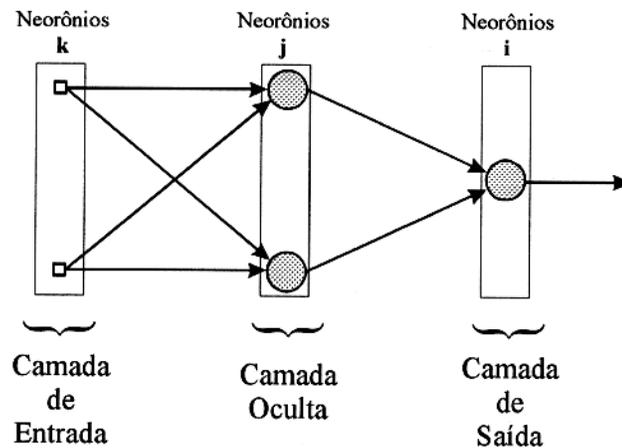


Figura 3.14 - Diagrama de localização dos neurônios nas camadas

Discutir-se-a cada termo do lado direito da equação 3.23, começando pelo termo $\frac{\partial E(t)}{\partial S_j(t)}$. Para o qual aplica-se a regra da cadeia na equação 3.22, obtemos o resultado parcial

$$\frac{\partial E(t)}{\partial S_j(t)} = \sum_i^M e_i(t) \frac{\partial e_i(t)}{\partial S_j(t)}. \quad (3.24)$$

Utilizando novamente a regra da cadeia, a equação 3.24 pode ser desenvolvida para

$$\frac{\partial E(t)}{\partial S_j(t)} = \sum_i^M e_i(t) \frac{\partial e_i(t)}{\partial P_i(t)} \frac{\partial P_i(t)}{\partial S_j(t)}. \quad (3.25)$$

Lembrando a equação 3.11

$$e_i = D_i - S_i = D_i - \frac{1}{1 + e^{-\gamma P_i}},$$

chega-se a seguinte expressão

$$\frac{\partial e_i(t)}{\partial P_i(t)} = -\varphi'(P_i(t)). \quad (3.26)$$

O potencial de entrada $P_i(t)$ do neurônio i foi mostrado pela equação 3.10 ou,

$$P_i(t) = \sum_{j=0}^N w_{ij}(t) S_j(t).$$

Assim, continuando com a determinação dos termos a direita da equação 3.25, derivando ambos os lados da equação acima em função de $S_j(t)$, chega-se ao resultado

$$\frac{\partial P_i(t)}{\partial S_j(t)} = w_{ij}(t). \quad (3.27)$$

Com isto, a equação 3.25 fica escrita na forma

$$\frac{\partial E(t)}{\partial S_j(t)} = -\sum_i^M e_i(t) \varphi'(P_i(t)) w_{ij}(t). \quad (3.28)$$

A equação 3.18 escrita agora para um neurônio j da camada oculta é dada por

$$\frac{\partial P_j(t)}{\partial w_{jk}(t)} = S_k(t), \quad (3.29)$$

e a equação 3.17 fica na forma

$$\frac{\partial S_j(t)}{\partial P_j(t)} = \varphi'(P_j(t)).$$

A equação 3.23 pode, então, ser escrita na forma final

$$\frac{\partial E(t)}{\partial w_{kj}(t)} = -S_k(t) \varphi'(P_j(t)) \sum_i^M e_i(t) \varphi'(P_i(t)) w_{ij}(t). \quad (3.30)$$

A correção do peso sináptico $w_{jk}(t)$ é então escrita na forma

$$\Delta w_{jk}(t) = \eta S_k(t) \varphi'(P_j(t)) \sum_i^M e_i(t) \varphi'(P_i(t)) w_{ij}(t). \quad (3.31)$$

O termo $S_k \varphi'(P_j)$, depende exclusivamente do sinal direto na saída dos neurônios da camada oculta. O termo $\sum_i e_i(t) \varphi'(P_i(t)) w_{ij}(t)$, depende do sinal inverso, calculado na camada de saída e dos pesos sinápticos que conectam um neurônio da camada oculta com os neurônios da camada de saída. No caso de mais de uma camada oculta o procedimento é exatamente igual, apenas levando-se em conta que para uma extra camada oculta, a camada de saída deverá se substituída pela camada oculta imediatamente anterior, tomada na direção de propagação do sinal inverso.

3.3.2 Aproximação de Funções

Uma rede neuronal direta, treinada com o algoritmo da retro-propagação do erro, será interpretada como sendo a realização de um mapeamento não linear do espaço de estímulos sobre o espaço de respostas desejadas. De forma específica, seja p o número de elementos sensoriais (neurônios de entrada) de uma rede neuronal e q o número de neurônios da camada de saída da rede neuronal. O treinamento aplicado à rede neuronal definirá um mapa do espaço Euclidiano de estímulos p -dimensional, no espaço Euclidiano de respostas desejadas q -dimensional, segundo o seguinte teorema (CYBENKO, 1989; HORNIK et al., 1989):

Seja φ uma função não linear, contínua, limitada e monotonicamente crescente. Seja H_p um hipercubo unitário, $[0, 1]^p$, p -dimensional. O espaço das funções contínuas no interior de H_p será denotado por $C(H_p)$. Então, dada qualquer função $f \in C(H_p)$ e um $\epsilon > 0$, existe um inteiro M e um conjunto de constantes reais α_i , θ_i e w_{ij} , aonde $i = 1, \dots, M$ e $j = 1, \dots, p$, tal que

$$F(x_1, \dots, x_p) = \sum_{i=1}^M \alpha_i \varphi\left(\sum_{j=1}^p w_{ij} x_j - \theta_i\right), \quad (3.32)$$

seja uma aproximação de f , ou seja,

$$|F(x_1, \dots, x_p) - f(x_1, \dots, x_p)| < \epsilon,$$

para todo $x_1, \dots, x_p \in H_p$.

Esse teorema mostra somente a existência, no sentido em que apresenta uma justificativa matemática para a aproximação de uma função arbitrária. A equação 3.32 é diretamente aplicada à rede neuronal direta se

1. A rede possui p elementos sensoriais, na sua camada de entrada e uma camada oculta com M neurônios.
2. Cada neurônio i , da camada oculta, possui um peso sináptico dado por w_{ij} e potencial limite, θ_i .
3. A saída da rede é uma combinação linear das respostas dos neurônios da camada oculta e os $\alpha_1, \dots, \alpha_M$, definem os coeficientes dessa combinação.

A equação 3.32 generaliza apenas a aproximação de funções por uma série finita, estabelecendo que uma simples camada oculta é suficiente para que uma rede neuronal direta produza uma aproximação da função que mapeia o conjunto de estímulos, representado por x_1, \dots, x_p , sobre o conjunto de respostas desejada $F(x_1), \dots, F(x_p)$.

4 - DETERMINAÇÃO DE INTERFACES COM A REDE NEURONAL DIRETA MULTICAMADA

4.1 INTRODUÇÃO

Neste capítulo apresenta-se um método para a simulação da tomada de decisão do intérprete, na tarefa de determinação ou a localização das interfaces em um perfil por meio de uma rede neuronal direta multicamada, treinada com o algoritmo da retro-propagação do erro. Neste caso, a utilização do dado de perfil como sinal de entrada da rede levou a uma concepção para a arquitetura da rede, que possibilitou a sua utilização para o tratamento conjunto de vários sinais que possuem número de amostras diferentes. Para o caso particular da interpretação de perfis apresenta-se uma definição conveniente para o conjunto do treinamento, tal que propiciasse um baixo custo computacional com a conseqüente redução do tempo de treinamento da rede.

Inicia-se este capítulo apresentando formalmente a importância prática e o conceito da expressão interface, após descrevemos a nossa abordagem do problema na forma de um problema de decisão e discutimos a concepção da arquitetura da rede apresentada, bem como, a do conjunto de treinamento. Apresenta-se em seguida alguns dos testes realizados com esta metodologia aplicada sobre dados sintéticos e dados reais.

4.2 INTERFACES NO PERFIL

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 da base das diversas camadas litológicas, depositadas ao longo do tempo, até o limite de perfuração do poço, com o objetivo de determinar a *espessura aparente* dessas camadas. O termo *espessura aparente* foi utilizado no sentido em esta distância na vertical, somente será a espessura verdadeira da camada se essa for plana e horizontal, o que não ocorre na maioria das situações geológicas reais.

A importância do conhecimento da espessura de uma camada pode ser melhor avaliada através da análise da equação 4.1, a qual é, normalmente, utilizada para a avaliação econômica

do volume de hidrocarboneto contido em uma camada reservatório,

$$V_o = (hA)\phi(1 - S_w), \quad (4.1)$$

na qual 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 da rocha, ϕ é a sua 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 da 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 aberto.

Em termos da interpretação de perfis, um termo comumente utilizado para a identificação das formas geométricas no perfil, representativas de eventos geológicos de subsuperfície, seria o de eletrofácies (*electrofacies*) (SERRA & ABBOTT, 1980), o qual descreve o conjunto de respostas dos perfis que caracterizam uma camada rochosa, permitindo a sua distinção das demais. As fácies geológicas convencionais (sedimentar, faunal, etc.) são conceituadas por meio de um conjunto de atributos, os quais são característicos de certas rochas formadas sob condições equivalentes (ambiente). O termo eletrofácie difere do termo fácie, 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 uma característica propriedade petrofísica associada (DOVETON, 1986).

Convencionalmente, o zoneamento (*zonation*) ou a determinação das interfaces em um trecho de perfil é realizado a partir da identificação de distintos *picos* e *vales* característicos, associando-os à presença de uma determinada camada. A separação formal entre zonas adjacentes é localizada no ponto de inflexão da curva do perfil (DOVETON, 1986).

Com a necessária conjugação de diversas fontes de informação, como os testemunhos recuperados, apesar dos problemas da correlação rocha-perfil, que os testemunhos apresentam e/ou a utilização da informação geológica de superfície (afloramentos), bem como se valendo da contribuição de outros perfis e de outros métodos geofísicos e com base na sua experiência da geologia da área, o intérprete procura ao longo do perfil as profundidades das interfaces, não necessariamente nos pontos de inflexão da curva do perfil, mas sim, nas profundidades onde considera terminada a resposta do perfil àquela camada em questão, isto a partir da sua *experiência geológica*. Assim, a tomada de decisão do intérprete de perfis para a localização em profundidade de uma interface é de natureza eminentemente empírica, o que torna a sua simulação em um computador digital através de um algoritmo convencional extremamente complexa.

4.3 A REDE NEURONAL DIRETA MULTICAMADAS

Nesta seção abordaremos a simulação da tomada de decisão do intérprete, na definição do número e no posicionamento das interfaces no perfil, por meio de uma rede neuronal direta multicamada s, treinada com o algoritmo da retro-propagação do erro. Neste caso, a interferência do intérprete no processamento da rede, ocorre de maneira direta, quando ele define explicitamente a resposta desejada da rede neuronal, localizando em um intervalo de perfil, tomado como referência, a posição da interface em profundidade.

A simulação da tomada de decisão do intérprete para a definição das interfaces no perfil será baseada unicamente sobre os dados do próprio perfil, o que acarreta que a rede neuronal deva apresentar, simultaneamente, duas respostas a duas questões distintas que são:

1. O número de interfaces presentes no trecho de perfil apresentado.
2. A localização em profundidade de cada interface.

A utilização do dado de perfil, como única fonte de informação, busca exatamente simular o comportamento do intérprete no seu cotidiano de análise de perfis, da feita que apesar de ter a sua disposição outras fontes de informação, na definição das interfaces, a informação relevante é o perfil.

4.3.1 Arquitetura da Rede Neuronal

A utilização de uma rede neuronal direta, com treinamento supervisionado, para a simulação da tomada de decisão do intérprete na determinação do número e do posicionamento

em profundidade das interfaces em um perfil, foi inspirada nas características dessa classe de redes neuronais na simulação do comportamento do sistema visual humano (LECUN et al., 1990; SEJNOWSKI et al., 1990; SACKINGER et al., 1992; LUTHI et al., 1995).

A definição da arquitetura básica da rede tem início a partir da interpretação do problema da simulação da tomada de decisão do intérprete para a determinação das interfaces em um perfil de poço como um problema de decisão, isto é frente ao perfil, o intérprete decidirá, com base no seu conhecimento geológico da área se um dado ponto do perfil representa ou não uma interface. O que pode ser interpretado como um problema de decisão do tipo binário, ou idealmente com apenas duas alternativas possíveis, *sim*, para uma interface e *não*, para o caso contrário. Essa interpretação do problema condicionará no desenho da arquitetura da rede neuronal na necessidade da existência de um único neurônio na sua camada de saída, o que, em outras palavras, seria a associação direta da resposta binária característica deste neurônio à solução do problema por um especialista. Neste caso, na profundidade onde a rede detectar uma interface, o neurônio da camada de saída, em princípio, estará ativado, produzindo um sinal de saída igual a um. Nos outros casos, este neurônio estará desativado e o seu sinal de saída será nulo.

Uma forma de interpretar os dados de perfil realizando o papel de estímulo (sinal de entrada) de uma rede neuronal direta, será entendê-lo a partir da sua própria sistemática de aquisição, na forma uma série espacial estacionária (LUTHI et al, 1995), similar a uma série temporal estacionária onde a variável tempo é substituída pela variável profundidade. Esta forma de interpretação do dado simplifica em muito o seu relacionamento com a rede neuronal, no sentido em que esta poderá tratá-lo amostra por amostra, na direção do crescimento da profundidade que deixa de ser uma variável do processo. Em termos da arquitetura da rede proposta neste trabalho, admite-se o perfil de poço não como uma série temporal, mas sim como uma sequência discreta finita. Essa interpretação do dado de poço induziu à concepção da camada de entrada da rede ser composta por um único neurônio, o que apresenta ainda a vantagem adicional de permitir uma independência da rede com o número de amostras do perfil. Este fato é de caráter geral e implica na possibilidade da utilização de uma mesma arquitetura de rede neuronal para o processamento de perfis de diferentes poços, os quais certamente possuem diferentes profundidades. Além disso a existência de um único neurônio na camada de entrada permite uma boa flexibilidade na escolha do tamanho do conjunto de treinamento.

Uma questão pertinente à computação envolvida com as redes neuronais, com camada de entrada composta por vários elementos, pouco explorada na literatura, trata sobre a possibilidade da vetorização das operações realizadas durante o processo de treinamento,

bem como na sua fase de operação. Analisaremos esta questão, a partir de uma hipotética, rede neuronal direta, com duas camadas, sendo uma camada de entrada composta por M neurônios e uma camada processadora, composta por N neurônios. Esta rede é treinada sobre um conjunto de estímulos, composto por R vetores com M elementos, que podem ser representados na forma de uma matriz $\overline{\overline{Q}}_{M \times R}$. Considerando que cada elemento da camada de entrada está conectado a cada um dos N neurônios da camada processadora, podemos escrever a matriz dos sinais de saída (sinal direto), $\overline{\overline{A}}_{N \times R}$ da camada processadora, na forma,

$$\overline{\overline{A}}_{N \times R} = \varphi(\overline{\overline{W}}_{N \times M} \overline{\overline{Q}}_{M \times R}). \quad (4.2)$$

Nesta equação, N representa o número de neurônios na camada processadora, R , representa o número de vetores de entrada (estímulos) e M , é o número de elementos de cada vetor de entrada. $\overline{\overline{W}}_{N \times M}$ é a matriz de pesos sinápticos e φ é a função de ativação, associada a cada neurônio. A operação na qual temos interesse é a multiplicação matricial, vista a direita na equação 4.2, a qual será realizada para o cálculo do sinal de erro, quantas vezes forem necessárias, para que se efetive o treinamento da rede a partir da apresentação do conjunto de respostas desejadas, $\overline{\overline{D}}_{N \times R}$, que forma com o conjunto de estímulos o conjunto de treinamento da rede.

RUI-LIN et al (1992) e LUTHI et al (1995), buscaram uma redução do esforço computacional envolvido nessas operações, bem como a solução para o problema da existência de vetores de entrada com diferentes números de elementos, para uma rede com M elementos na sua camada de entrada, através da utilização da camada de entrada da rede funcionando como uma janela móvel (*time-delay layer*), para a entrada dos dados de perfil na forma vetorial, de tal sorte que a cada iteração da fase de treinamento, um novo ponto do perfil é apresentado à rede, entrando na M -ésima posição, todos os pontos anteriores são movidos de uma posição e conseqüentemente, descarta-se o valor do perfil atribuído à primeira posição. A potencial vantagem desta metodologia é transformar a matriz de entrada da rede em um vetor linha ($\overline{\overline{Q}}_{M \times 1}$), conseqüentemente reduzindo a multiplicação matricial na equação 4.2 a uma multiplicação vetorial, computacionalmente mais eficiente. A apresentação dos vários padrões pretendidos seria garantida pela própria dinâmica da janela móvel.

Apesar da redução do tempo de processamento, a técnica da janela móvel apresenta uma enorme redundância na apresentação dos padrões de entrada, uma vez que a diferença entre o padrão atual e o anterior é de somente uma amostra do perfil. Esta redundância é responsável ainda, por um alto tempo de processamento, na fase de treinamento, que se propaga danosamente para a fase de operação, uma vez que M é menor que o número de

amostras do perfil. Tal fato, não ocorre com a arquitetura de rede, com um único neurônio na camada de entrada, que além de tomar partido da vetorização das operações, na fase de treinamento, permite ainda a apresentação à rede neuronal de todo o conjunto de treinamento de uma única vez, na forma de um vetor linha. Para o treinamento com o algoritmo da retro-propagação do erro permite-se que a aprendizagem seja realizada com todo o conjunto de padrões de uma única vez, o que resulta numa maior acurácia no cálculo da direção do vetor gradiente (HAYKIN, 1994).

Para o completar o projeto da arquitetura da rede neuronal, resta a definição do número de neurônios e conseqüentemente o número de camadas ocultas. Esta definição depende fundamentalmente da forma de interpretação do processamento envolvido na rede neuronal e do tipo de problema, com o qual a rede operará. Neste trabalho interpreta-se a rede neuronal, treinada com o algoritmo da retro-propagação do erro na forma de um aproximador universal de funções. Conforme visto no CAP. II sob este ponto de vista necessita-se de apenas uma camada oculta. Por outro lado a definição do número de neurônios nesta camada dependerá exclusivamente da complexidade dos padrões de treinamento.

O número de neurônios da camada oculta é variável e depende fundamentalmente da complexidade do perfil. O critério adotado neste trabalho, com base nos experimentos realizados, foi o de estabelecer o número inicial de neurônios da camada oculta da rede igual ao número de amostras do conjunto de treinamento. Essa forma possibilitou um tempo de treinamento adequado com um bom desempenho na fase de operação no posicionamento das interfaces.

A arquitetura da rede neuronal pode ser resumida na forma

1. A rede neuronal é composta por tres camadas.
2. A camada de entrada é constituída por apenas um neurônio.
3. A camada oculta é composta por um número variável de neurônios, apresentando como função de ativação a função logística ou

$$\varphi(P_j) = \frac{1}{1 + e^{-P_j}}$$

P_j representa o potencial de ativação do neurônio j da camada oculta.

4. A camada de saída possui apenas um neurônio que possui uma função linear como função de ativação

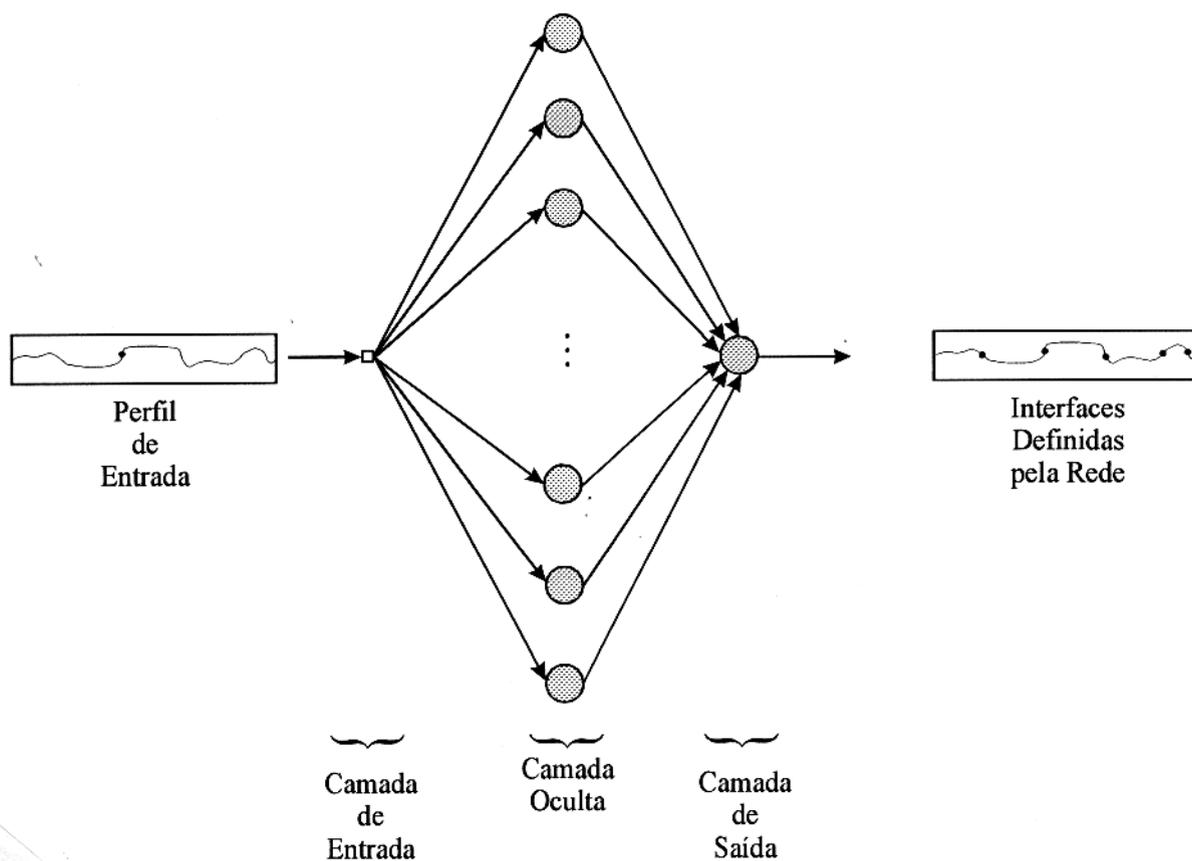


Figura 4.1 - Arquitetura da rede neuronal direta multicamada para a simulação da tomada de decisão do intérprete na determinação das interfaces no perfil.

4.3.2 Conjunto de Treinamento

Um outro aspecto da utilização das redes neuronais para a simulação das operações realizadas por um especialista é a definição do apropriado conjunto de treinamento, tal que forneça à rede um bom conhecimento do ambiente externo, no qual ela está envolvida. Neste sentido, LUTHI et al (1995) apresentaram um conjunto de treinamento formado a partir de um conjunto de estímulos que seria todo o perfil. O conjunto de respostas desejadas seria construído com base na informação de um especialista na geologia da área, tal que na posição definida para a interface (*datum*), seria designado o valor, um e zero para todas as demais posições.

Treinando a rede sobre uma única interface, LUTHI et al. (1995) perceberam que uma interface situada a uma profundidade abaixo daquela de treinamento produzia uma saída semelhante àquela de treinamento. Este fato nos levou a levantar a possibilidade de se reduzir o conjunto de estímulos a um número mínimo de amostras, tal que o tempo de treinamento fosse expressivamente reduzido e que a rede efetivamente produzisse uma resposta aceitável sobre o número e o posicionamento das interfaces em todo o trecho de perfil. Inúmeros testes foram realizados, até que chegamos a uma sistematização considerada razoável para o conjunto de treinamento, de tal forma que a rede adquiriu o conhecimento necessário do seu ambiente externo. Assim sendo, podemos definir o conjunto de treinamento para a simulação da tomada de decisão do intérprete na definição das interfaces no perfil, com as seguintes características

- (a) O conjunto de estímulos é formado por um conjunto de trechos do perfil, contendo interfaces características para todo o perfil e sequências de não-interfaces. As interfaces características que formarão o conjunto de estímulos serão escolhidas a critério do intérprete.
- (b) O conjunto de respostas desejadas] é criado na forma de um conjunto binário, no qual o valor 1 (um) indica a presença de uma interface e o valor 0 (zero) para o caso contrário. A definição da posição da interface no vetor de resposta desejada, pode ser realizada a partir da análise de testemunhos ou do conhecimento empírico do intérprete.

A utilização desse conjunto de treinamento, sobre a arquitetura de rede neuronal vetorizada, mostrou uma redução expressiva do tempo de treinamento, com a utilização do algoritmo original da retro-propagação do erro. No entanto, a utilização de uma variante desse algoritmo, como mostraremos a seguir se mostrou computacionalmente mais eficiente.

4.3.3 Algoritmo de Treinamento

A performance do algoritmo de retro-propagação do erro na sua formulação tradicional como apresentado no CAP. II, mostra em muitos casos práticos uma convergência lenta (JACOBS, 1988). A utilização do algoritmo convencional de retro-propagação do erro no treinamento das redes estimuladas com dados de perfil, apresentou um tempo de convergência, ainda extremamente longo. Para contornar esta situação utiliza-se a associação de duas metodologias para promover a aceleração do processo de treinamento da rede neuronal.

4.3.3.1 Termo de Momento e Adaptação do Parâmetro de Aprendizagem

A convergência do algoritmo de retro-propagação do erro é determinada pela equação abaixo

$$w_{ij}(t + 1) = w_{ij}(t) + \Delta w_{ij}(t). \quad (4.3)$$

O ajuste do peso sináptico $\Delta w_{ij}(t)$ como apresentado no CAP. II é dado pela equação

$$\Delta w_{ij}(t) = \eta e_i(t) \varphi'(P_i) S_j(t). \quad (4.4)$$

O parâmetro de aprendizagem, η , que governa o tempo de treinamento deveria ser escolhido suficientemente pequeno de modo a promover a minimização da função erro E . Entretanto, a adoção de pequenos valores para η , implica em uma convergência extremamente lenta. No caso contrário, para altos valores de η , obtemos a redução do tempo de convergência, porém em contra partida, não temos garantia da minimização da função erro.

A aceleração do processo de convergência e garantia de minimização da função erro, podem ser obtidos com a introdução do termo de momento, α , na equação 4.4, ou como segue

$$\Delta w_{ij}(t) = \eta e_i(t) \varphi'(S_i) S_i(t) + \alpha \Delta w_{ij}(t - 1). \quad (4.5)$$

O termo de momento reduz o tempo de convergência mantendo a estabilidade do processo e evitando oscilações parasitas (RUMELHART & McCLELLAND, 1986; CICHOCKI & UNBEHAU, 1995). Intuitivamente, se a mudança no valor do peso sináptico anterior é alta, adiciona-se uma fração desse valor ao novo peso, acelerando o processo. Tipicamente, o termo de momento deve ser tomado tal que $0 \leq \alpha \leq 1$. Nos experimentos realizados adota-se $\alpha = 0,85$.

Outra modificação do algoritmo tradicional de retro-propagação do erro, que causa uma drástica redução do tempo de processamento é a possibilidade da variação do parâmetro de aprendizagem, η , descrito matematicamente na forma

$$\eta(t) = \begin{cases} a \eta(t-1) & \text{se } E(\bar{w}(t)) \leq E(\bar{w}(t-1)) \\ b \eta(t-1) & \text{se } E(\bar{w}(t)) \leq \rho E(\bar{w}(t-1)) \\ \eta(t-1) & \text{Outros} \end{cases} \quad (4.6)$$

É realizado então, um incremento no valor do parâmetro de aprendizagem de forma empírica, multiplicando-se η por $a = 1,05$, se a função erro (E) a ser minimizada é decrescente, isto é o novo valor calculado do sinal erro é inferior ao anterior. Quando a função erro for crescente, promove-se uma redução do parâmetro de aprendizagem, através da sua multiplicação por $b = 0,7$; isto é, o valor atual do sinal de erro é ρ ($\rho = 1,04$) vezes maior que o valor anterior. Neste, o valor atual do peso sináptico e do sinal de erro serão descartados, o parâmetro de treinamento atualizado e um novo valor do peso sináptico calculado.

4.4 RESULTADOS

A arquitetura de rede neuronal, o conjunto e o algoritmo de treinamento apresentados neste capítulo foram aplicados e avaliados em dados sintéticos e dados reais, como descrito a seguir

4.4.1 Resultados sobre dados sintéticos

A simulação da tomada de decisão do intérprete, para a quantificação e o posicionamento em profundidade das interfaces em um perfil, foi inicialmente estudada sobre dados sintéticos, obtidos a partir do modelo convolucional e do modelo numérico.

4.4.1.1 Resultados do modelo convolucional

No primeiro caso estuda-se o comportamento da rede neuronal direta multicamadas em um perfil sintético obtido com o modelo convolucional a partir da convolução no domínio da profundidade, entre a distribuição ideal da propriedade petrofísica, como mostrado na Figura 4.2 em linha traço-pontilhada e a resposta vertical da ferramenta (DOLL, 1949). Sobre esse perfil o conjunto de estímulos para o treinamento da rede foi escolhido no intervalo de

profundidades de 685 cm a 695 cm, contando com 57 amostras. A rede neuronal foi então desenhada com 57 neurônios na camada oculta e treinada sobre esse conjunto de treinamento. O treinamento se estendeu por 1 000 épocas, onde cada época corresponde a uma apresentação completa de todo o conjunto de treinamento à rede. Mostra-se, na Figura 4.3, quatro instantes da fase de treinamento da rede. Na Figura 4.2, mostra-se as interfaces determinadas pela rede neuronal, marcadas com círculos escuros. Observa-se que a rede treinada foi capaz de simular convenientemente, a tomada de decisão do intérprete para a definição das interfaces no perfil, como se pode verificar pela coincidência entre o posicionamento das interfaces definidas pela rede e as descontinuidades no perfil da distribuição ideal da propriedade petrofísica.

4.4.1.2 Resultados do modelo numérico

Nas Figura 4.4 e Figura 4.7, mostra-se a aplicação da metodologia de redes neurais diretas, aqui apresentada para os modelos numéricos da ferramenta de espectrometria de raios gama natural (SILVA, 1993).

Na Figura 4.4, estuda-se um caso clássico da interpretação de perfis, que podemos denominar de *ruído geológico*, para os casos de difícil localização de uma interface. Neste exemplo toma-se o conjunto de estímulos no intervalo de 400 cm a 465 cm, o que resultou em uma arquitetura de rede, com 66 neurônios na sua camada oculta. O objetivo da escolha desse conjunto de treinamento era o de verificar a possibilidade da passagem do conhecimento de uma transição do perfil, na forma escada, para a rede neuronal, que assim seria sensível à mesma transição encontrada no intervalo de 50 cm a 190 cm. Isto não foi possível, visto que a rede foi sensível apenas ao contraste entre os valores de interface e não-interface, uma vez que para o conjunto de respostas desejadas, como aqui definido, todo o intervalo entre interfaces é considerado como não-interface, independente de suas características peculiares. No entanto, apesar da rede não ser sensível às transições na forma escada, ela foi suficientemente treinada, para o posicionamento das demais interfaces presentes neste trecho de perfil. Quatro instantes do treinamento desta rede neuronal que se estendeu a um total de 1 500 épocas são mostrados na Figura 4.5. Na Figura 4.6, estuda-se o comportamento da rede neuronal multicamadas para o tratamento com dados ruidosos. Neste caso, apresenta-se o mesmo perfil mostrado na Figura 4.4, contaminado com ruído branco, com média zero e variância igual a um. Observa-se que o comportamento da rede não foi substancialmente alterado.

Na Figura 4.7, mostra-se outro exemplo da aplicação de uma rede neuronal direta, para a identificação e posicionamento das interfaces em um modelo numérico de perfil. O trecho de perfil adotado para o treinamento foi escolhido no intervalo de 280 cm a 420 cm, num total de 140 amostras. Neste caso, estuda-se a possibilidade de redução do número de neurônios

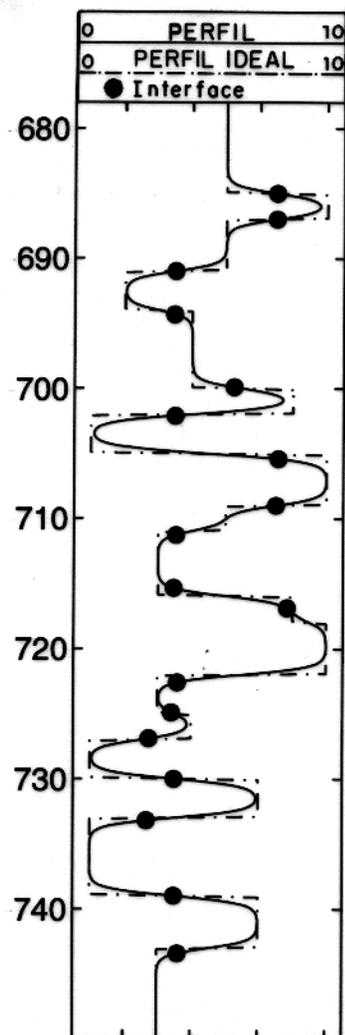


Figura 4.2 - Determinação de interfaces em modelos convolucionais. A figura mostra a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético (linha cheia) e as interfaces determinadas pela rede neuronal direta multicamadas, marcadas com círculos escuros. As profundidades estão marcadas em centímetros.

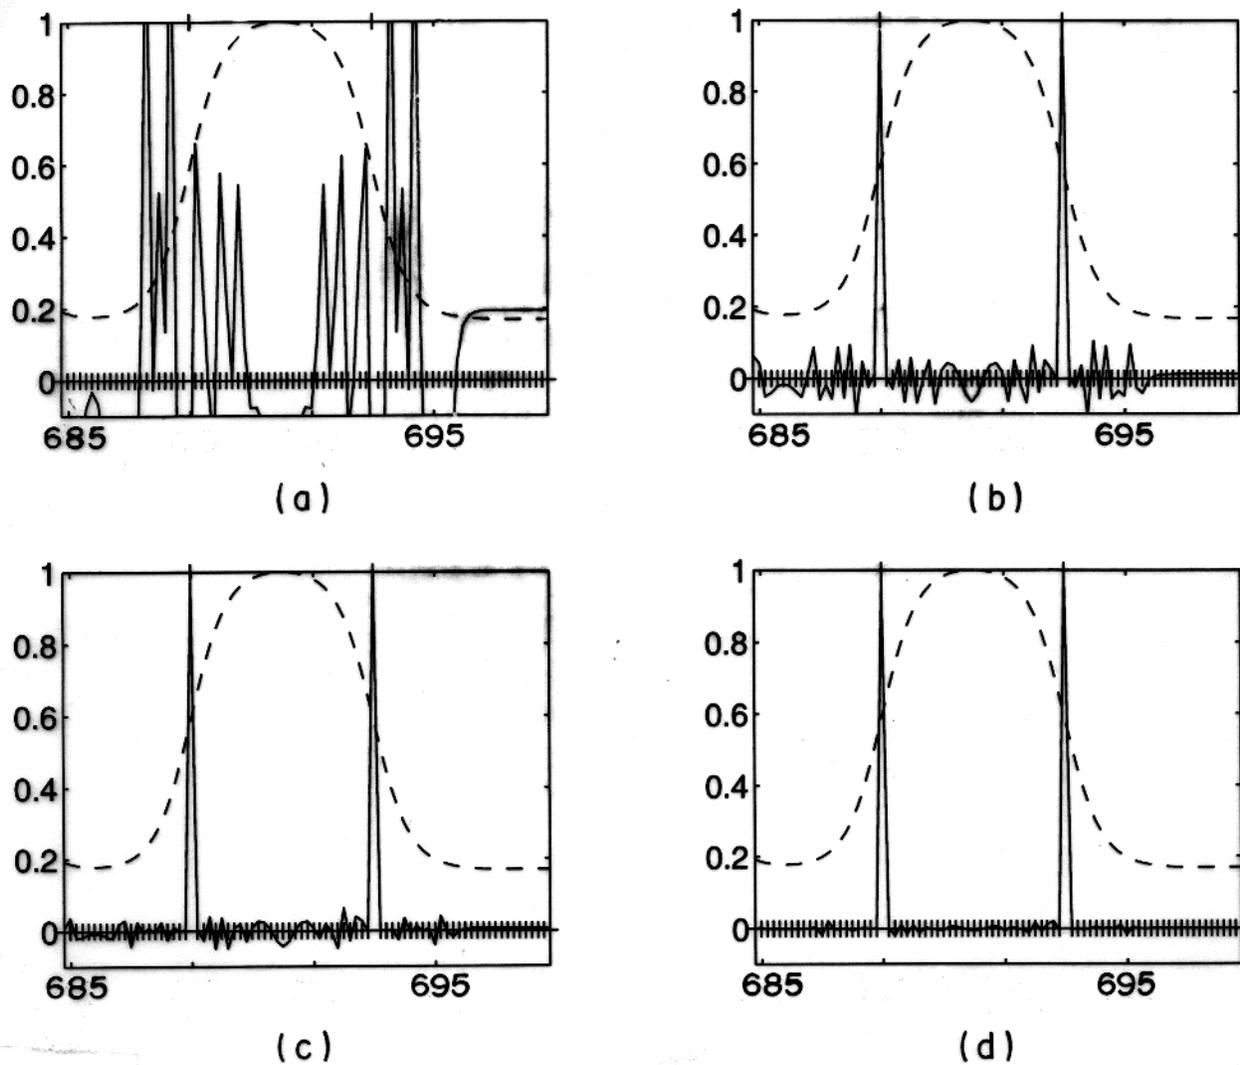


Figura 4.3 - Instantes do treinamento da rede neuronal. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas está marcado com cruzes e a linha cheia representa a resposta da rede. (a) 50 épocas. (b) 250 épocas. (c) 750 épocas. (d) 1.000 épocas.

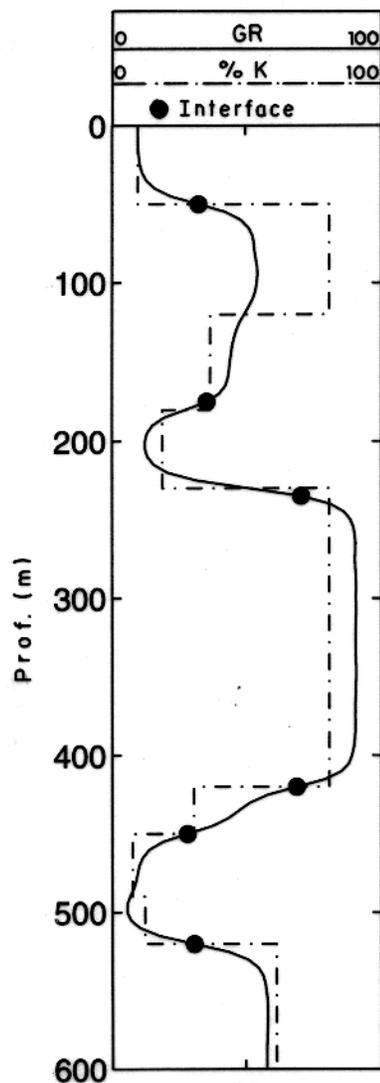


Figura 4.4 - Determinação de interfaces em modelos numéricos. A figura mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neural direta, marcadas com círculos escuros.

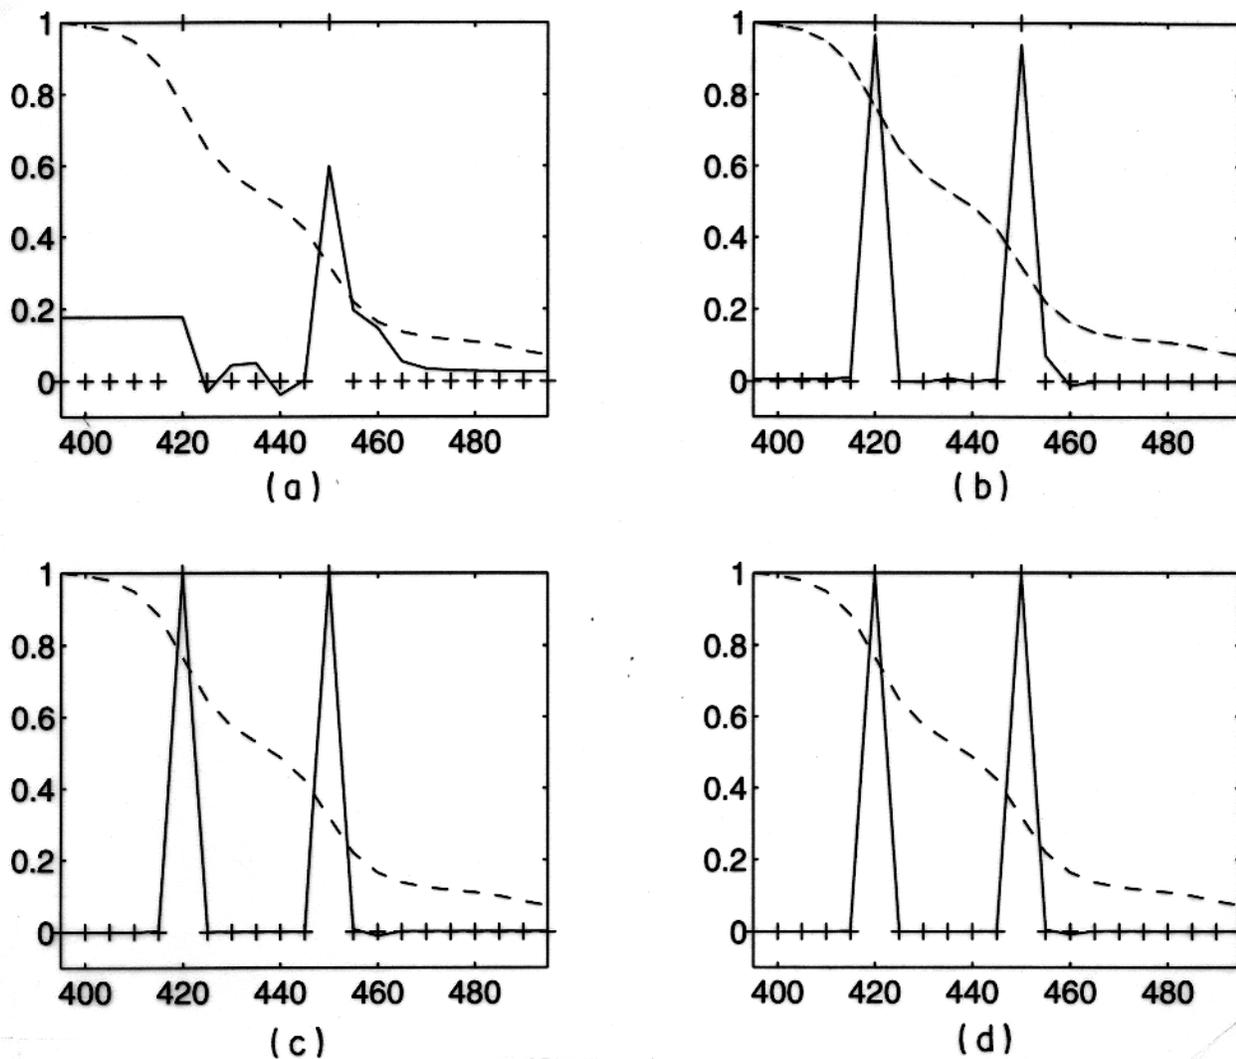


Figura 4.5 - Instantes do treinamento da rede neuronal. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas está marcada com cruzeiros e a linha cheia, representa a resposta da rede. (a) 50 épocas. (b) 250 épocas. (c) 750 épocas. (d) 1 500 épocas.

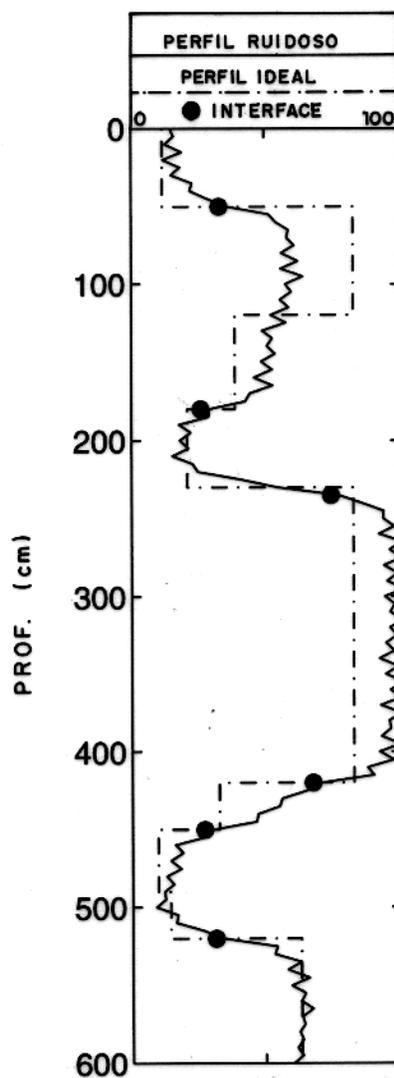


Figura 4.6 - Determinação de interfaces em modelos numéricos com ruído. A figura mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal direta, marcadas com círculos escuros.

da camada oculta da rede, a partir do número padrão, que adota-se como sendo igual ao número de amostras do trecho de perfil adotado como conjunto de estímulos da rede. A redução do número de elementos processadores na camada oculta tem o papel de promover uma drástica redução do tempo de treinamento da rede, mas por outro lado implica em uma sensível redução na capacidade de memorização da rede. Com isto, o objetivo foi o de buscar o menor número de neurônios na camada oculta, capazes de armazenar convenientemente o padrão de interface aplicado na fase de treinamento e apresentasse também boa generalização. Neste caso realiza-se testes sucessivos, reduzindo a cada teste o número de neurônios da camada oculta de cinco elementos processadores. Assim a Figura 4.7, mostra a simulação do comportamento do intérprete através de uma rede neuronal com apenas vinte neurônios na sua camada oculta, apresentando o mesmo resultado que a rede convencional com 140 neurônios na camada oculta. Na Figura 4.8 são apresentados quatro instantes desse treinamento, que se estendeu por 800 épocas.

Na Figura 4.9, explora-se a possibilidade de uma rede neuronal, treinada sobre um perfil, ser capaz de simular o comportamento do intérprete frente a um novo perfil, pertencente à mesma área. A partir de uma rede treinada, sobre o perfil mostrado na Figura 4.7, aplica-se, unicamente na fase de operação o perfil mostrado na Figura 4.4. O resultado dessa experiência está mostrado na Figura 4.9-B, que apresenta a localização das interfaces em posições próximas daquelas mostradas na Figura 4.4. Em função da informação armazenada na rede neuronal, pelo conjunto de estímulos na fase de treinamento, a transição em escada nas profundidades de 50 a 190, foi devidamente encontrada, no entanto a transição, na profundidade de 400 a 465, não foi encontrada, com a rede apresentando a existência de uma única interface neste trecho.

4.4.2 Resultados sobre dados reais

Na avaliação do comportamento da rede direta multicamadas sobre dados reais de perfil, utiliza-se os perfis de raio gama natural pertencentes ao membro Lower Lagunillas, da formação Lagunillas, bloco IV do campo de Bachaquero, na Venezuela. O número e a posição em profundidade das interfaces, foram obtidos da interpretação de especialistas na geologia da área (BRYANT & VILLARROEL, 1994).

Mostra-se na Figura 4.10 quatro instantes do treinamento de uma rede neuronal direta, com 120 neurônios na sua camada oculta desenhada para a simulação da interpretação no poço w991. O treinamento foi realizado no intervalo de 3224 m a 3234 m e estendeu por 5 000 épocas, devido à complexidade do dado real. Na Figura 4.11, mostra-se as interfaces definidas pelo intérprete marcadas com asteriscos e aquelas definidas pela rede neuronal, marcadas com

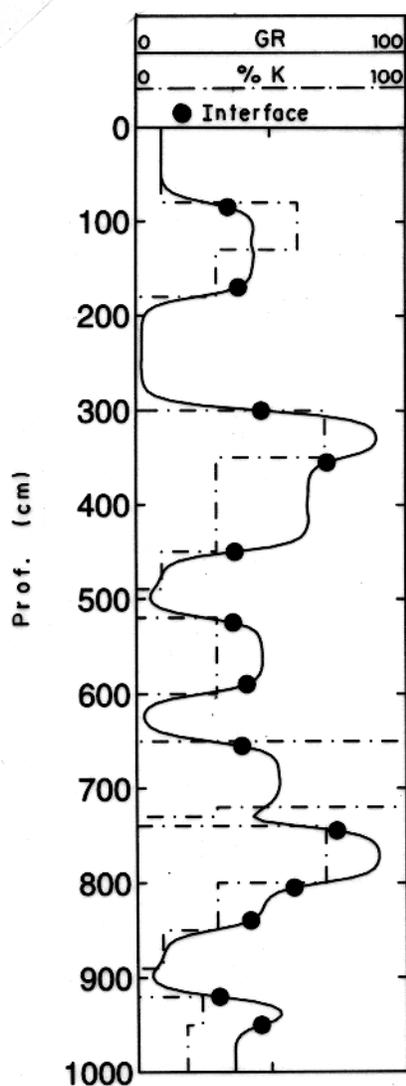


Figura 4.7 - Determinação de interfaces em modelos numéricos. A figura mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal direta, marcadas com círculos escuros.

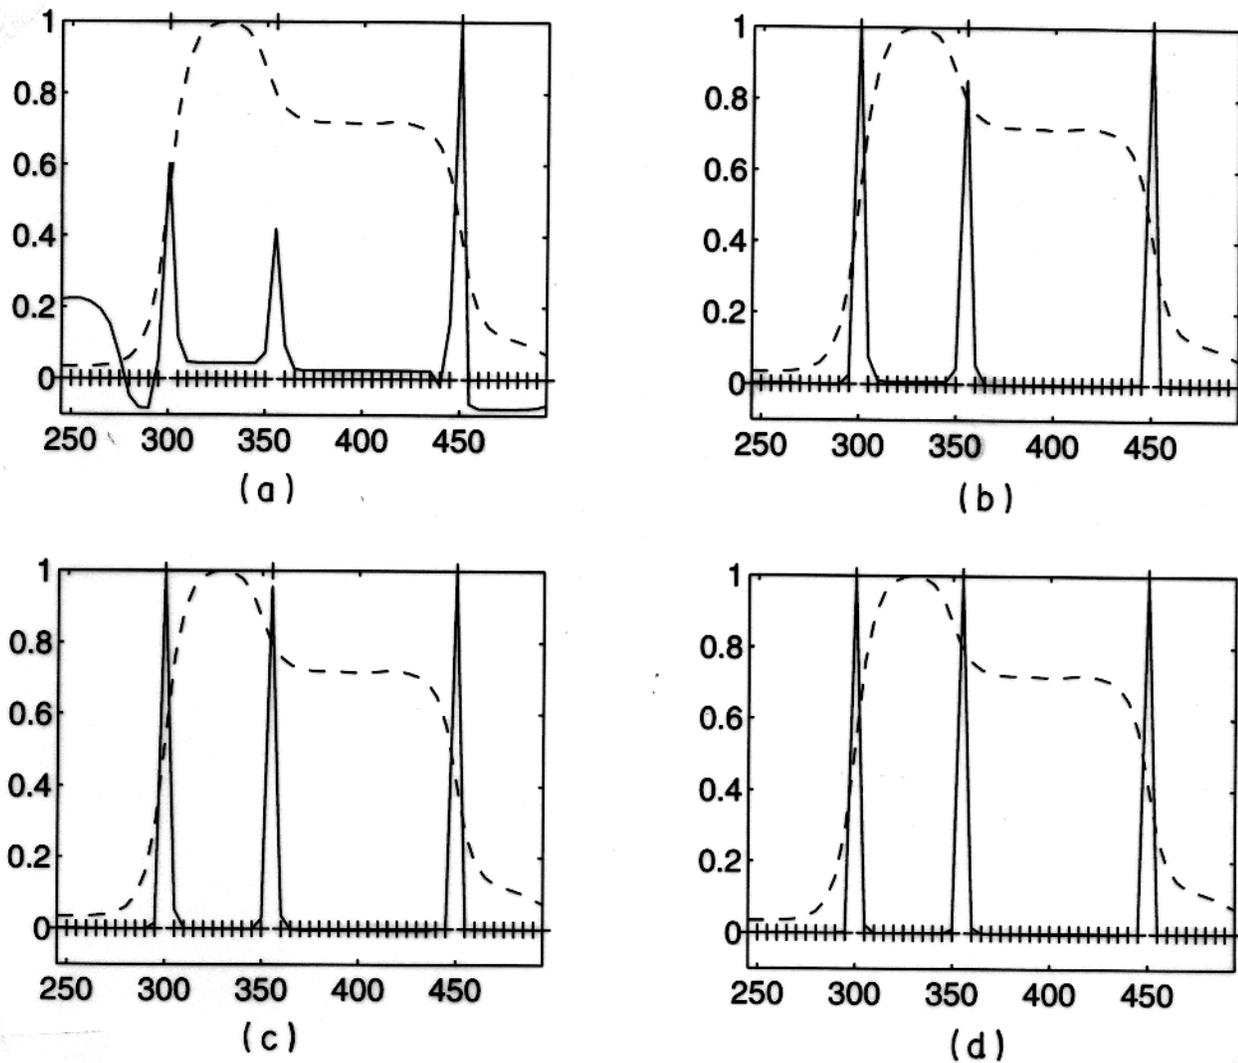


Figura 4.8 - Instantes do treinamento da rede neuronal. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas esta marcada com cruces e a linha cheia, representa a resposta da rede. (a) 50 épocas. (b) 250 épocas. (c) 500 épocas. (d) 800 épocas.

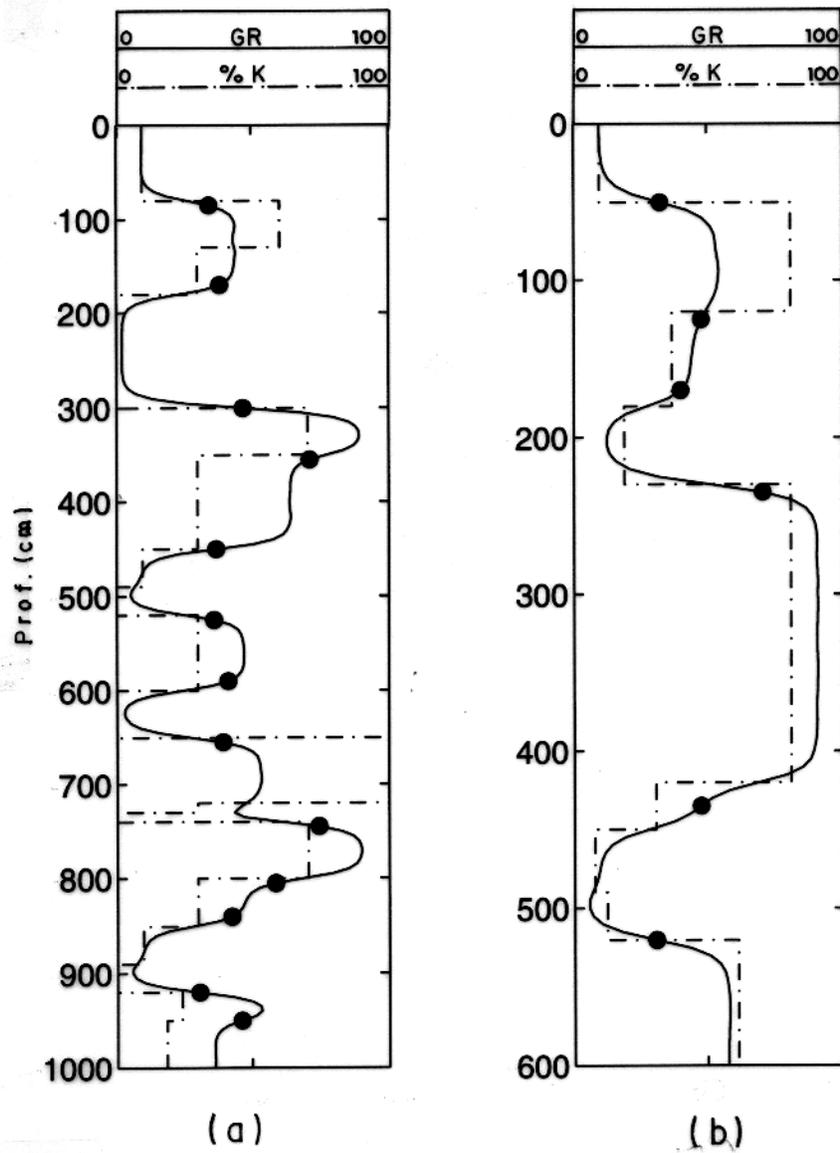


Figura 4.9 - (a) Perfil utilizado na fase de treinamento da rede. (b) Perfil utilizado na fase de operação da rede. As interfaces determinadas pela rede estão marcadas com círculos escuros.

círculos escuros. Podemos observar um ajuste razoável entre as duas situações, o que também pode ser observado através da Tabela 4.1.

Um experimento semelhante, realizado sobre o perfil do poço w1112, está mostrado na Figura 4.12, com uma rede neuronal com 120 neurônios na sua camada oculta e com o treinamento se estendendo a 4 000 épocas como mostrado na Figura 4.13. A tabela Tabela 4.2, mostra a comparação entre as profundidades das interfaces, definidas pelo intérprete e pela rede neuronal.

Na Figura 4.14, mostra-se um exemplo que mostra a possibilidade do conhecimento das interfaces adquiridos em um poço tomado como referência ser estendido a outros poços da área. Neste exemplo, treina-se uma rede neuronal com 120 elementos processadores na sua camada oculta sobre o conjunto de treinamento utilizado para o poço w1112. Na fase de operação apresenta-se o perfil do poço w991. Os resultados, conforme a Figura 4.14, são semelhantes.

4.5 CONCLUSÕES

A utilização de uma rede neuronal direta multicamadas com treinamento supervisionado, para a simulação do comportamento do intérprete, se mostrou bastante eficaz nos exemplos mostrados.

A performance da rede neuronal direta é condicionado pelo seu treinamento em função da escolha, pelo intérprete, do conjunto de estímulos, que em última análise é o responsável direto pelo conhecimento armazenado na rede e conseqüentemente pela sua eficiência na fase de operação.

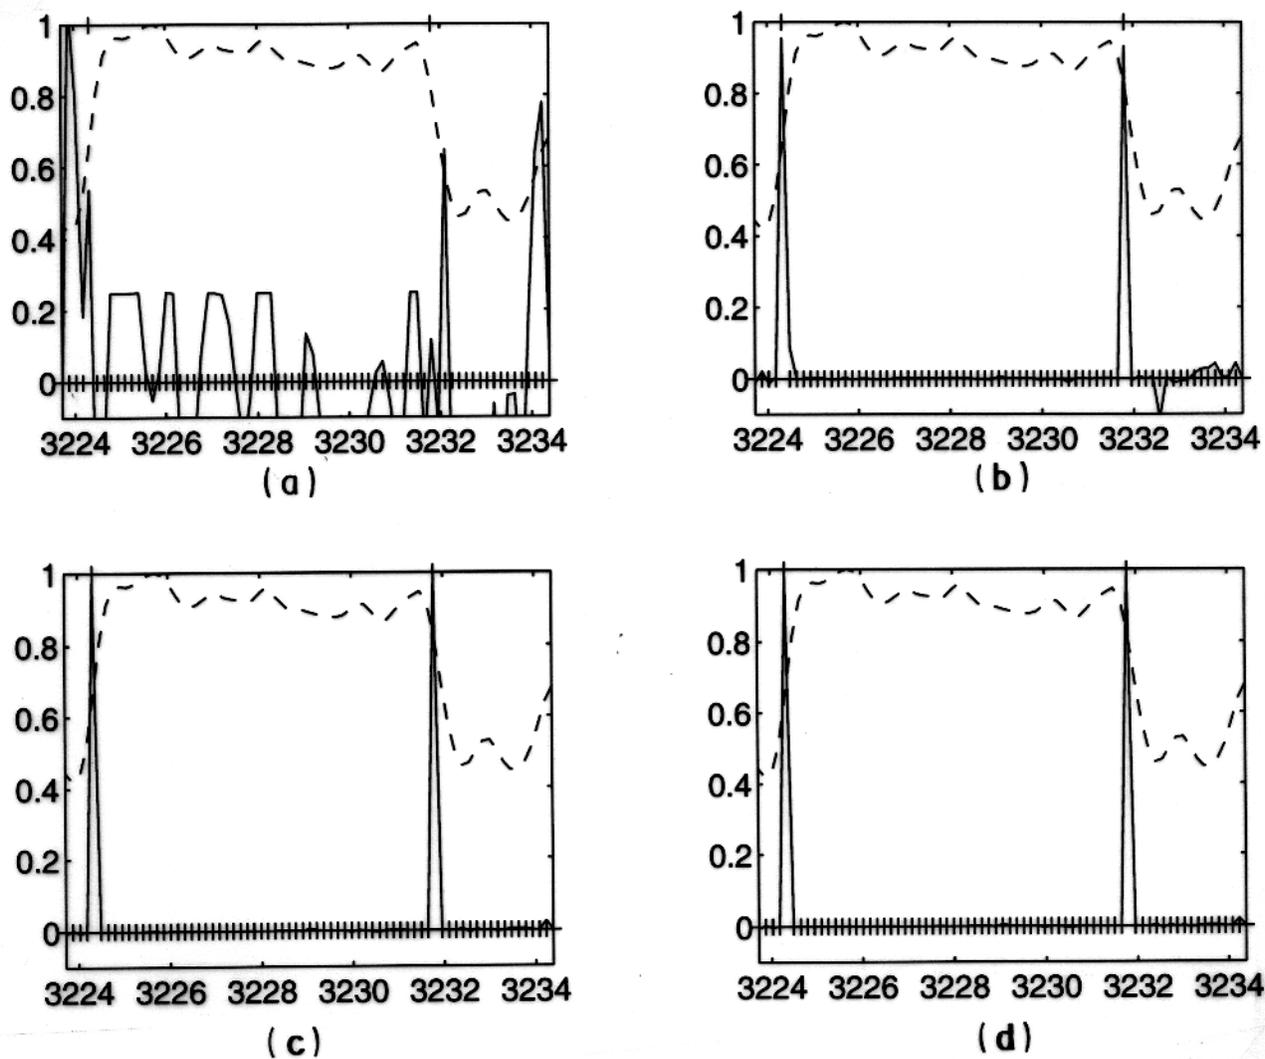


Figura 4.10 - Instantes do treinamento da rede neuronal para o poço w991. No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas esta marcada com cruces e a linha cheia, representa a resposta da rede. (a) 50 épocas. (b) 1 000 épocas. (c) 2 500 épocas. (d) 5 000 épocas.

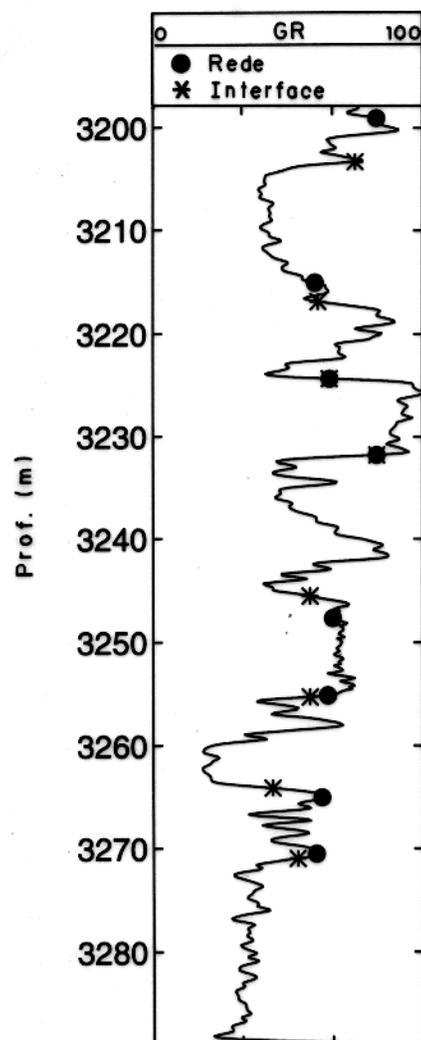


Figura 4.11 - Determinação de interfaces em um perfil do poço w991. A figura mostra o perfil de raio gama natural, as interfaces definidas a partir do intérprete, marcadas com asteriscos e as interfaces definidas pela rede neuronal, marcadas com círculos escuros

Tabela 4.1 - Comparação das profundidades (em metros) das interfaces determinadas pelo interprete e pela rede neuronal direta para o poço w991

Interprete	Rede Neuronal	Ajuste (%)
3 203,3	3 198,2	0,1590
3 216,8	3 216,5	0,0090
3 224,1	3 223,5	0,0180
3 231,8	3 232,5	-0,020
3 245,5	3 243,3	0,0670
3 255,2	3 255,4	-0,006
3 264,1	3 266,3	-0,067
3 271,0	3 270,5	0,0150

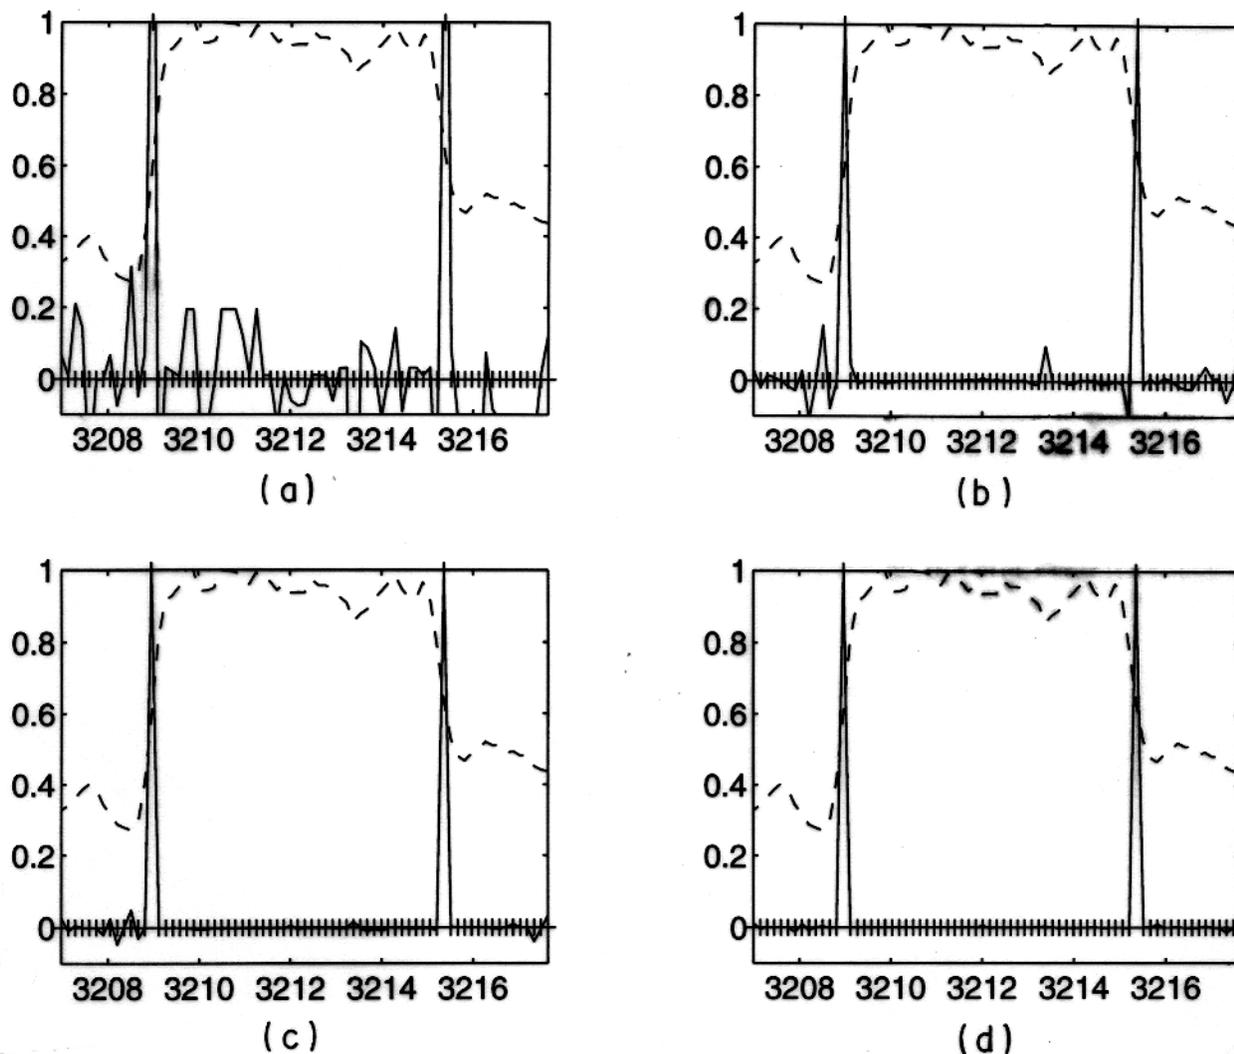


Figura 4.12 - Instantes do treinamento da rede neuronal para o poço w1112 No eixo horizontal estão marcadas as profundidades referentes ao intervalo de treinamento e na vertical os valores de saída da rede. A linha pontilhada mostra o conjunto de estímulos. O conjunto de respostas desejadas está marcada com cruzes e a linha cheia, representa a resposta da rede. (a) 500 épocas. (b) 1 000 épocas. (c) 2 500 épocas. (d) 4 000 épocas.

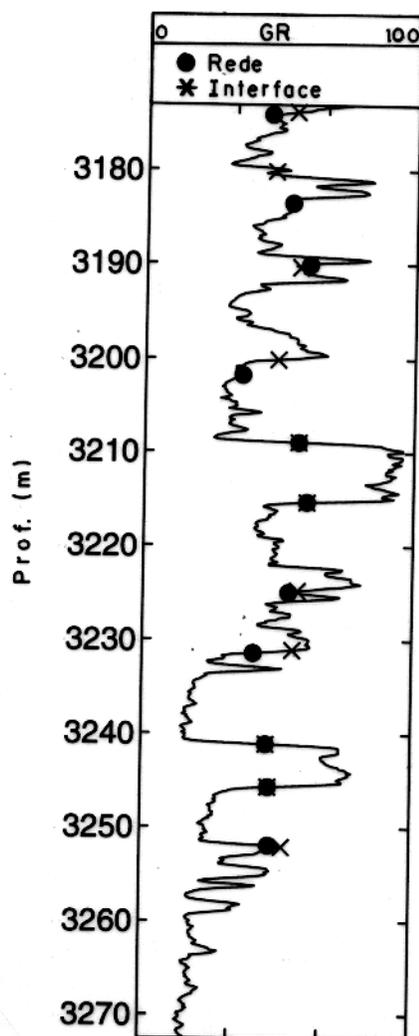


Figura 4.13 - Determinação de interfaces em um perfil do poço w1112. A figura mostra o perfil de raio gama natural, as interfaces definidas a partir do intérprete, marcadas com asteriscos e as interfaces definidas pela rede neuronal, marcadas com círculos escuros

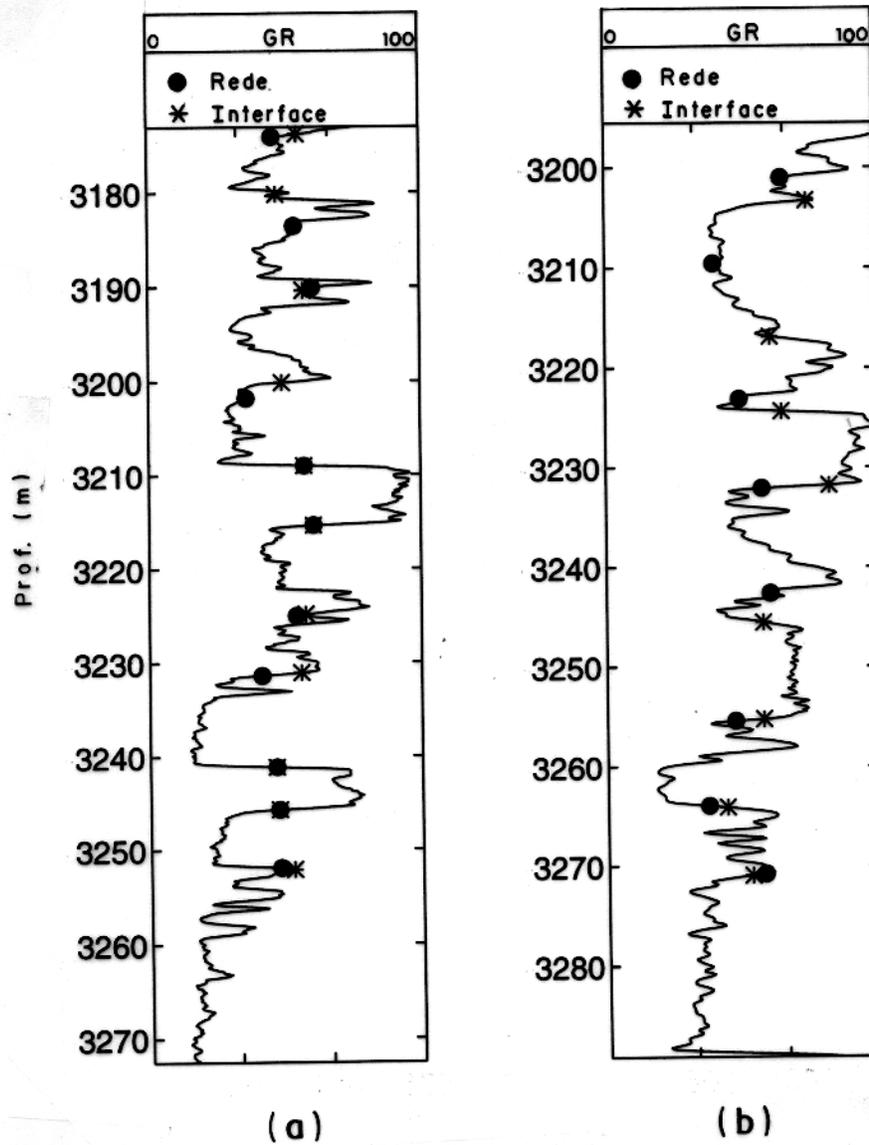


Figura 4.14 - (a) Perfil utilizado na fase de treinamento da rede (w1112). (b) Perfil utilizado na fase de operação da rede (w991). As interfaces determinadas pela rede estão marcadas com círculos escuros.

Tabela 4.2 - Comparação das profundidades (em metros) das interfaces determinadas pelo interprete e pela rede neuronal direta para o poço w1112.

Interprete	Rede Neuronal	Ajuste (%)
3 173,7	3 173,9	-0,006
3 180,1	3 183,1	-0,094
3 190,3	3 190,8	-0,015
3 200,1	3 198,0	0,065
3 209,0	3 209,0	0,0
3 215,3	3 215,3	0,0
3 224,8	3 223,1	0,052
3 231,0	3 229,8	0,03
3 241,1	3 241,1	0,0
3 245,7	3 245,7	0,0
3 251,7	3 251,9	-0,006

5 - DETERMINAÇÃO DE INTERFACES COM A REDE NEURONAL DE HOPFIELD

5.1 INTRODUÇÃO

Neste capítulo, aborda-se novamente um método para a simulação da tomada de decisão do interprete, para a determinação das interfaces no perfil por meio das redes neuronais artificiais. Neste caso estuda-se a possibilidade da simulação do comportamento do especialista ser realizado a partir de um modelo matemático para o perfil de poço e a quantificação e posicionamento vertical das interfaces serem tratados então, na forma de um problema de otimização, através da dinâmica do processamento da rede neuronal de HOPFIELD.

5.2 REDE NEURONAL RECORRENTE DE HOPFIELD

A rede neuronal de HOPFIELD é classificada como do tipo recorrente e opera de modo não supervisionado. Ela pode ser visualizada de maneira ampla como um sistema conexionista, onde os neurônios e as conexões entre eles (sinapses) são utilizadas para codificar as informações que descrevem o problema e as qualidades que a sua solução deve apresentar (BARBOSA & CARVALHO, 1992). Estas características, tornam a rede neuronal de HOPFIELD, extremamente útil para a solução de problemas de otimização combinatória.

A ideia básica de HOPFIELD foi de associar uma função, chamada *Função Energia* ao comportamento da rede neuronal. HOPFIELD mostrou a existência de um isomorfismo entre a função energia associada à rede neuronal e a energia associada ao modelo do spin do vidro (*spin glass model*), que é remanescente de alguns modelos simples de materiais magnéticos encontrados na mecânica estatística (HOPFIELD, 1982). Ele mostrou ainda, que o processo dinâmico aplicado à rede garante a sua convergência para um mínimo local desta energia. Em outras palavras, a existência da função energia permite a localização de cada padrão a ser armazenado pela rede em um mínimo desta função permitindo então, que um procedimento dinâmico atuando sobre os estados dos neurônios, buscasse este mínimo. Esta operação implica que a rede poderá resgatar um padrão previamente armazenado através da apresentação de um padrão ruidoso ou incompleto.

A arquitetura básica de HOPFIELD (Figura 5.1) consiste de um conjunto de neurônios,

agrupados em uma única camada, os quais calculam a soma ponderada de suas entradas e as limitam, tal que produzam uma saída no intervalo $[0, 1]$. A função de ativação utilizada é a função sinal. A saída de qualquer neurônio é conectada com a entrada de todos os outros neurônios (feedback), com exceção dele próprio. Assim a matriz de pesos sinápticos w é simétrica e possui diagonal principal nula. O elemento w_{ij} , representa o peso da conexão entre o neurônio i e o neurônio j . A versão padrão da rede de HOPFIELD, utiliza o modelo de neurônio de MCCULLOCH & PITTS (1943). A obtenção das informações armazenadas na rede é realizada via um processo dinâmico de atualização dos estados de um neurônio, tomado aleatoriamente, assim apenas um único neurônio tem o seu estado atualizado a cada instante. Este comportamento é próprio das redes de HOPFIELD com neurônios binários.

5.2.1 Rede Binária de HOPFIELD

Seja N_i um neurônio binário, o seu estado S_i em um instante de tempo qualquer é um valor no conjunto $\{0, 1\}$, determinado na forma

$$S_i = \begin{cases} 0, & \text{se } P_i \leq \theta_i \\ 1, & \text{se } P_i > \theta_i, \end{cases} \quad (5.1)$$

onde θ_i é o potencial limite e P_i representa o potencial de entrada no neurônio N_i , que depende dos estados dos demais neurônios através da equação,

$$P_i = \sum_{j \neq i} w_{ij} S_j + I_i. \quad (5.2)$$

Nesta equação, I_i , corresponde à entrada externa ao neurônio N_i e w_{ij} ao peso da conexão entre o neurônio N_i e o neurônio N_j .

Para $w_{ij} = w_{ji}$ mostra-se (HOPFIELD, 1982) que para todo $1 \leq i, j \leq m$ a evolução dos estados dos neurônios com o tempo, segundo a equação 5.1. Isto a partir de um estado inicial qualquer e desde que apenas um neurônio seja atualizado por vez, o que promove uma minimização local da função energia (E) (HOPFIELD, 1982) dada por

$$E = -\frac{1}{2} \sum_i \sum_{j \neq i} w_{ij} S_i S_j - \sum_i I_i S_i + \sum_i \theta_i S_i. \quad (5.3)$$

A minimização de E é local; ou seja, leva a um estado da rede que é estável por meio do decrescimento permanente de E .

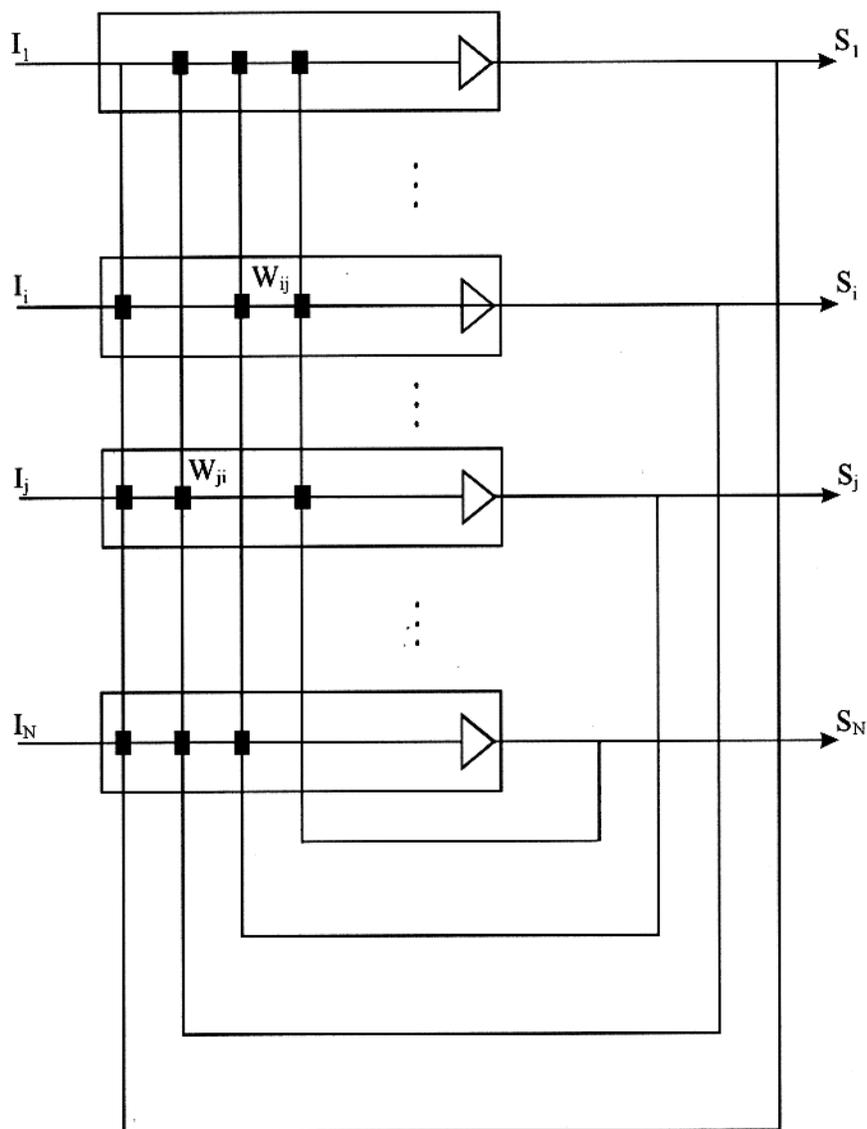


Figura 5.1 - Arquitetura básica da rede neuronal de HOPFIELD.

5.2.2 Função Energia

Uma das principais contribuições de HOPFIELD, foi estabelecer o conceito de uma função energia (equação 5.3) associada ao comportamento dinâmico da rede neuronal com a propriedade de ser monotonicamente decrescente com a variação dos estados dos neurônios no tempo, o que ocorrerá até que um mínimo local da função energia seja alcançado. O gráfico da função energia descreve a dependência da função E com o estado geral da rede especificada por uma particular matriz de pesos sinápticos w_{ij} (HAYKIN, 1994).

Seja $\Delta E_i(t)$, a variação da função energia, no instante t , devido à mudança de estado do neurônio N_i de $S_i(t-1)$ para $S_i(t)$ definida por

$$\Delta S_i(t) = S_i(t) - S_i(t-1). \quad (5.4)$$

A partir da equação 5.3 chega-se a relação

$$\Delta E_i(t) = - \left(\frac{1}{2} \sum_{j \neq i} w_{ij} S_j(t) + I_i \right) \Delta S_i(t). \quad (5.5)$$

Vemos que a quantidade entre parênteses é exatamente a equação 5.2, de modo que podemos escrever a equação 5.5 como

$$\Delta E_i(t) = -P_i(t) \Delta S_i(t). \quad (5.6)$$

A análise é simples, para mostrar que o comportamento da função energia é sempre decrescente, basta que $\Delta E_i(t) \leq 0,0$ para todos os possíveis estados do neurônio N_i . Assim, se $\Delta S_i(t) < 0$, significa que $S_i(t-1) = 1$ e $S_i(t) = 0$. Pela equação 5.1 verifica-se que $P_i(t) < 0,0$, então levando este resultado a equação 5.6 concluímos que $\Delta E_i(t) < 0,0$. A outra possibilidade seria, $\Delta S_i(t) > 0,0$, significando que $S_i(t-1) = 0,0$ e $S_i(t) = 1,0$, novamente pela equação 5.1, temos $P_i(t) > 0,0$ e pela equação 5.6 obtemos $\Delta E_i(t) < 0,0$. Como a rede neuronal binária de HOPFIELD opera assincronamente, ou seja, apenas o estado de um único neurônio é atualizado a cada instante de tempo, sempre teremos $\Delta E_i(t) \leq 0,0$, o que significa que a dinâmica da rede se estabilizará em um estado para o qual a função energia é localmente minimizada.

5.3 SIMULAÇÃO ATRAVÉS DA REDE NEURONAL BINÁRIA DE HOPFIELD

A rede neuronal binária de HOPFIELD é classificada como uma rede neuronal artificial recorrente e sua principal característica é apresentar uma função energia capaz de descrever

o seu comportamento dinâmico em função dos seus parâmetros livres ou característicos, que são:

1. w_{ij} é o peso sináptico entre os neurônios i e j da camada recorrente.
2. I_i é a entrada externa no neurônio i .
3. θ_i é o potencial limite no neurônio i .

A função energia é escrita na forma

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j \neq i=1}^N w_{ij} S_i S_j - \sum_{i=1}^N I_i S_i + \sum_{i=1}^N \theta_i S_i. \quad (5.7)$$

A rede neuronal de HOPFIELD, como foi originalmente projetada, não tinha especificamente o objetivo da simulação do comportamento de um especialista. No entanto, ela apresenta uma performance excepcional para a solução de problemas de otimização (BARBOSA & CARVALHO, 1992). Um problema de otimização pode ser descrito como sendo a minimização de uma função objeto (MENKE, 1984). A função a ser minimizada pode ser escrita como uma medida do ajuste ou do desvio (erro) entre o dado observado e o modelo determinístico (GIANNAKIS et al., 1989), na forma

$$\bar{E} = \frac{1}{2} \sum_{k=1}^N [y_k - \bar{y}_k]^2. \quad (5.8)$$

Na qual y_k representa o dado observado e \bar{y}_k é o modelo determinístico.

O principal passo para a utilização das redes neuronais de HOPFIELD, para a solução de um problema de otimização é relacionar a função objeto característica do problema à função energia associada a rede neuronal (BARBOSA & CARVALHO, 1992).

Assim, para escrevermos o problema da simulação do comportamento do interprete para a determinação das interfaces no perfil através da rede neuronal de HOPFIELD, na forma de um problema de otimização necessita-se adotar um modelo determinístico. Para tanto assumimos o modelo convolucional para descrever o perfil petrofísico de poço aberto na forma

$$\bar{y}_k = \sum_{i=1}^N p_i g_{k-i} + \eta_k. \quad (5.9)$$

Nesta equação, \bar{y}_k representa o perfil petrofísico sintético, p_k a a distribuição ideal da propriedade petrofísica com a profundidade, g_k a resposta vertical da ferramenta e η_k o ruído branco, aditivo e instrumental. Normalmente, a sequência p_k é representada na forma de uma função degrau, na qual introduziremos um ponto exatamente na descontinuidade, de modo a caracterizar explicitamente a presença das interfaces. Reescrevemos, a sequência p_k na forma

$$p_k = c_k + r_k \left(\frac{c_{k-1} + c_{k+1}}{2} - c_k \right), \quad (5.10)$$

onde a sequência $r_k \in \{0, 1\}$ caracteriza a posição em profundidade das interfaces e pode ser determinística ou aleatória de tal forma que se $r_k = 1$ encontra-se uma interface de amplitude dada por $(\frac{c_{k-1} + c_{k+1}}{2})$. Se $r_k = 0$ encontra-se uma camada considerada homogênea e isotrópica, apresentando uma amplitude constante igual a c_k .

Assim estamos prontos para escrever a função objeto para o nosso problema desprezando o termo de ruído na forma

$$\bar{E} = \frac{1}{2} \sum_{k=1}^N \left\{ y_k - \sum_{i=1}^N \left[c_i + r_i \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) \right] g_{k-i} \right\}^2. \quad (5.11)$$

Deste modo, o problema da simulação da determinação das interfaces no perfil por um especialista pode ser agora tratado, como o problema de otimização, cujo objetivo da minimização da função \bar{E} é o da obtenção da sequência r_k , que descreve o posicionamento das interfaces.

O passo seguinte é o de associar a equação 5.11 à função energia da rede neuronal de HOPFIELD de modo tal que a característica binária da sequência r_i será associada diretamente aos estados binários dos neurônios da rede neuronal e a sua dinâmica se responsabilizará pela minimização local de \bar{E} . Para isto expandimos o quadrado na equação 5.11 e desprezando os termos independentes de r_i , tem-se que

$$\begin{aligned} \bar{E} = & \frac{1}{2} \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) \left(\frac{c_{j-1} + c_{j+1}}{2} - c_j \right) g_{k-i} g_{k-j} r_i r_j \\ & + \sum_k \sum_{i=1}^N \left(\sum_{j=1}^N c_j g_{k-j} - y_k \right) \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) g_{k-i} r_i. \end{aligned} \quad (5.12)$$

Para que \bar{E} seja associada à função energia de uma rede neuronal binária de HOPFIELD, para a determinação da sequência r_i , que representa o posicionamento das interfaces geológicas

em profundidade, teremos que considerar a existência dos termos $w_{ii} \neq 0$ na expressão de \bar{E} que não existem na função energia (equação 5.7). Para tanto, adiciona-se o termo abaixo ao lado esquerdo da equação 5.12

$$-\frac{1}{2} \sum_{i=1}^N \sum_{k=1}^N \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right)^2 g_{k-i}^2 r_i (r_i - 1)$$

É fácil ver que este termo em uma rede neuronal de HOPFIELD com neurônios binários é sempre nulo. Assim sendo podemos escrever a equação 5.12 na forma

$$\begin{aligned} \bar{E} = & \\ & -\frac{1}{2} \sum_{i=1}^N \sum_{j \neq i=1}^N \left[-\sum_{k=1}^N \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) \left(\frac{c_{j-1} + c_{j+1}}{2} - c_j \right) g_{k-i} g_{k-j} \right] r_i r_j \\ & - \sum_{i=1}^N \left[\sum_{k=1}^N \left(y_k + \frac{1}{2} \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) g_{k-i} \right) \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) g_{k-i} \right] r_i \\ & + \sum_{i=1}^N \left[\sum_{k=1}^N \left(\sum_{j=1}^N c_j g_{k-j} \right) \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) g_{k-i} \right] r_i. \end{aligned} \quad (5.13)$$

Fazendo agora a associação termo a termo das equações (5.7) e (5.13) obtemos as expressões, para os parâmetros livres, que caracterizam a rede neuronal binária de HOPFIELD, o primeiro deles é a matriz de pesos sinápticos da rede, dada por

$$w_{ij} = - \sum_{k=1}^N \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) \left(\frac{c_{j-1} + c_{j+1}}{2} - c_j \right) g_{k-i} g_{k-j}. \quad (5.14)$$

O vetor de entrada externa é dado por

$$I_i = \sum_{k=1}^N \left(y_k + \frac{1}{2} \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) g_{k-i} \right) \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) g_{k-i}, \quad (5.15)$$

e o potencial limite é dado por

$$\theta_i = \sum_{k=1}^N \left(\sum_{j=1}^N c_j g_{k-j} \right) \left(\frac{c_{i-1} + c_{i+1}}{2} - c_i \right) g_{k-i}. \quad (5.16)$$

Desta forma todos os parâmetros livres da rede neuronal de HOPFIELD estão determinados pelas equações 5.14, 5.15 e 5.16, o que completa o desenho da sua arquitetura, de forma que ela apresenta na sua camada recorrente tantos neurônios quantos forem os pontos amostrados do perfil.

Por outro lado, para a utilização prática desta arquitetura, devemos ainda estimar as quantidades c_k e g_k , da feita que normalmente não se conhece exatamente a distribuição ideal das propriedades petrofísicas e a função resposta vertical da ferramenta. Contornaremos essa situação estimando a distribuição real da propriedade petrofísica em profundidade, através do perfil de mais alta resolução vertical existente no conjunto de perfis disponíveis. A resposta vertical da ferramenta será estimada através da *resposta vertical da ferramenta sob as condições atuais do poço* (ANDRADE, 1992; ANDRADE & LUTHI, 1993). Desta forma, todas as quantidades envolvidas nas equações 5.14, 5.15 e 5.16 estão definidas, com excessão da sequência r_k , que será então, determinada a partir da dinâmica do processamento da rede neuronal de HOPFIELD.

5.3.1 Resposta Vertical da Ferramenta sob as Condições Atuais do Poço

A estimativa da resposta vertical da ferramenta será realizada a partir da identificação de um intervalo de profundidades no perfil, ao qual chamaremos de *intervalo de controle*. Ele deve ser escolhido em um trecho do perfil marcado por camadas espessas e suficientemente grande para que o efeito das camadas adjacentes (*shoulder bed effect*) não afete o perfil de alta resolução vertical. A premissa básica que norteia essa estimativa é a de que no interior do intervalo de controle o perfil de baixa resolução vertical seja exatamente o resultado da convolução da resposta vertical da ferramenta sob as condições atuais do poço com o perfil de alta resolução vertical, que por sua vez é uma boa aproximação da distribuição ideal da propriedade petrofísica. No intervalo de controle a resposta vertical da ferramenta será estimada através da resposta vertical da ferramenta sob as condições atuais do poço, que representa um mapeamento do perfil de alta resolução vertical sobre o perfil de baixa resolução vertical, ambos no domínio da frequência espacial, explicitamente na forma

$$G_m = \frac{Y_m}{X_m}. \quad (5.17)$$

Nesta equação, G_m , representa a transformada de Fourier da resposta vertical da ferramenta nas condições atuais do poço. Y_m , é a transformada de Fourier do trecho do perfil de baixa resolução no interior do intervalo de controle e X_m é a transformada de Fourier do perfil de alta resolução vertical, tomado no interior do intervalo de controle.

A resposta vertical da ferramenta nas condições atuais de poço, no domínio da profundidade será obtida, explicitamente, pela transformada discreta inversa de Fourier, na forma,

$$g_n = \sum_{m=0}^{N-1} G_m e^{i2\pi \frac{nm}{N}}. \quad (5.18)$$

5.4 RESULTADOS

Estuda-se o comportamento da rede neuronal de HOPFIELD para a solução do problema da determinação das interfaces no perfil, de início em um caso simples, com o intuito de verificarmos a convergência da rede na sua formulação padrão ou se haveria a necessidade da incorporação de outras técnicas como a do *simulated annealing*, por exemplo.

5.4.1 Resultados sobre Modelos Convolucionais

Avalia-se no primeiro experimento o comportamento da dinâmica da rede neuronal de HOPFIELD em um modelo convolucional (equação 5.9), como visto na Figura 5.2-a, que mostra representado pela linha cheia o perfil sintético (\bar{y}_k), obtido a partir da convolução (da distribuição ideal da propriedade petrofísica p_k (equação 5.10), mostrado na Figura 5.2-a, em linha tracejada e a resposta vertical unidimensional da ferramenta de perfilagem (g_k), segundo DOLL (1949).

A partir dos sinais \bar{y}_k , p_k e do conhecimento de g_k , construímos uma rede neuronal de HOPFIELD com seus parâmetros livres determinados segundo as equações 5.14, 5.15 e 5.16. Assim, mostra-se na Figura 5.2-b as interfaces definidas pela simulação do comportamento do interprete através da rede de HOPFIELD, representadas por círculos escuros. Mostra-se também, o perfil sintético e a distribuição da propriedade petrofísica, como referência para o posicionamento correto das interfaces. Observa-se, que a dinâmica do processamento da rede neuronal de HOPFIELD, foi capaz de prever o número e o posicionamento correto das interfaces.

Realiza-se um estudo detalhado do comportamento da dinâmica da rede de HOPFIELD para o caso de dados contaminados por ruído, como exemplificado na Figura 5.3-a, na qual apresenta-se o perfil sintético do caso anterior, agora contaminado com ruído branco, com média zero e variância igual a um, não correlacionável com o perfil. Com se observa pela Figura 5.3-b, a presença de ruído nos dados não produziu efeitos sensíveis sobre o comportamento da rede neuronal de HOPFIELD.

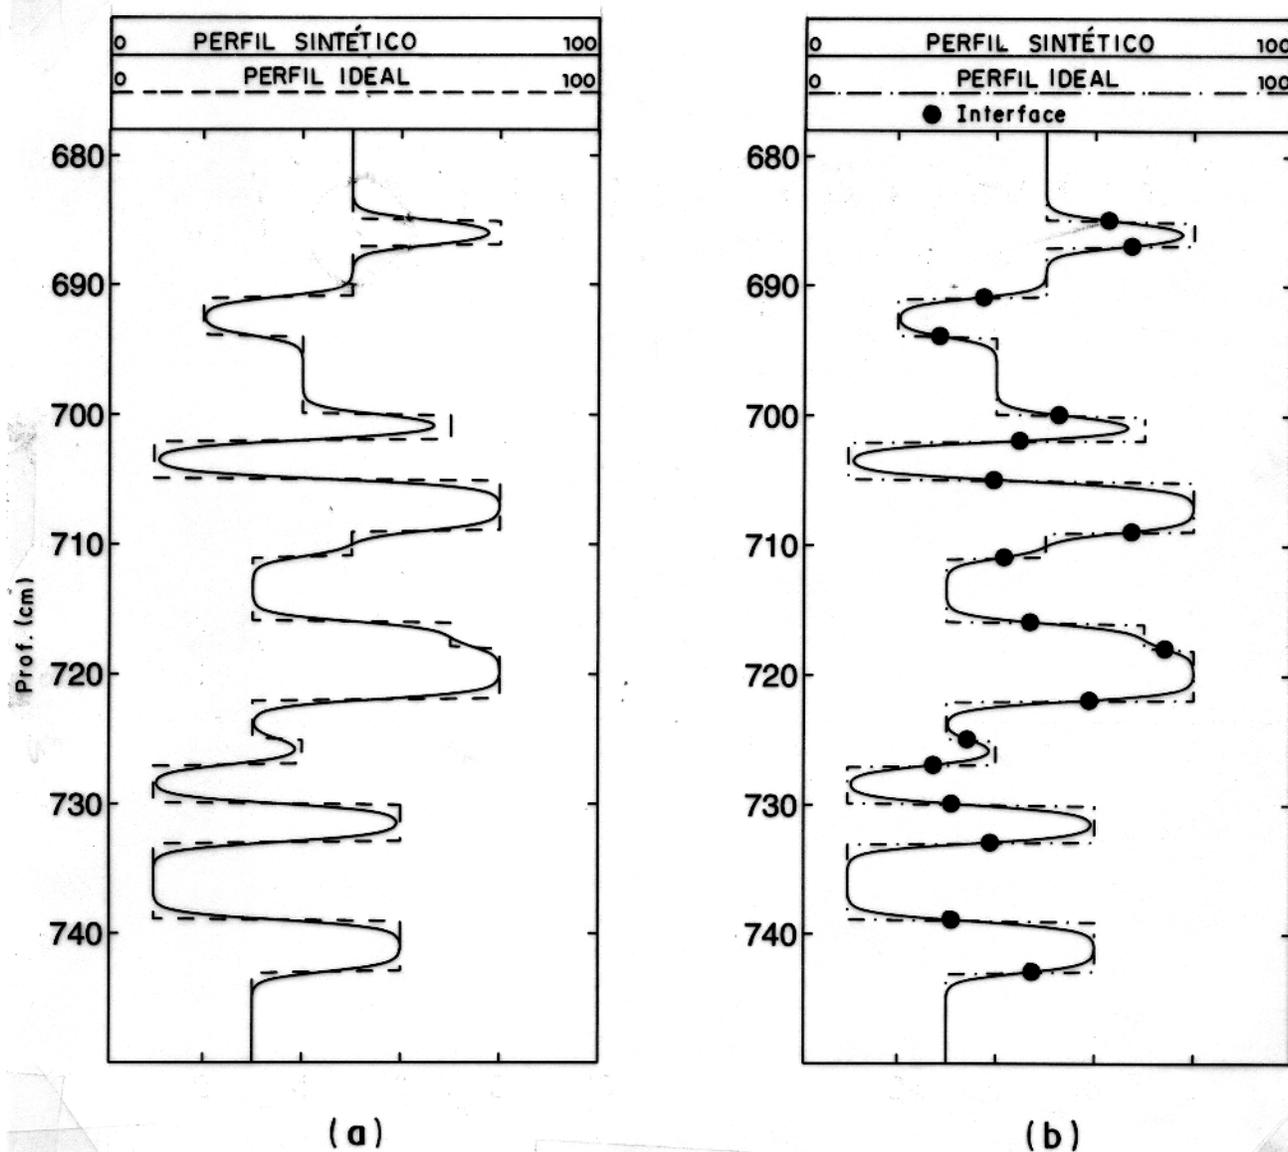


Figura 5.2 - Determinação de interfaces em modelos convolucionais. (a) Mostra a distribuição ideal da propriedade petrofísica (linha tracejada) e o perfil petrofísico sintético (linha cheia). (b) Mostra a a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético convolucional (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.

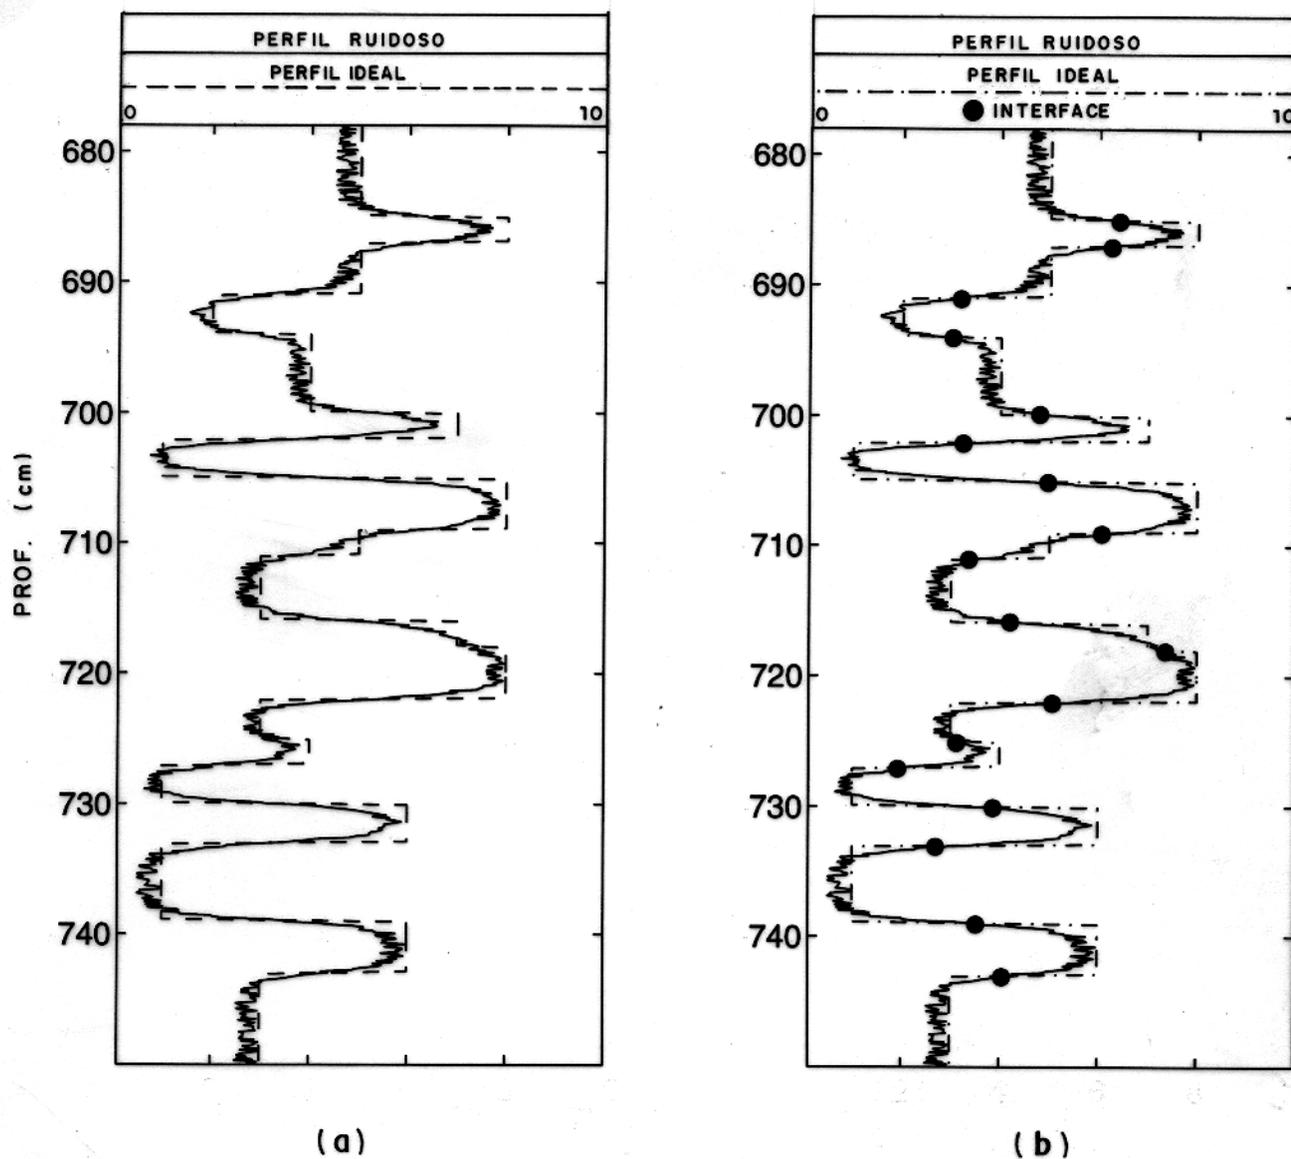


Figura 5.3 - Determinação de interfaces em modelos convolucionais com ruído. (a) Mostra a distribuição ideal da propriedade petrofísica (linha traço-jeada) e o perfil petrofísico sintético com ruído (linha cheia). (b) Mostra a a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético com ruído (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.

O segundo exemplo, (Figura 5.4), foi gerado a partir do modelo convolucional. Assumindo um modelo laminar da subsuperfície e considerando a propriedade petrofísica constante em cada lâmina. Aplicando-se duas respostas verticais das ferramentas de perfilagem (DOLL, 1949), com diferentes resoluções verticais, obteve-se dois perfis sintéticos com resoluções verticais diferentes, como mostrado na Figura 5.4-a. Neste experimento, busca-se verificar o comportamento da rede neuronal de HOPFIELD, na simulação de um caso real, no qual não dispomos de todas as grandezas necessárias para a completa definição dos seus parâmetros livres, ou seja, considera-se desconhecido o sinal p_k e a sequência g_k . Assim, procedemos à determinação da resposta vertical da ferramenta sob as condições atuais do poço (equações 5.17 e 5.18), sendo que utiliza-se para o intervalo de controle o trecho entre as profundidades 730 e 740 centímetros, marcado por um círculo na Figura 5.4-a. Posteriormente, assumindo a resposta vertical estimada no lugar da sequência g_k e o perfil de alta resolução vertical (linha cheia na Figura 5.4-a), procedeu-se à localização das interfaces, através de uma rede de HOPFIELD, com valores característicos obtidos a partir das equações 5.14, 5.15 e 5.16. Como se observa na Figura 5.4-b, uma vez que modelo convolucional é o inspirador da rede neuronal de HOPFIELD aqui apresentada, bem como da estimativa da resposta vertical da ferramenta, a sua aplicação para a determinação das interfaces se mostrou bastante precisa,

Destes dois experimentos tem-se que apesar da dinâmica do processamento das redes neuronais de HOPFIELD levarem, por meio de um decrescimento contínuo, a um mínimo local da função energia (equação 5.7), nenhuma técnica adicional, que propicie o encontro do mínimo global se mostrou necessária, uma vez que o mínimo local encontrado satisfaz às questões desse problema em particular.

Uma questão relevante trata sobre a amplitude do perfil na profundidade definida como sendo uma interface, conforme visto pela equação 5.10, este valor é determinado como a média aritmética dos valores do perfil dos pontos adjacentes àquele definido como sendo a interface e portanto não é um problema para o qual a rede neuronal de HOPFIELD deva produzir uma solução. Uma vez que a saída da rede neuronal de HOPFIELD para este ponto é exatamente igual a um, ou um valor muito próximo de um, os valores do perfil marcados com o círculo escurecido, devem ser considerados como apenas, uma representação gráfica para as interfaces.

O terceiro experimento, que pode ser visto na Figura 5.5, mostra o mesmo modelo convolucional, porem com uma distribuição da propriedade petrofísica em profundidade, um pouco mais complexa. Neste caso, observa-se uma limitação da rede neuronal de HOPFIELD, para a localização das interfaces, como visto no intervalo de 130 cm a 140 cm. Mostrando que a resolução da rede neuronal de HOPFIELD esta limitada à resolução do perfil de baixa

resolução vertical, ou seja, uma vez que o perfil de baixa resolução vertical não consegue *enxergar* uma camada a rede também não o conseguirá. Este efeito evidencia o fato de que a única informação disponível para a rede neuronal é o próprio perfil, sobre o qual se deseja interpretar o posicionamento das interfaces.

5.4.2 Resultados sobre Modelos Numéricos

Os modelos convolucionais são simulações rudimentares dos perfis reais. Assim, a necessidade da avaliação da performance da rede neuronal de HOPFIELD, sobre dados controlados nos levou à utilização de perfis obtidos a partir da modelagem numérica, como os gerados pela ferramenta de espectrometria de raios gama natural, mais representativos dos perfis reais.

No primeiro experimento, mostrado na Figura 5.6, toma-se a curva de contagem total de raios gama natural, tomada aqui como o perfil de baixa resolução vertical e a curva de porcentagem de potássio, tomada aqui como de alta resolução vertical (PANTUZZO, 1996). O intervalo de controle para a determinação da resposta vertical da ferramenta nas condições atuais do poço, se encontra no interior do círculo na Figura 5.6-a, onde mostra-se também a distribuição da máxima porcentagem de potássio admitida para cada camada, como uma representação do posicionamento em profundidade das interfaces. A partir destas duas curvas de resolução vertical diferente e da determinação da resposta vertical estimada da ferramenta, construímos uma rede neuronal de HOPFIELD com os parâmetros livres obtidos com as equações 5.14, 5.15 e 5.16. Na Figura 5.6-b mostra-se a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada, que é indicativa do verdadeiro posicionamento em profundidade das interfaces. A dinâmica do processamento da rede neuronal de HOPFIELD, levou ao posicionamento das interfaces que se encontram marcados com círculos escuros. Mais uma vez, se observa a dependência da rede neuronal de HOPFIELD, com a resolução do perfil de baixa resolução vertical, o que determina a obtenção do número e do posicionamento em profundidade das interfaces, conforme mostrado na Figura 5.6-b.

O segundo experimento com modelos numéricos, mostrado na Figura 5.7, para o qual repetimos o mesmo procedimento adotado no caso anterior, obtendo o posicionamento das interfaces, vista com círculos escuros na Figura 5.7-b. Neste caso, onde a distribuição das camadas em profundidade é um pouco mais complexa, a definição das interfaces pela rede neuronal, mostrou uma perda de resolução para o caso das camadas finas, apesar do perfil de baixa resolução vertical *enxergar* essas camadas.

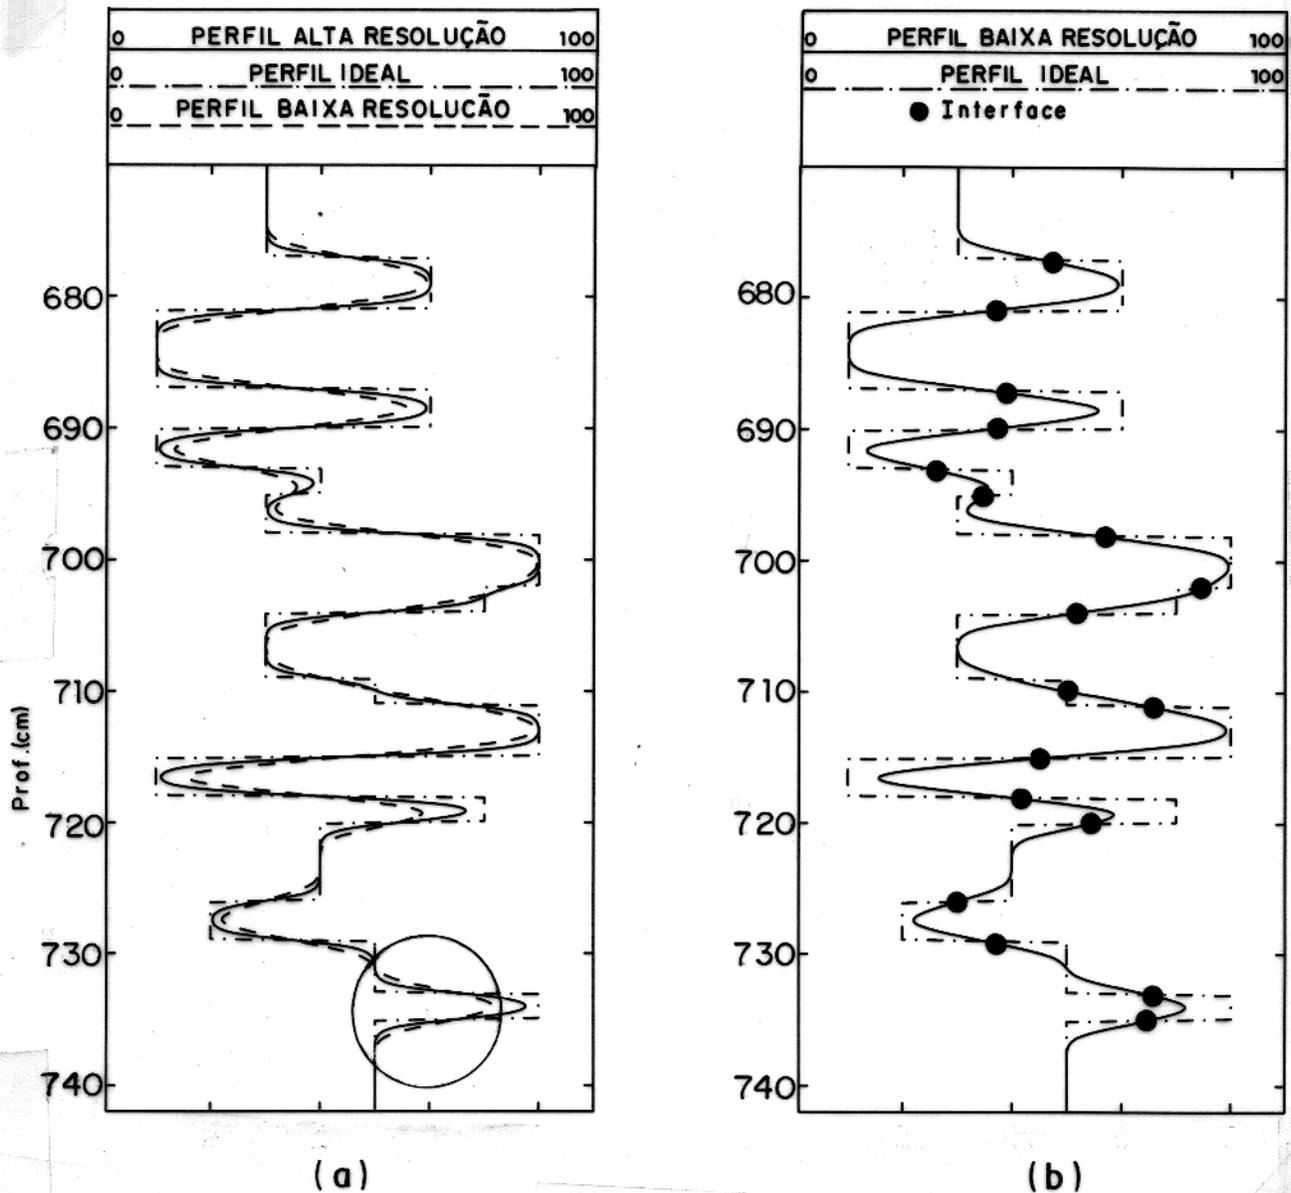


Figura 5.4 - Determinação de interfaces em modelos convolucionais. (a) Mostra a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha tracejada) e o perfil sintético de alta resolução vertical (linha cheia). (b) Mostra a a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.

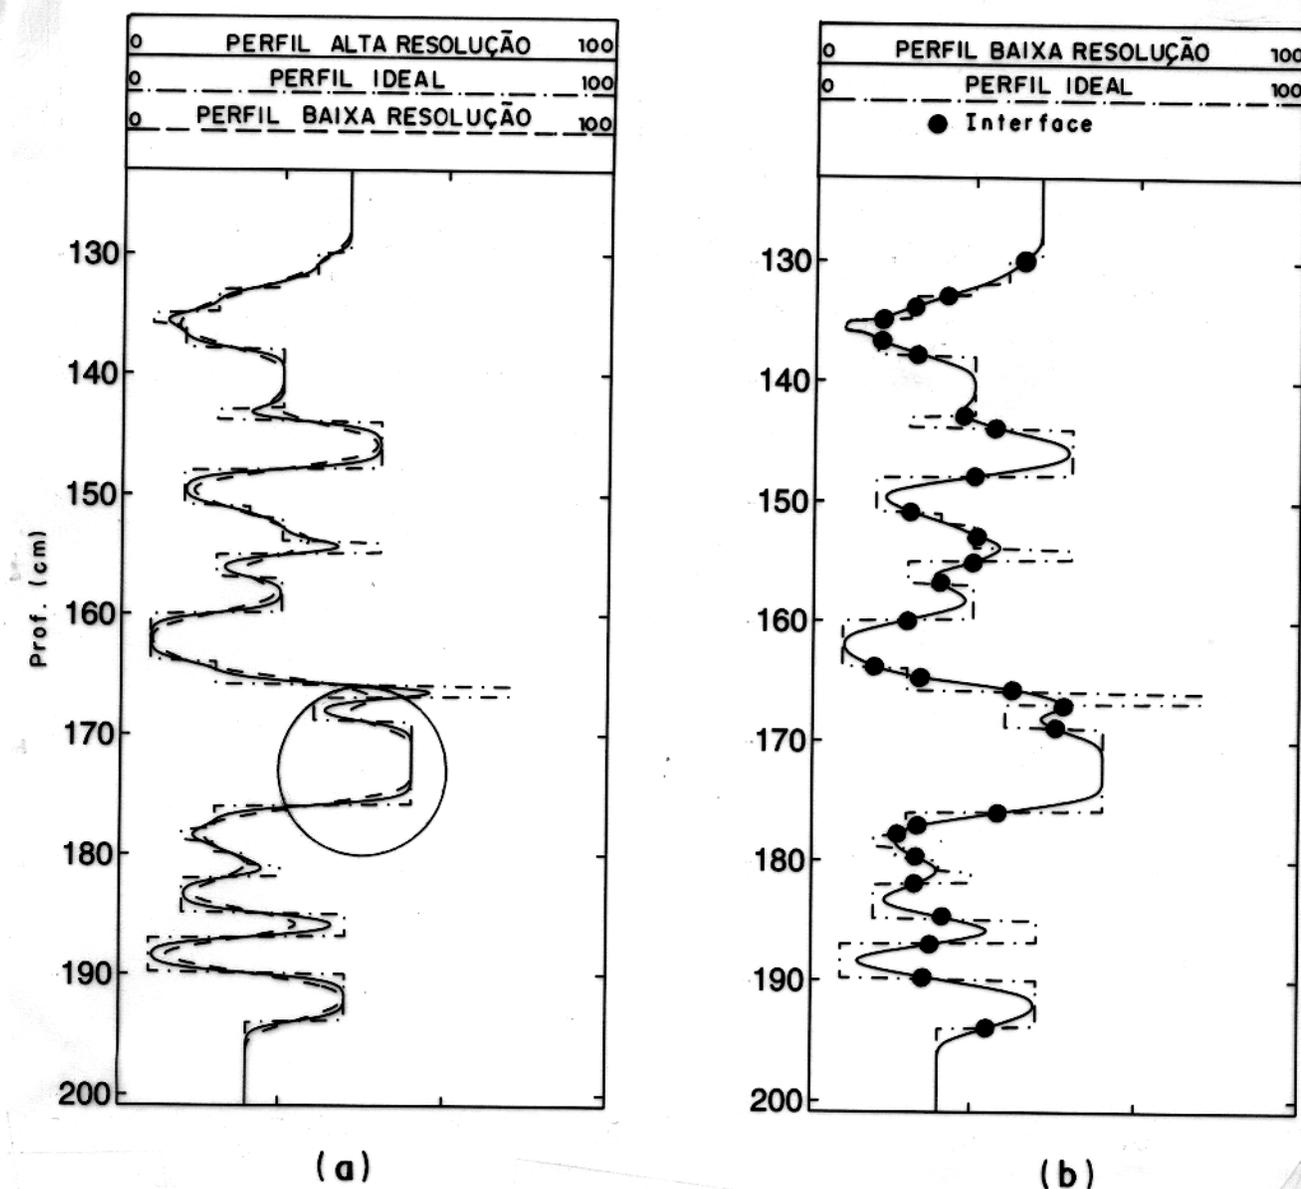


Figura 5.5 - Determinação de interfaces em modelos convolucionais. (a) Mostra a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha tracejada) e o perfil sintético de alta resolução vertical (linha cheia). (b) Mostra a distribuição ideal da propriedade petrofísica (linha traço-pontilhada), o perfil sintético de baixa resolução vertical (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.

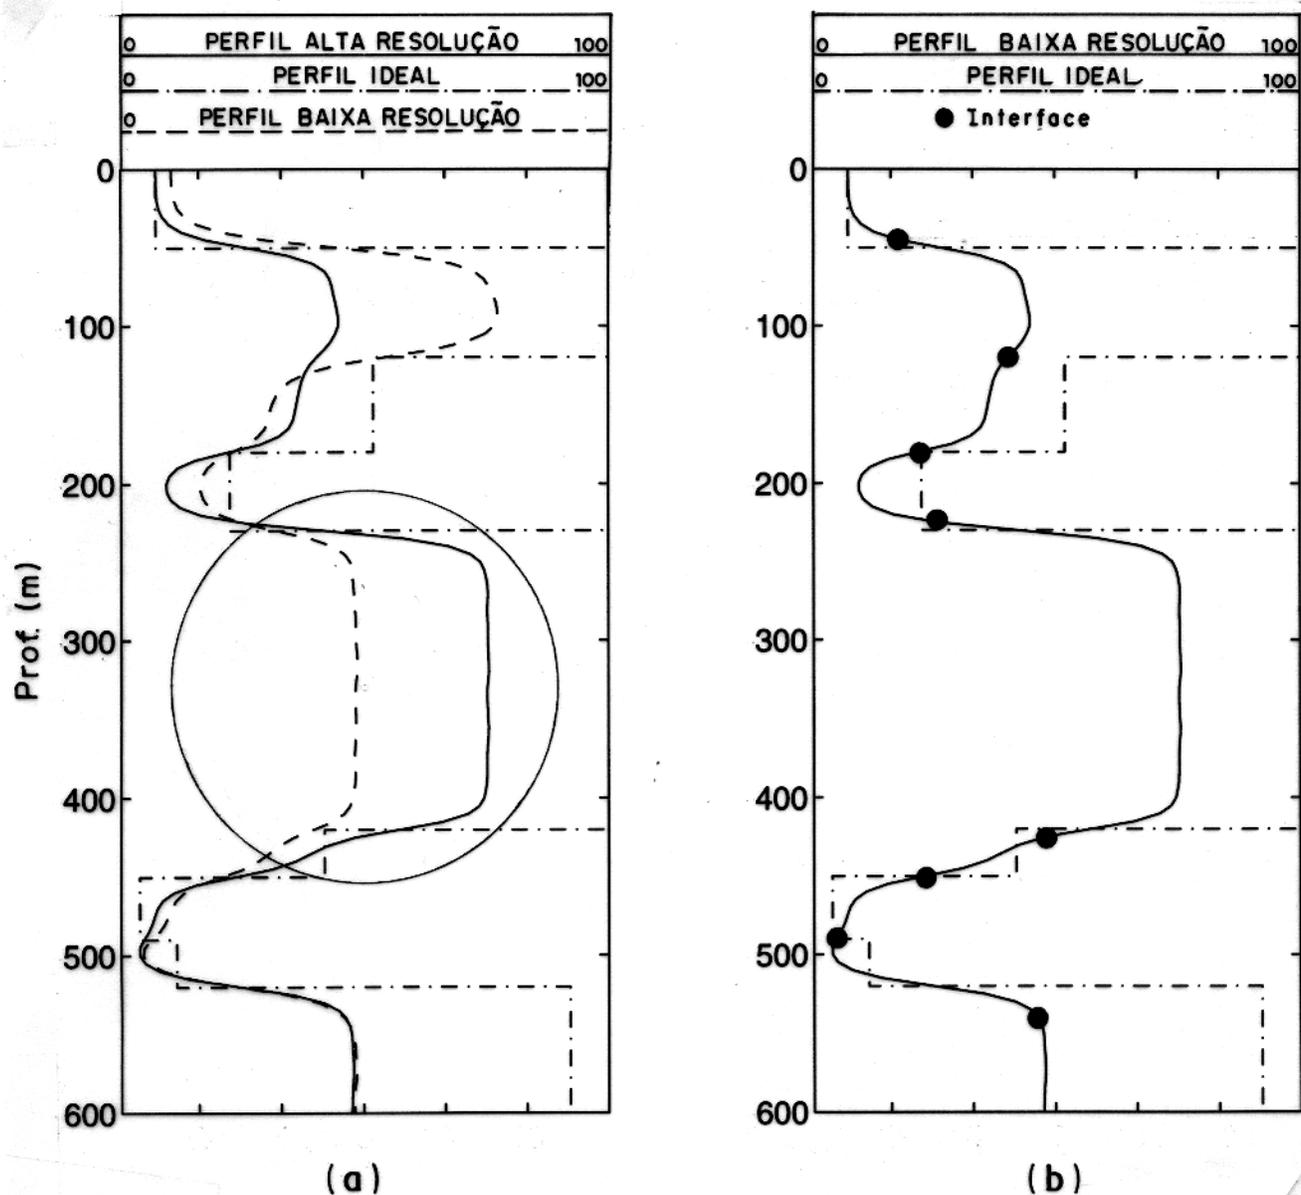


Figura 5.6 - Determinação de interfaces em modelos numéricos. (a) Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de porcentagem de potássio (linha pontilhada) e perfil de contagem total de raios gama natural (linha cheia). (B) - Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.

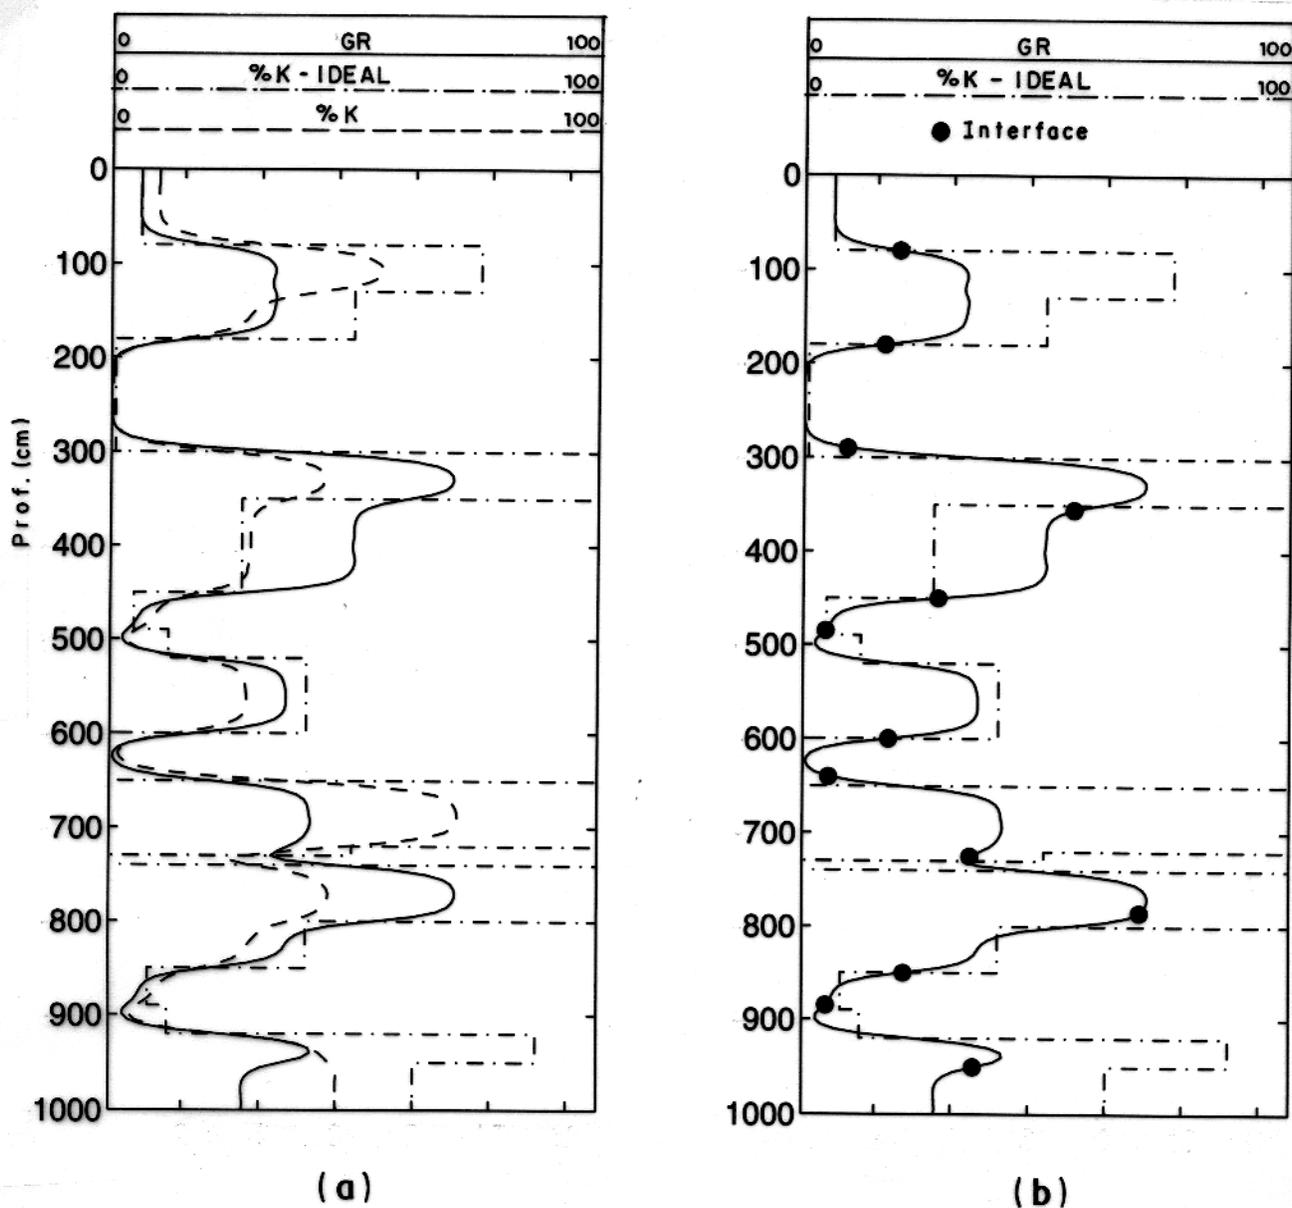


Figura 5.7 - Determinação de interfaces em modelos numéricos. (a) Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de porcentagem de potássio (linha pontilhada) e perfil de contagem total de raios gama natural (linha cheia). (b) - Mostra a distribuição em profundidade da máxima porcentagem de potássio admitida para cada camada (linha traço-pontilhada), o perfil de contagem total de raios gama natural (linha cheia) e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos escuros.

5.4.3 Resultado sobre Perfis Reais

Para mostrarmos uma aplicação da rede neuronal de HOPFIELD, para o tratamento com os dados reais de perfil, trata-se um par de perfis elétricos com diferentes resoluções verticais, obtidos no poço w1112 na região do lago Maracaibo, Venezuela (BRYANT & VILLARROEL, 1994)

O perfil de investigação rasa (alta resolução vertical) utilizado para a estimativa da distribuição ideal da propriedade petrofísica foi o MSFL (*Micro-Spherically Focused Log, Schlumberger*) ou perfil de R_{xo} , combinado com o perfil de investigação profunda (baixa resolução vertical) ILD (*Induction Log Deep, Schlumberger*) ou perfil de R_T . Seguindo-se o procedimento, descrito pelas equações 5.14, 5.15 e 5.16, construiu-se uma rede neuronal de HOPFIELD, para a simulação do comportamento do interprete quando da determinação do número e do posicionamento vertical das interfaces no perfil. Mostra-se na Figura 5.8-(a), o perfil de alta resolução vertical - (R_{xo}) e o perfil de baixa resolução vertical - (R_T). O intervalo de controle utilizado para a determinação da resposta vertical da ferramenta sob as condições atuais do poço foi tomado nas profundidades de 3 207 a 3 217 metros. Na Figura 5.8 - (b), mostra-se o perfil de R_T , as interfaces definidas pelo interprete (BRYANT & VILLARROEL, 1994), marcadas com asteriscos e as interfaces definidas a partir do processamento da rede neuronal de HOPFIELD, marcadas por círculos escuros.

Observando-se a Figura 5.8, vemos que a dinâmica da rede de HOPFIELD apresentou um bom comportamento, sendo capaz de identificar com precisão a ocorrência dos maiores eventos (camadas espessas) ao longo do perfil. Na Tabela 5.1, mostra-se a profundidade das interfaces definidas pela rede de HOPFIELD e pelo interprete.

5.5 CONCLUSÕES

A utilização das redes neuronais de HOPFIELD para a simulação da tomada de decisão do interprete de perfis quando da localização das interfaces no perfil apresentou um comportamento relativamente bom. No entanto este trabalho, aponta para a necessidade do estudo de modelos matemáticos mais representativos para os perfis petrofísicos, bem como para a estudo de formas de se permitir a introdução de *informação a priori* por parte do interprete no processamento da rede neuronal, de uma forma semelhante aos métodos convencionais para a solução dos problemas de otimização, o que resultaria certamente numa melhoria considerável do comportamento dessa rede neuronal no tratamento com os dados reais de perfil.

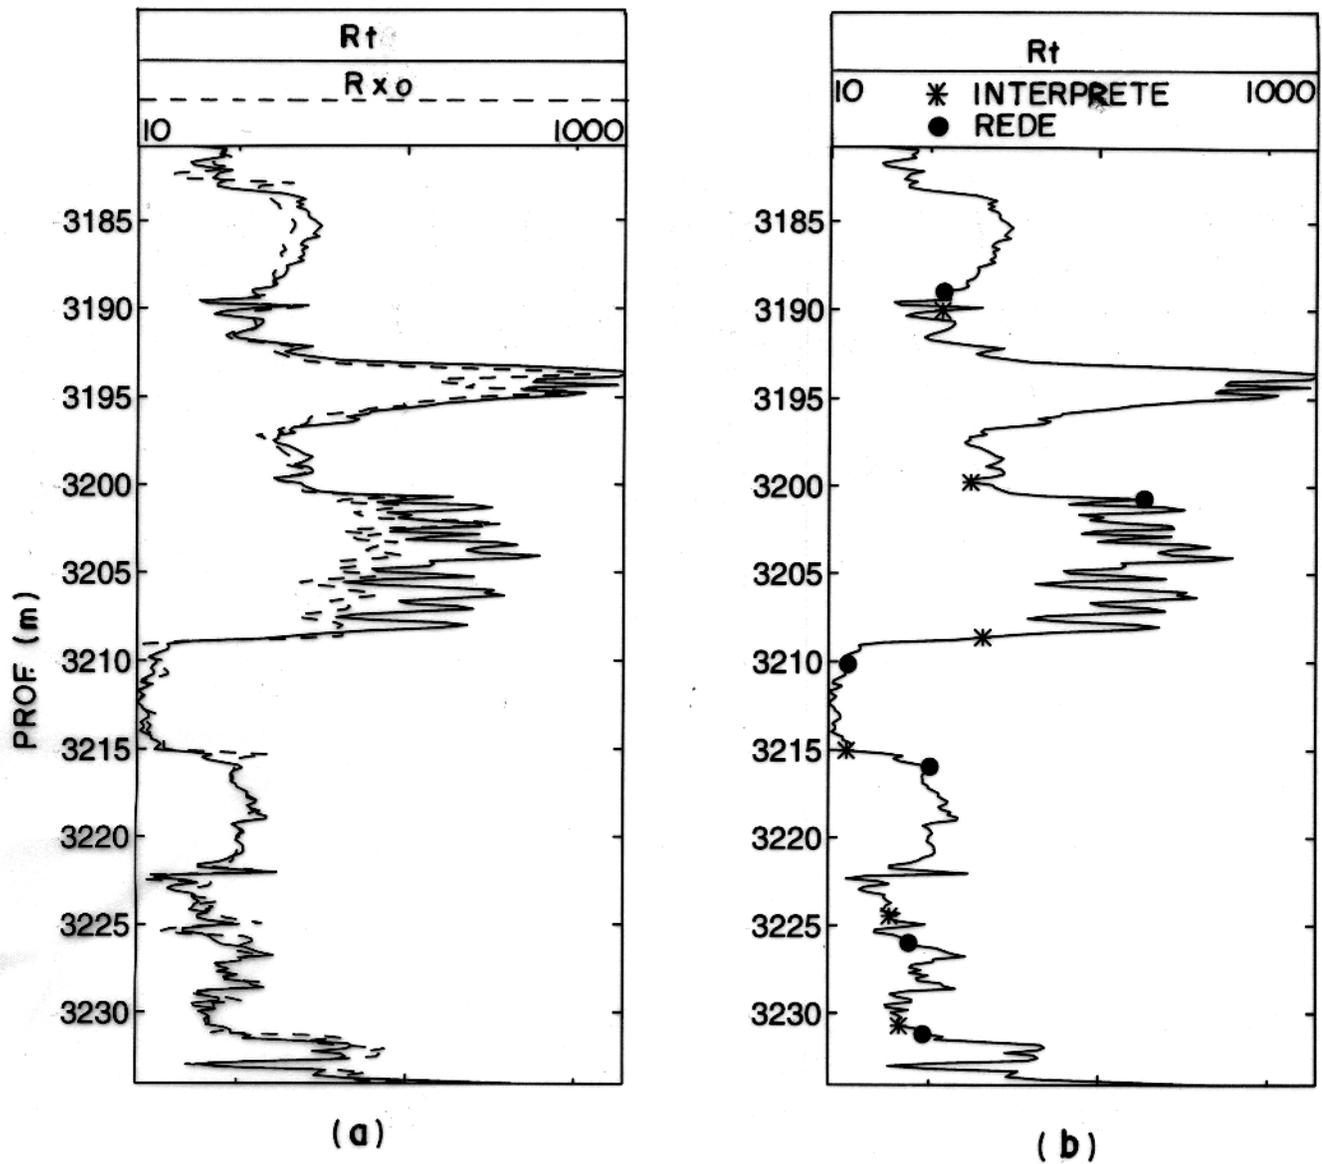


Figura 5.8 - Determinação de interfaces em perfil real. (a) - Mostra o perfil de alta resolução vertical - R_{xo} (linha traço-pontilhada) e o perfil de baixa resolução vertical - R_T (linha cheia). (b) - Mostra o perfil de baixa resolução vertical - R_T , as interfaces definidas pelo interprete, marcadas com asteriscos e as interfaces determinadas pela rede neuronal de HOPFIELD, marcadas com círculos.

Tabela 5.1 - Comparação das profundidades (em metros) das interfaces determinadas pelo interprete e pela rede neuronal de HOPFIELD para o poço w1112.

Interprete	Rede Neuronal	Ajuste (%)
3 190,3	3 194,1	0,120
3 200,1	3 202,0	-0,060
3 209,0	3 210,1	-0,034
3 215,3	3 218,1	-0,083
3 224,8	3 226,0	-0,037
3 231,0	3 232,3	-0,040

6 - IDENTIFICAÇÃO DE LITOLOGIAS EM PERFIS

6.1 INTRODUÇÃO

Quando as rochas não apresentam porosidade alguma, quer primária ou secundária e se constituem de um único mineral, a identificação desse mineral através dos perfis geofísicos de poço é imediata, como é o caso dos evaporitos, por exemplo a halita (NaCl). Neste caso, o perfil de densidade é bastante e suficiente para diagnosticar a presença desse mineral, a partir do seu valor característico de densidade, $\rho_b = 2,03 \text{ g/cm}^3$. Infelizmente, os evaporitos não são rochas do tipo reservatório que são de constituição mineralógica muito mais complexa, como é o caso do arenito que é uma rocha reservatório bastante comum. Esta rocha, na grande maioria das ocorrências não é composta exclusivamente por sílica (SiO_2), mas sim de combinações complexas de sílica e argilo-minerais e/ou carbonatos cimentantes.

A complexa constituição das rochas de interesse e a necessidade da correta identificação litológica de um certo trecho em profundidade, de um poço perfurado, levou à caracterização litológica de um determinado tipo de rocha, não por meio de uma completa descrição mineralógica, mas sim, através da identificação do seu principal mineral constituinte, ou mineral essencial.

Para a caracterização litológica ou a identificação do mineral essencial de uma rocha, através dos perfis, foram desenvolvidos diversos métodos, numéricos, como a análise composicional (WYLLIE et al., 1956) e gráficos, como o gráfico M-N (*M-N plot*) (BURKE et al., 1969).

Apresenta-se neste capítulo, um método para a determinação do mineral essencial das rochas a partir dos perfis de poço, por meio de uma simulação da interpretação realizada por um intérprete em um gráfico M-N através de uma arquitetura de rede neuronal com camada competitiva, no sentido de simular a tomada de decisão do intérprete de perfis, quando da utilização do gráfico M-N.

No âmbito da computação conexionista das redes neuronais artificiais, a simulação da tomada de decisão do intérprete, quando da utilização do gráfico M-N, pode ser entendida como um problema de decisão com um número finito de alternativas ou como um problema de classificação não-linear do conjunto (espaço) de estímulos, no conjunto (espaço) de padrões.

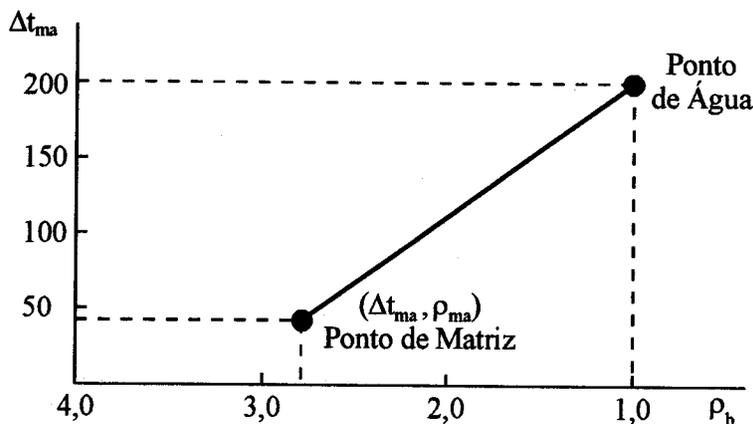


Figura 6.1 - Representação gráfica idealizada do perfil de densidade versus o perfil sônico

6.2 O GRÁFICO M-N

Quando três perfis de porosidade são disponíveis, um processo gráfico bastante utilizado para a identificação de minerais é chamado de gráfico M-N (BURKE et al., 1969). O gráfico M-N representa a solução de um problema tridimensional, reduzido para o plano, uma vez que os parâmetros M e N são praticamente independentes da porosidade, exceto nas formações contendo hidrocarboneto leve. Como indicado na Figura 6.1, temos que uma combinação das medidas do perfil sônico (Δt) e do perfil de densidade (ρ_b), é utilizada para a definição do parâmetro M, o qual é uma estimativa da inclinação da curva, que une o *ponto de matriz* ($\rho_{b_{ma}}, \Delta t_{ma}$), ou o ponto que representa uma rocha constituída exclusivamente pela parte sólida, com porosidade nula e o *ponto de água* ($\rho_{b_w}, \Delta t_w$), que representa uma rocha hipotética, com 100% de porosidade, com a totalidade dos seus poros preenchidos por água. De forma inteiramente análoga, como mostrado na Figura 6.2, o parâmetro N, representa uma estimativa da inclinação da curva, que une o *ponto de matriz* ($\rho_{b_{ma}}, \phi_{n_{ma}}$) e o *ponto de água* (ρ_{b_w}, ϕ_{n_w}), para a associação do perfil de densidade e o perfil neutrônico (ϕ_n).

De forma explícita, adotando unidades do sistema métrico, temos para o parâmetro M a forma

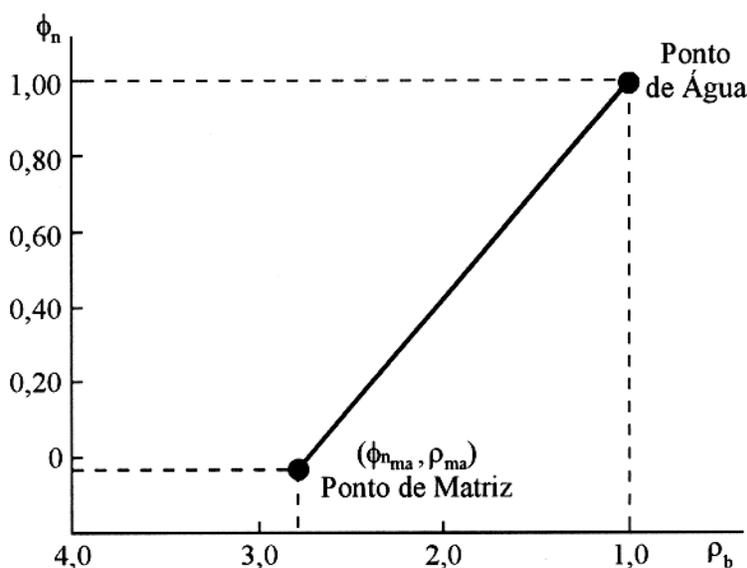


Figura 6.2 - Representação gráfica idealizada do perfil de densidade versus o perfil neutrônico

$$M = \frac{\Delta t_w - \Delta t_{ma}}{\rho b_{ma} - \rho b_w} \cdot 0,003; \quad (6.1)$$

e para o parâmetro N a expressão

$$N = \frac{\phi n_w - \phi n_{ma}}{\rho b_{ma} - \rho b_w}. \quad (6.2)$$

Utilizando os valores apropriados para cada valor de matriz (arenito, calcário, dolomita), obtém-se os chamados *pontos fixos* (padrões), que serão então lançados em um gráfico, como mostrado na Figura 6.3. Estes serão então, tomados como pontos de referências para a identificação do mineral essencial da rocha em análise.

Se calcularmos o valor do parâmetro M em um ponto qualquer do perfil através da expressão 6.1, substituindo o valor Δt_{ma} pelo seu valor particular do tempo de trânsito e se este ponto for representativo de uma rocha formada unicamente por quartzo, com qualquer valor de porosidade, os valores do parâmetro M encontrados serão essencialmente iguais. Isto se deve ao fato de que a variação do tempo de trânsito e da densidade com a porosidade é efetivamente linear, ou a inclinação representada pelo parâmetro M é constante e independente do valor de porosidade. Semelhante argumento não é necessariamente válido para o

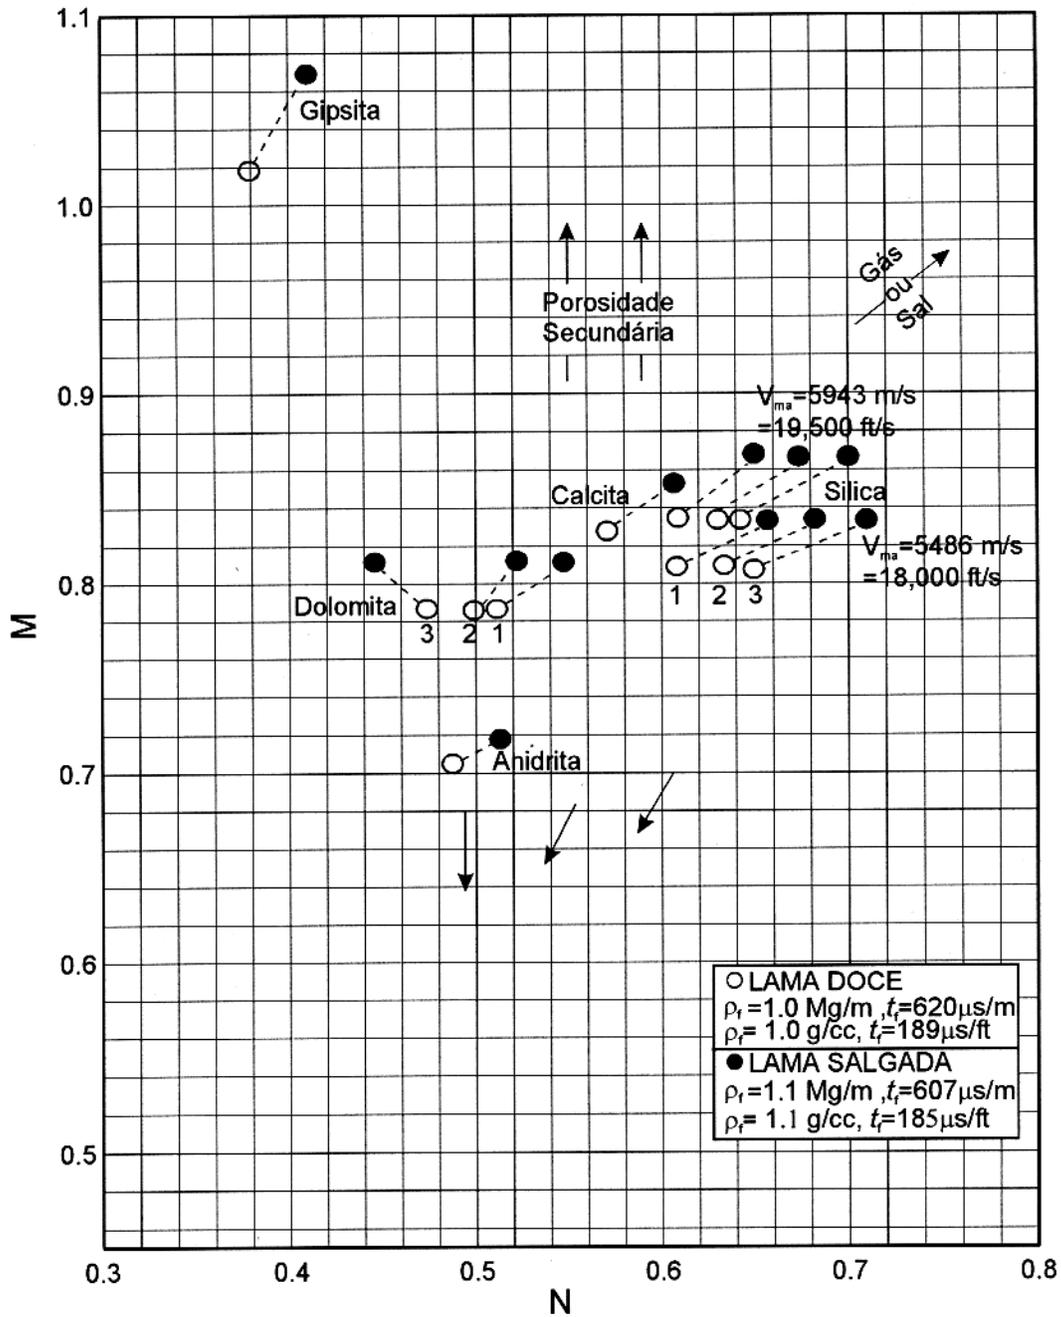


Figura 6.3 - Gráfico M-N (modificado, SCHLUMBERGER, 1988)

parâmetro N , em função das flutuações do perfil de porosidade neutrônica, assim na Figura 6.3, mostra para os arenitos (Silica) e as dolomitas, uma variação dos pontos fixos para três intervalos de porosidade que são

1. $0,0 \leq \phi < 12,0 \text{ pu}$
2. $12,0 \leq \phi < 27,0 \text{ pu}$
3. $27,0 \leq \phi < 40,0 \text{ pu}$

6.3 REDES NEURONAIS COM CAMADA COMPETITIVA

As redes neuronais baseadas em um treinamento do tipo competitivo (*competitive learning*), são constituídas por uma camada de elementos sensoriais (camada de entrada), uma única camada de elementos processadores, chamada de camada competitiva (*competitive layer*).

Estas redes neuronais são caracterizadas pela indução dos neurônios da camada competitiva a atuarem uns sobre os outros, de tal modo que apenas um único neurônio, permaneça ativo, ou seja, produza um sinal de saída não nulo, a cada instante de tempo. Uma maneira de se induzir a competição entre os neurônios é a introdução de conexões (sinapses) laterais inibitórias entre eles (ROSENBLATT, 1962).

Para explorarmos um pouco mais sobre as sinapses inibitórias, consideremos a rede neuronal mostrada na Figura 6.4, na qual a camada competitiva está destacada, mostrando as conexões primárias com a camada de entrada da rede e as conexões inibitórias, que são uma segunda fonte de estímulos. Cada tipo de conexão, serve a um propósito definido. A soma ponderada dos sinais de entrada (estímulos) em cada neurônio se presta à detecção de padrões no espaço de estímulos. Assim cada neurônio produzirá uma resposta seletiva para cada particular conjunto de estímulos. As conexões laterais, por sua vez, produzem efeitos excitatórios e inibitórios, dependendo da distância relativa dos neurônios conectados.

Por força da motivação biológica, as conexões laterais, são matematicamente descritas por uma função do tipo chapéu mexicano (HAYKIN, 1994), como mostrado na Figura 6.5. Nesta podemos distinguir duas regiões de interesse na interação lateral entre os neurônios, a região central, de caráter excitatório e as regiões laterais vizinhas, de caráter inibitório. Normalmente, são desprezadas as regiões mais afastadas da região central.

Este tipo de rede neuronal apresenta duas características importantes:

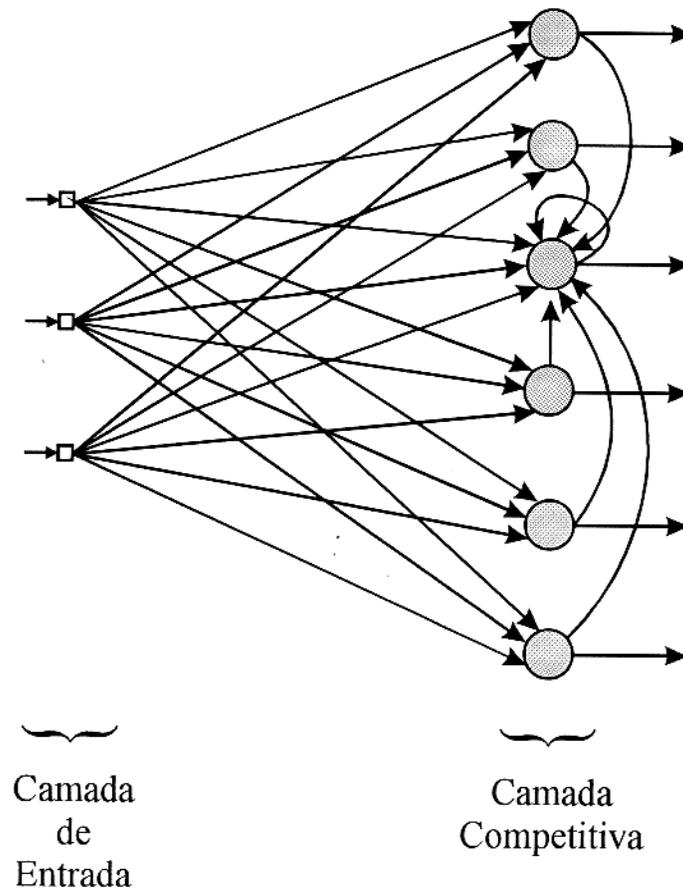


Figura 6.4 - Rede neuronal direta com camada competitiva, mostrando as conexões laterais inibitórias para um do neurônios desta camada

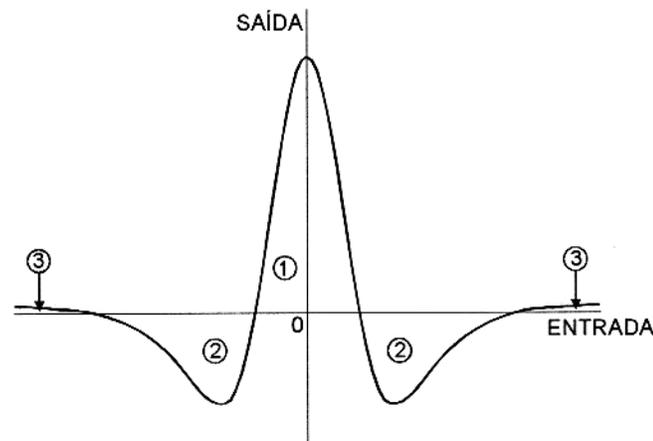


Figura 6.5 - Função tipo chapéu mexicano das conexões laterais.

1. A rede tende a concentrar a sua atividade no interior de nuvens locais (*clusters*), no espaço de estímulos, referida como bolha de ativação (*activity bubbles*) (KOHONEN, 1988).
2. A localização das bolhas de ativação é determinada fundamentalmente pela natureza dos estímulos.

Sejam x_1, \dots, x_p os estímulos aplicados à rede neuronal, com p elementos sensoriais na sua camada de entrada. Sejam w_{j1}, \dots, w_{jp} os correspondentes pesos sinápticos do neurônio j da camada competitiva. e $c_{j,-K}, \dots, c_{j,0}, \dots, c_{j,K}$ os pesos das conexões laterais, que são os valores de uma função chapéu mexicano, na forma discretizada com K amostras. Sejam y_1, \dots, y_N os sinais de saída da rede, ou sinal de saída de cada um dos N neurônios da camada competitiva. Expressa-se o sinal de saída do neurônio j na forma

$$y_j = \varphi(P_j + \sum_{k=-K}^K c_{jk}y_{j+k}), \quad (j = 1, 2, \dots, N). \quad (6.3)$$

Nesta equação φ é qualquer função de ativação, responsável pela quantização do sinal de saída no intervalo $[0, 1]$. O termo P_j é o potencial de entrada do neurônio j , na forma,

$$P_j = \sum_{l=1}^p w_{lj} x_l. \quad (6.4)$$

A solução da equação 6.3 é obtida recursivamente, uma vez reformulada, com a introdução de um parâmetro (β), que é um controlador empírico da convergência. Assim a equação 6.3 fica escrita na forma,

$$y_j(t+1) = \varphi(P_j + \beta \sum_{k=-K}^K c_{jk} y_{j+k}(t)), \quad j = 1, 2, \dots, N. \quad (6.5)$$

Na equação 6.5, $y_j(t+1)$ é a saída do neurônio j , no tempo $t+1$ e $y_{j+k}(t)$ é a saída do neurônio $j+k$, no tempo t . A ação limitante da função φ faz com que a resposta y_n se estabilise, na dependência do valor adotado para β (HAYKIN, 1994). Se o parâmetro β é grande o suficiente, no estado final, correspondente a $t \rightarrow \infty$, o valor de y_j tenderá a permanecer no interior de uma nuvem espacialmente limitada (bolha de ativação), centrada em um ponto onde o sinal de saída inicial $y_j(t=0)$ devido unicamente ao estímulo representado pelo potencial de ativação P_j é máximo.

6.4 MÉTODO

O objetivo deste experimento é de promover uma simulação da utilização do gráfico M-N através de uma rede neuronal, de certa forma emulando o comportamento do intérprete de perfis, quando ele utiliza o gráfico M-N para determinação do elemento mineralógico principal das rochas, em um intervalo de profundidade de um poço, através dos dados de perfil.

6.4.1 A Rede Neuronal

Para a obtenção da arquitetura da rede neuronal aqui apresentada, formula-se o problema da determinação da composição mineralógica da rocha em um certo intervalo do perfil, de uma forma bastante simplificada. Assim, deseja-se uma arquitetura de rede neuronal, capaz de apenas, identificar o mineral essencial ou o principal mineral responsável pela formação da matriz rochosa, que ocorre em um determinado intervalo de profundidade. Nesse sentido podemos interpretar o comportamento da rede como sendo o da realização de uma classificação dos pontos (M_i , N_i), representativos das camadas definidas no perfil em função dos pontos fixos no plano N-M.

Na Figura 6.6, apresenta-se a arquitetura de rede neuronal desenhada para a classificação dos pontos (M_i , N_i), que formam a entrada da rede neuronal, composta por dois elementos sensoriais na sua camada de entrada. Em função dos oito pontos fixos, marcados no gráfico M-N (Figura 6.7), definimos, que cada ponto fixo será representado por um elemento processador na camada competitiva da rede, composta então, por oito neurônios. Para a construção final da camada competitiva da rede neuronal, associa-se ao peso sináptico (w_{ij}) característico de cada um dos seus neurônios, o valor de cada um dos pontos fixos representativos de um mineral em particular, como visto na Tabela 6.1. A partir dos experimentos realizados, o parâmetro β , foi tomado igual a unidade. A função representativa das conexões laterais foi aproximada pela função do inverso multiplicativo da distância Euclidiana, entre um ponto fixo (peso sináptico) e um ponto qualquer (M_i , N_i), no plano M-N. A rede neuronal, assim desenhada esta preparada para a classificação do espaço de estímulos em oito classes (minerais) distintos.

6.5 RESULTADOS

6.5.1 Resultados sobre Dados Reais

A aplicação dessa arquitetura de rede neuronal foi realizada sobre um conjunto de perfis (sônico, densidade e neutrônico) de um poço do campo petrolífero do Rio Juruá, na bacia do Alto Amazonas (Petrobras).

Mostra-se na Figura 6.7, os pontos M_i e N_i (mostrado com cruces), calculados a partir das expressões 6.1 e 6.2, para o ponto médio de cada intervalo de interfaces, como definido pela análise de testemunhos. Os pontos fixos estão representados por círculos numerados de acordo com o mineral que representam, como visto na Tabela 6.2.

A introdução de um ponto fixo extra para a representativo da argila (folhelho) (mostrado por um círculo, com o número 1 na Figura 6.7) no gráfico M-N se deve a uma prévia análise dos testemunhos, onde se verifica a presença de sequências de arenitos e folhelhos, de modo a tornar a classificação realizada pela rede neuronal mais realista. A definição do ponto de argila se deu a partir da determinação do ponto de máximo valor no perfil de raios gama natural RG_{max} (Figura 6.7) para este intervalo de perfil analisado. Posteriormente, efetua-se o cálculo de M e N do ponto de argila a partir das expressões 6.1 e 6.2 com os valores de Δt_{sh} , ρb_{sh} e ϕn_w tomados como a média aritmética de todos os pontos do perfil, que apresentassem um valor de raio gama da ordem de 90% de RG_{max} .

A simulação da classificação mineralógica realizada pela rede neuronal está mostrada na

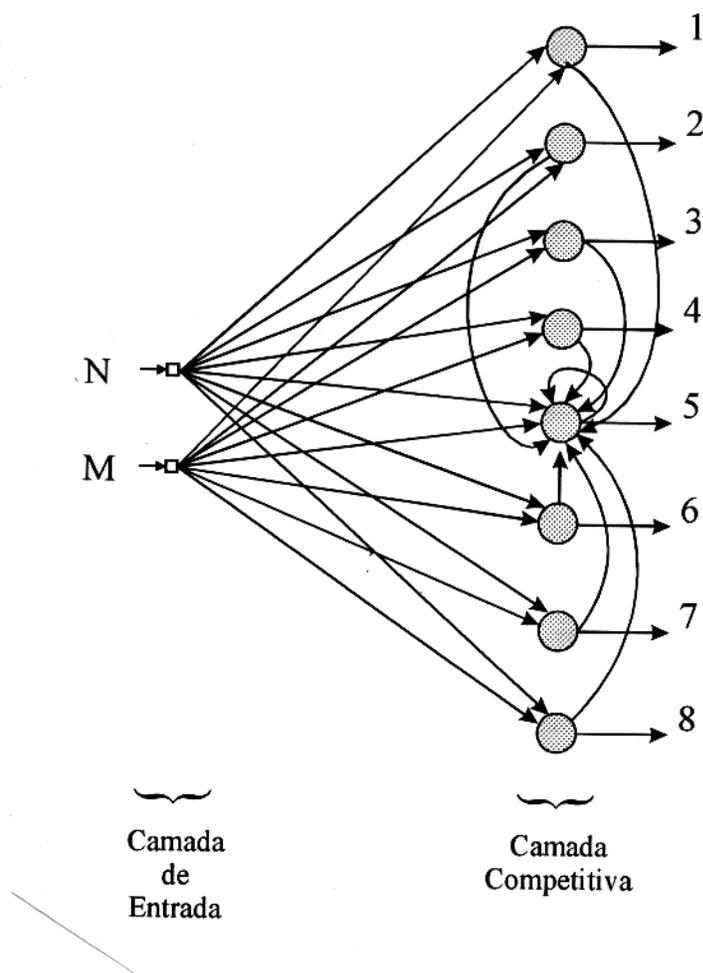


Figura 6.6 - Rede neuronal direta, com camada competitiva, para a simulação do comportamento do intérprete na análise do gráfico M-N. Mostra-se as conexões laterais apenas para o neurônio de número 5.

Tabela 6.1 - Pontos fixos no gráfico M-N, representativos de cada neurônio da camada competitiva.

Neurônio	M	N
1	0,771	0,553
2	0,628	0,838
3	0,650	0,838
4	0,585	0,830
5	0,537	0,785
6	0,520	0,785
7	0,505	0,705
8	0,380	1,020

Tabela 6.2 - Associação de números à minerais utilizada pela rede neuronal.

Número	Mineral
1	Argila
2	Silica ($0,0 \leq \phi \leq 12,0 pu$)
3	Silica ($12,1 \leq \phi \leq 27,0 pu$)
4	Calcita
5	Dolomita ($0,0 \leq \phi \leq 12,0 pu$)
6	Dolomita ($0,0 \leq \phi \leq 12,0 pu$)
7	Anidrita
8	Gesso

Figura 6.8-C na forma de um gráfico de barras, onde no eixo horizontal estão mostrados os números referentes aos minerais classificados, como na Tabela 6.1, para cada intervalo de profundidades, como mostrado no eixo vertical. A análise de testemunho deste poço realizada a partir dos testemunhos recuperados deste poço realizada por um especialista (Petrobras) esta mostrada na Figura 6.8-B, como uma forma de validar da classificação realizada pela rede neuronal. Onde se observa que as lentes de siltito foram incorretamente classificados, por vezes como argila, outras vezes como arenito.

6.6 CONCLUSÃO

A simulação do comportamento do intérprete quando da utilização do gráfico M-N, a partir da utilização de uma rede neuronal com camada competitiva, se mostrou efetiva no

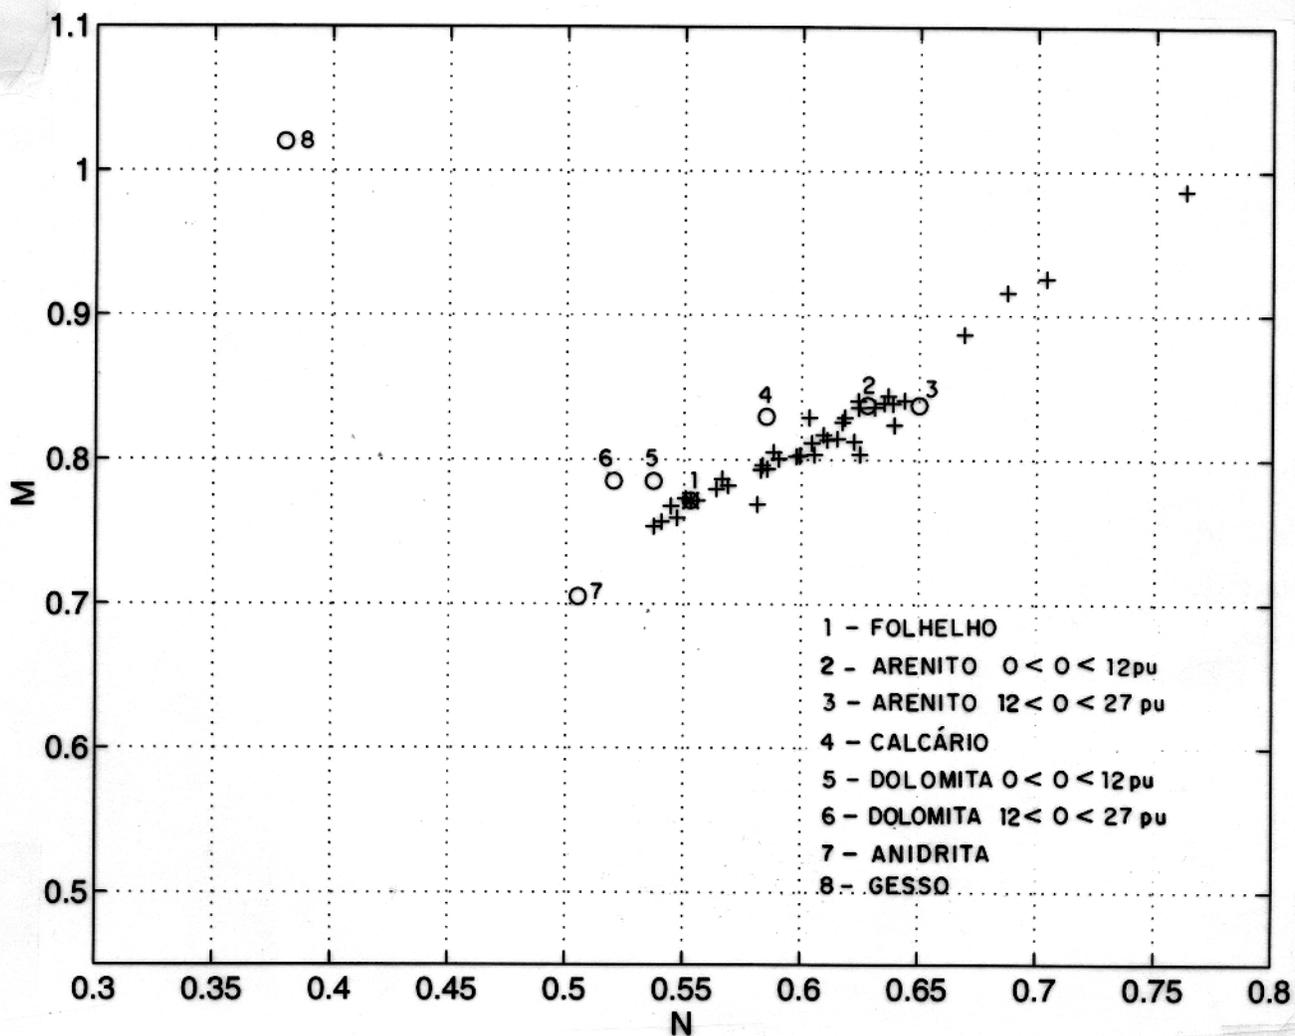


Figura 6.7 - Gráfico M-N, sobre o qual a rede neuronal realizará a sua classificação.

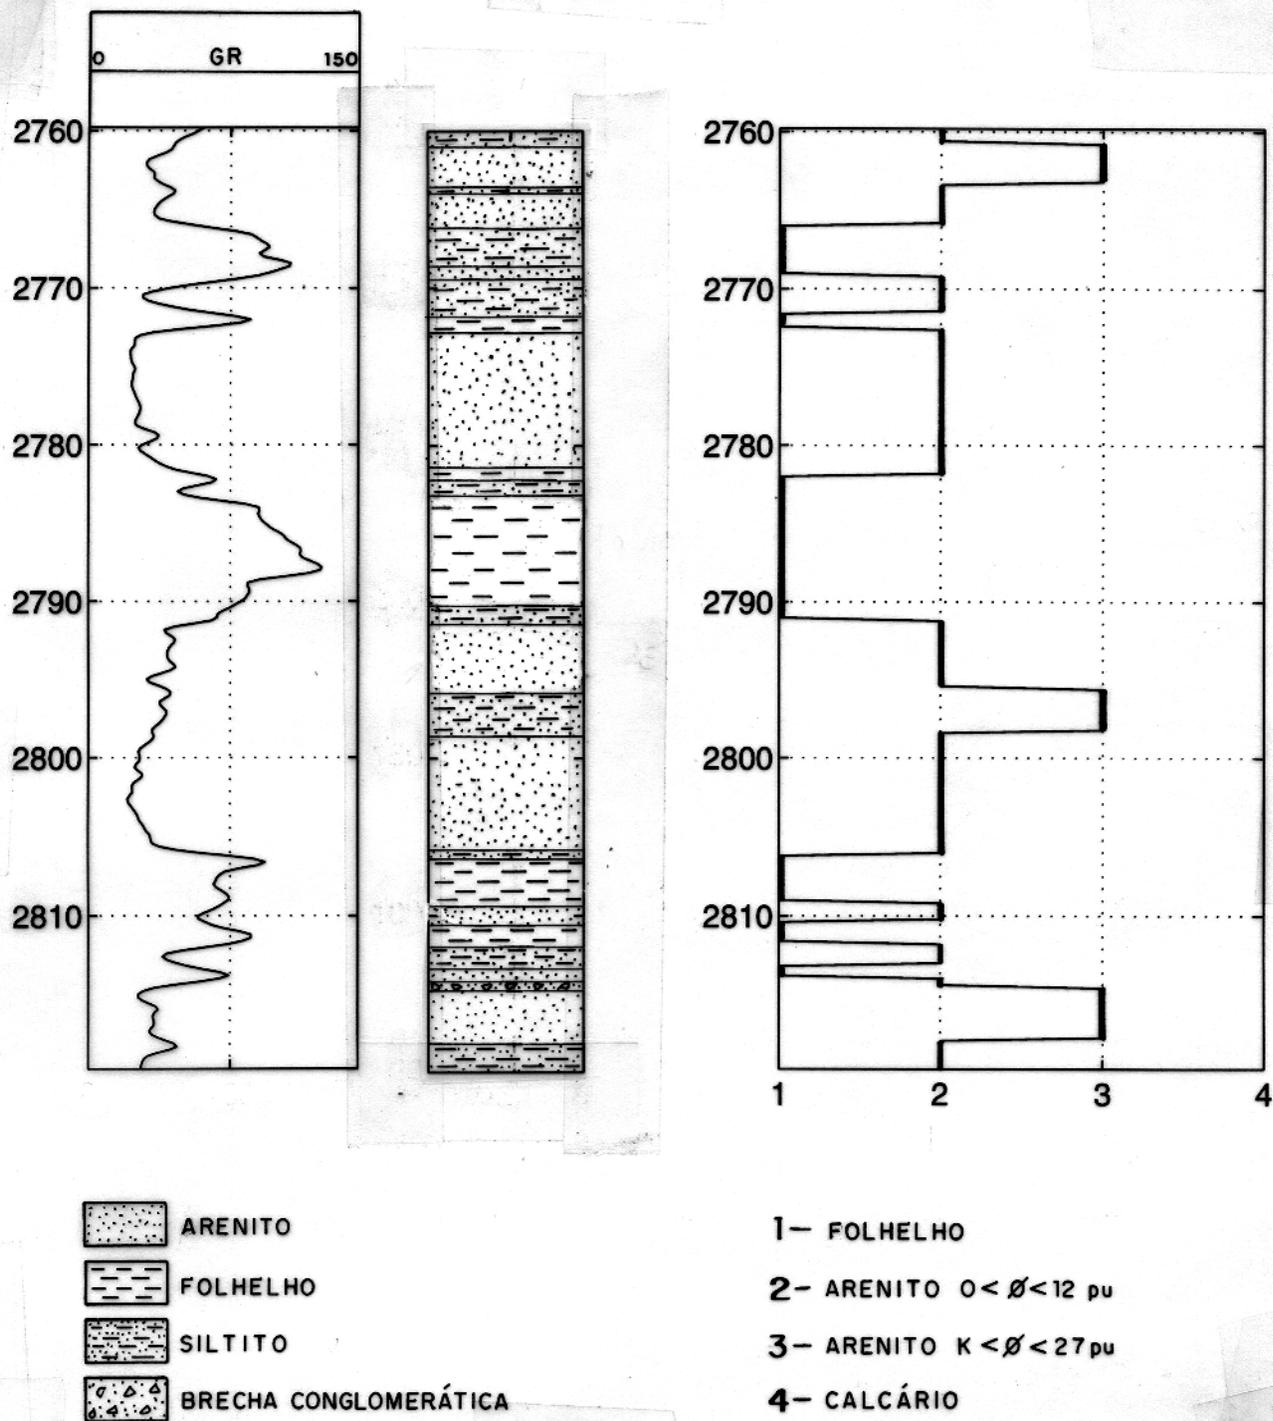


Figura 6.8 - (A) - Perfil de raios gama natural. (B) Análise de testemunhos. (C) - Classificação mineralógica realizada pela rede neuronal.

sentido da identificação dos minerais essenciais com a introdução de um ponto fixo representativo da argila, sem o qual classificações errôneas seriam realizadas. Este comportamento evidencia o fato de que, apesar da rede neuronal prescindir da fase de treinamento supervisionado, é de extrema necessidade a presença do intérprete para a correta definição *a priori* dos pontos fixos (classes) a serem utilizados na fase de operação da rede neuronal. Este fato no entanto não inviabiliza a utilização dessa rede neuronal, para a identificação de minerais nos perfis, uma vez que a correta definição das classes pelo intérprete pode ser entendida como a aprendizagem ou formação do conhecimento da rede neuronal.

7 - CORRELAÇÃO ESTRATIGRÁFICA DE PERFIS

7.1 INTRODUÇÃO

A correlação estratigráfica pode ser entendida como sendo a determinação da correta equivalência espacial das rochas baseada em suas propriedades físicas (OLEA & DAVIS, 1986). A correlação estratigráfica busca a determinação da continuidade lateral das rochas, podendo ser realizada com base em diversos critérios, como declinados abaixo

1. Identificação de elementos fosseis.
2. Posição relativa na sequência sedimentar (idade da rocha).
3. Textura.
4. Geometria (forma da formação).
5. Relações faciológicas.
6. Perfis petrofísicos de poços.

Na correlação realizada a partir dos perfis petrofísicos, as formações são descritas unicamente através de suas propriedades físicas e sua sequência textural (FONS, 1969).

A correlação estratigráfica poço-a-poço de perfis petrofísicos é uma das mais importantes aplicações da perfilagem de poço. Nesse processo, as curvas registradas no perfil, se constituem em uma importante ferramenta de trabalho para o intérprete, propiciando o correto mapeamento de estruturas de subsuperfície, a caracterização dos sistemas deposicionais e numa escala de maior detalhe, a reconstituição da morfologia das unidades de fluxo e das discontinuidades hidráulicas de um reservatório (DOVETON, 1986).

Na realização da correlação estratigráfica poço-a-poço, por meio dos perfis petrofísicos, o processo realizado pelo intérprete pode ser entendido, a partir da identificação de uma característica feição em um *perfil base* ou perfil do poço de referência, a qual é marcada como nível de referência (*datum*), associado à presença de uma determinada sequência sedimentar. Um datum deve representar uma interface de importância geológica regional, o que leva à sua principal característica, que é a sua visibilidade nos perfis dos demais poços. A partir

da marcação dos *datums* nos perfis dos vários poços, o intérprete passa à identificação da continuidade lateral das diversas unidades litológicas contidas no interior do intervalo de profundidade definido pelos *datums*, as quais o auxiliaram na construção de um modelo geométrico para o reservatório, o qual é de fundamental importância para o desenvolvimento futuro de um campo petrolífero. Este trabalho é por natureza tedioso e realizado de forma iterativa, com o intérprete continuamente re-examinado sua correlação anterior e alterando seus *datums*, quando necessário (LUTHI et al, 1995).

A sequência das operações realizadas pelo intérprete na execução de uma correlação poço-a-poço é tipicamente um processo de reconhecimento de padrões ou sob outro ponto de vista, como um problema de decisão. De qualquer forma é um forte indicativo para a utilização das redes neurais artificiais para a sua simulação computacional, uma vez que as redes neurais artificiais apresentam um bom comportamento para a solução deste tipo de problema (CICHOCKI & UNBEHAU, 1995).

Neste sentido, de modo a capturar computacionalmente o processo da correlação poço-a-poço de perfis, como realizado pelo intérprete, LUTHI et al (1995), apresentaram uma arquitetura de rede neuronal direta, treinada através do algoritmo da retro-propagação do erro para a identificação de um único datum ao longo de todo o perfil base, a qual foi satisfatoriamente aplicada sobre diversos perfis, oriundos de poços de uma mesma região. Conforme visto na Figura 7.1, esta arquitetura de rede neuronal é desenhada de forma tal que, a camada de entrada da rede, funciona na forma de uma janela móvel (*time delay layer*). A cada apresentação de um novo ponto do perfil, este entra na última posição (neurônio) da camada de entrada e descarta-se o valor contido na primeira posição, com o consequente deslocamento de todas as amostras do perfil de uma posição ao longo da camada de entrada. A camada oculta contém um número de neurônios, intermediário entre o o número de elementos processadores da camada de entrada e a camada de saída da rede. A camada é composta por um único neurônio, cujo estado é 1, na presença do datum e 0 para todos as demais possibilidades.

De maneira geral, a rede neuronal para a simulação da correlação poço-a-poço de perfis, deve ser capaz de fornecer duas respostas, quando aplicada sobre os perfis dos outros poços, na sua fase de operação, que são:

1. A existência do datum.
2. A posição em profundidade do datum.

Esta questão implica no projeto de uma arquitetura de rede neuronal na qual a quantidade de profundidade não faça parte do processo. Desta forma, o problema de decisão envolvido com

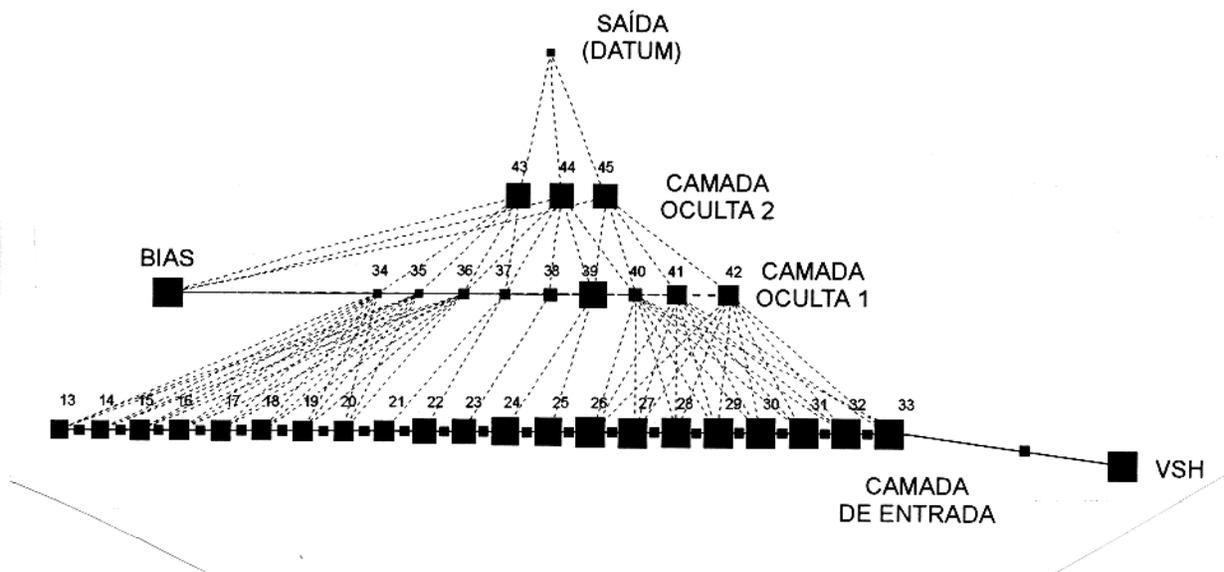


Figura 7.1 - Arquitetura de rede neuronal artificial para a determinação de um datum em um perfil de poço. (LUTHI et al, 1995)

a correlação poço-a-poço de perfis, passa a ser um problema de decisão binário; ou seja, admite apenas duas alternativas para a sua solução, *sim*, para a existência do datum e *não*, no caso contrário.

Assim sendo, apresenta-se neste capítulo, uma arquitetura de rede neuronal, composta por três camadas, treinada com o algoritmo da retropropagação do erro, sobre um único perfil, chamado *perfil base*, com o objetivo de simular a tomada de decisão de um intérprete, na realização da correlação poço-a-poço de perfis. Sob um ponto de vista um pouco mais abrangente, seria a localização em profundidade, não de um único datum, mas sim de uma unidade geológica (eletroface), através da localização de sua base e do seu topo, como definido pelo intérprete no perfil base, com os seguintes objetivos:

1. Determinar a existência dessa camada em outro poço da área.
2. Determinar o seu posicionamento em profundidade.

7.2 MÉTODO

A utilização das redes neuronais para a simulação da tomada de decisão do intérprete na realização da correlação de perfis, parte da interpretação do processo dedutivo do intérprete,

que pode ser visto na seguinte forma:

1. Identificação de uma camada de interesse no perfil base.
2. Identificação nos outros perfis da continuidade lateral desta camada.

Na identificação da continuidade lateral de uma determinada camada litológica, alguns fatores de natureza geométrica, devem ser considerados, devido aos processos naturais de deposição e sedimentação das rochas sedimentares, como por exemplo o espessamento das camadas selantes e o conseqüente acunhamento das camadas reservatórios. Neste sentido a rede neuronal deve ser capaz de capturar no seu processamento de indentificação, as características geológicas desse processo.

Mais uma vez, associando o perfil à realização de um processo temporal na forma de uma série temporal. A arquitetura da rede neuronal, proposta para simular a correlação poço-a-poço é mostrada na Figura 7.2. Nesta arquitetura, cada neurônio da camada oculta é ativado por uma função de ativação do tipo sigmoide e o neurônio da camada de saída por uma função linear, segundo o teorema da aproximação de funções.

As principais características desta rede são:

1. A existência de um único neurônio na camada de entrada, evita a restrição espacial da espessura da camada geológica, representada pelo número de amostras do perfil ser associada ao número de neurônios da camada de entrada.
2. Essa arquitetura intencionalmente vetoriza as operações na fase de treinamento da rede, com potencial ganho de eficiência computacional.

Deve-se observar que a presença de um único neurônio na camada de entrada da rede neuronal, em nada limita a sua capacidade de armazenamento de informação, da feita que de forma independente do número de interfaces (padrões) a serem armazenadas, elas serão escritas na forma de um único vetor.

O passo seguinte para a aplicação desta arquitetura, para a simulação da correlação poço-a-poço é a codificação da resposta desejada na forma de um vetor binário, tomando partido do sinal binário de saída, natural do neurônio da camada de saída da rede, de tal modo que o valor um represente uma posição de topo ou base, associado à camada de interesse no perfil base. Neste caso é importante que a rede neuronal memorize toda a camada a ser identificada nos demais poços, assim a resposta desejada será escrita na forma de um vetor binário, onde

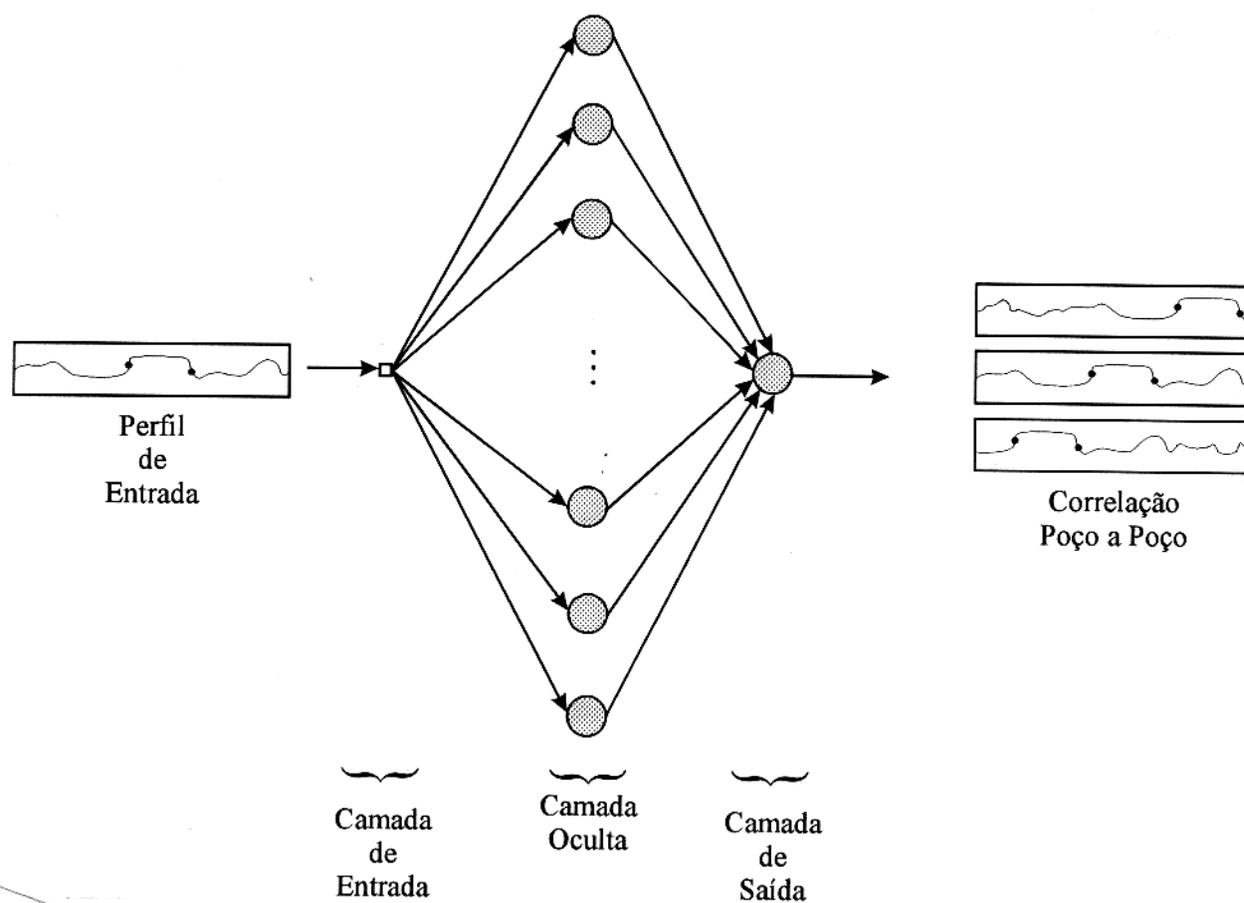


Figura 7.2 - Arquitetura de rede neuronal para a correlação poço-a-poço de uma camada.

a partir da interface de topo até a interface de base da camada é assinalado o valor um e para todos os demais pontos do intervalo de treinamento é assinalado o valor zero; ou seja, dado por

$$d = [0 \dots 0 \ 1 \dots 1 \ 0 \dots 0]^T,$$

onde T indica o transposto do vetor-linha.

7.3 RESULTADOS

A performance desta arquitetura de rede neuronal, para a simulação da correlação poço-a-poço de perfis petrofísicos, foi testada sobre dados sintéticos e dados reais.

7.3.1 Resultados sobre Dados Sintéticos

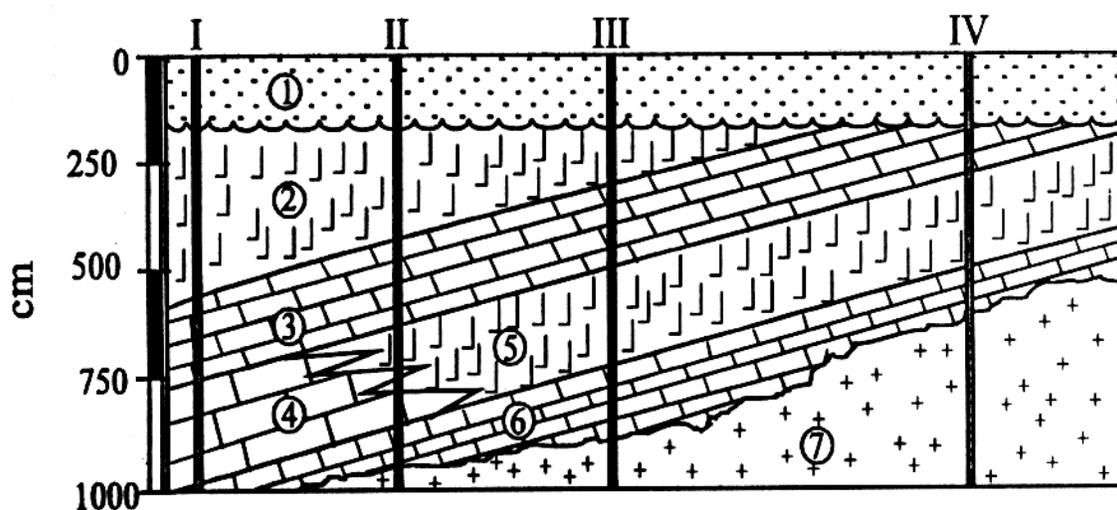
O estudo da arquitetura da rede neuronal aqui apresentada, foi realizado, em princípio, a partir de seções geológicas idealizadas (PANTUZZO, 1996) e sobre a simulação numérica dos perfis da ferramenta de espectrometria de raio gama natural (PANTUZZO, 1996; SILVA, 1993).

A primeira aplicação foi realizada sobre o modelo geológico sintético, mostrado na Figura 7.3, onde mostra-se a disposição geométrica das camadas e as frações volumétricas da sua mineralogia, foram obtidos através da simulação numérica (SILVA, 1993), os perfis de raio gama natural, para três dos poços mostrados.

Uma rede neuronal foi construída, segundo a arquitetura mostrada na Figura 7.2, contendo apenas 20 neurônios na sua camada oculta e treinada para o reconhecimento da camada limitada pelas interfaces marcadas com círculos escuros na Figura 7.5-a (poço I). O treinamento consistiu da apresentação desse intervalo e a correspondente resposta desejada à rede neuronal, por 2500 vezes. O suficiente para o mapeamento pretendido, como mostrado na Figura 7.4, onde mostra-se quatro instantes do treinamento da rede. Mostra-se na Figura 7.5 a correlação realizada pela rede neuronal para a camada 6 na Figura 7.3.

Na Figura 7.6 apresenta-se o resultado do comportamento da rede neuronal para a correlação estratigráfica para o mesmo exemplo mostrado no caso anterior, agora contaminado por ruído branco, com média zero e variância finita não correlacionável com o perfil. Observa-se que a rede neuronal não apresentou grandes variações no seu comportamento.

Para o modelo geológico sintético, mostrado na Figura 7.7, foram gerados os perfis da ferramenta de raios gama natural para os poços I, II e III. A partir do par estímulo-resposta,



LEGENDA

COMPOSIÇÕES MINERALÓGICAS E FRAÇÕES VOLUMÉTRICAS (%)

①	FOLHELHO	QUARTZO.....	21.00
		CALCITA.....	2.00
		CAOLINITA.....	6.00
		K-FELDSPATO.....	28.00
		MUSCOVITA.....	2.00
		ILITA.....	15.00
		POSFATO.....	0.50
ÁGUA.....	25.50		
②	EVAPORITO	ANIDRITA.....	90.00
		ÁGUA.....	10.00
③	CALCÁRIO DOLOMÍTICO	CALCITA.....	52.00
		DOLOMITA.....	30.00
④	CALCÁRIO	CALCITA.....	85.00
		ÁGUA.....	15.00
⑦	EMBASAMENTO	QUARTZO.....	50.00
		MUSCOVITA.....	14.00
		BIOTTA.....	4.00
		K-FELDSPATO.....	27.00
		ÁGUA.....	5.00

Figura 7.3 - Modelo geológico sintético I, perfilado nos poços I, II e III. (modificado de PANTUZZO, 1996)

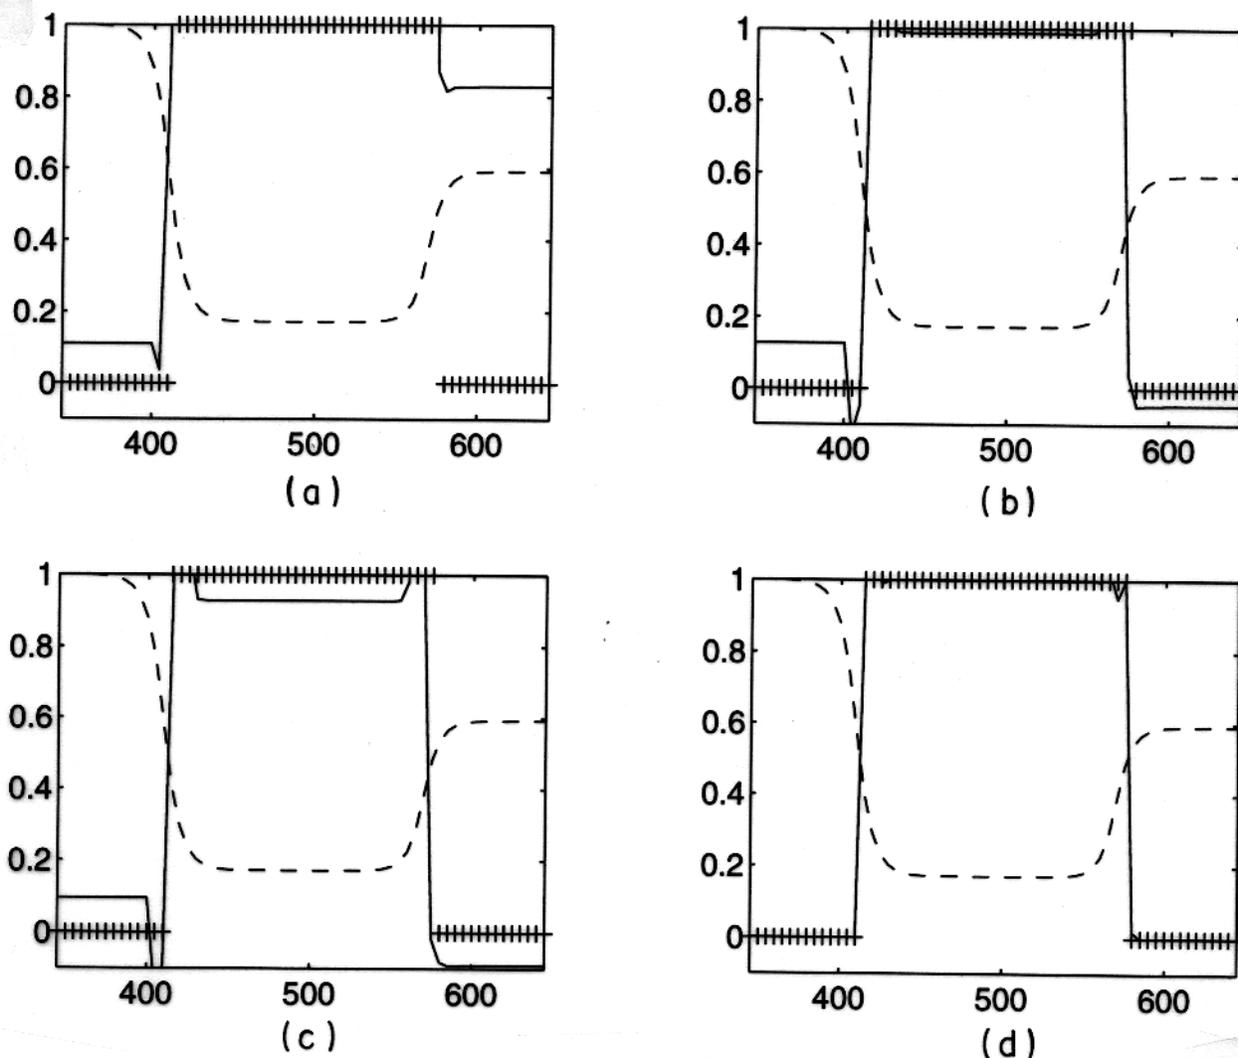


Figura 7.4 - Treinamento da rede neuronal. Nesta figura, no eixo horizontal estão marcadas as profundidades do intervalo de perfil adotado para o treinamento e no eixo vertical mostra-se a resposta da rede. O trecho do perfil de treinamento é marcado com linha tracejada, a resposta desejada esta marcada com cruzeiros e a resposta da rede é marcada com a linha cheia. (a) 50 épocas. (b) 750 épocas. (c) 1 500 épocas. (d) 2 500 épocas.

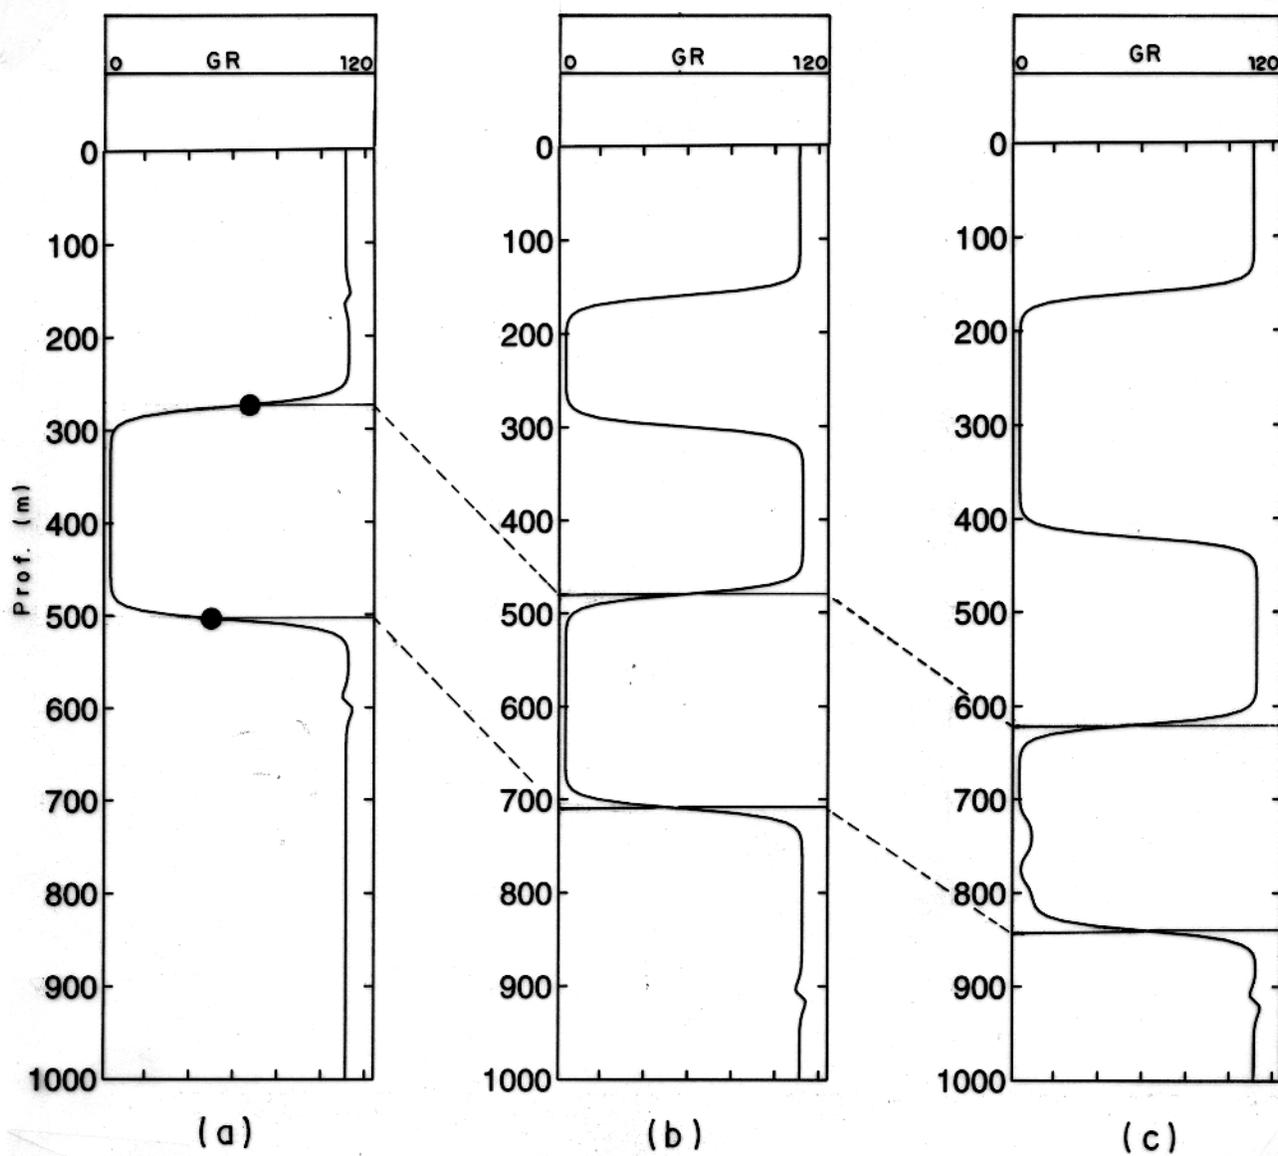


Figura 7.5 - Simulação da correlação poço-a-poço dos perfis de raio gama obtidos nos poços I (a), II (b) e III (c). Os círculos escuros no perfil (a) mostram as interfaces utilizadas para o treinamento da rede.

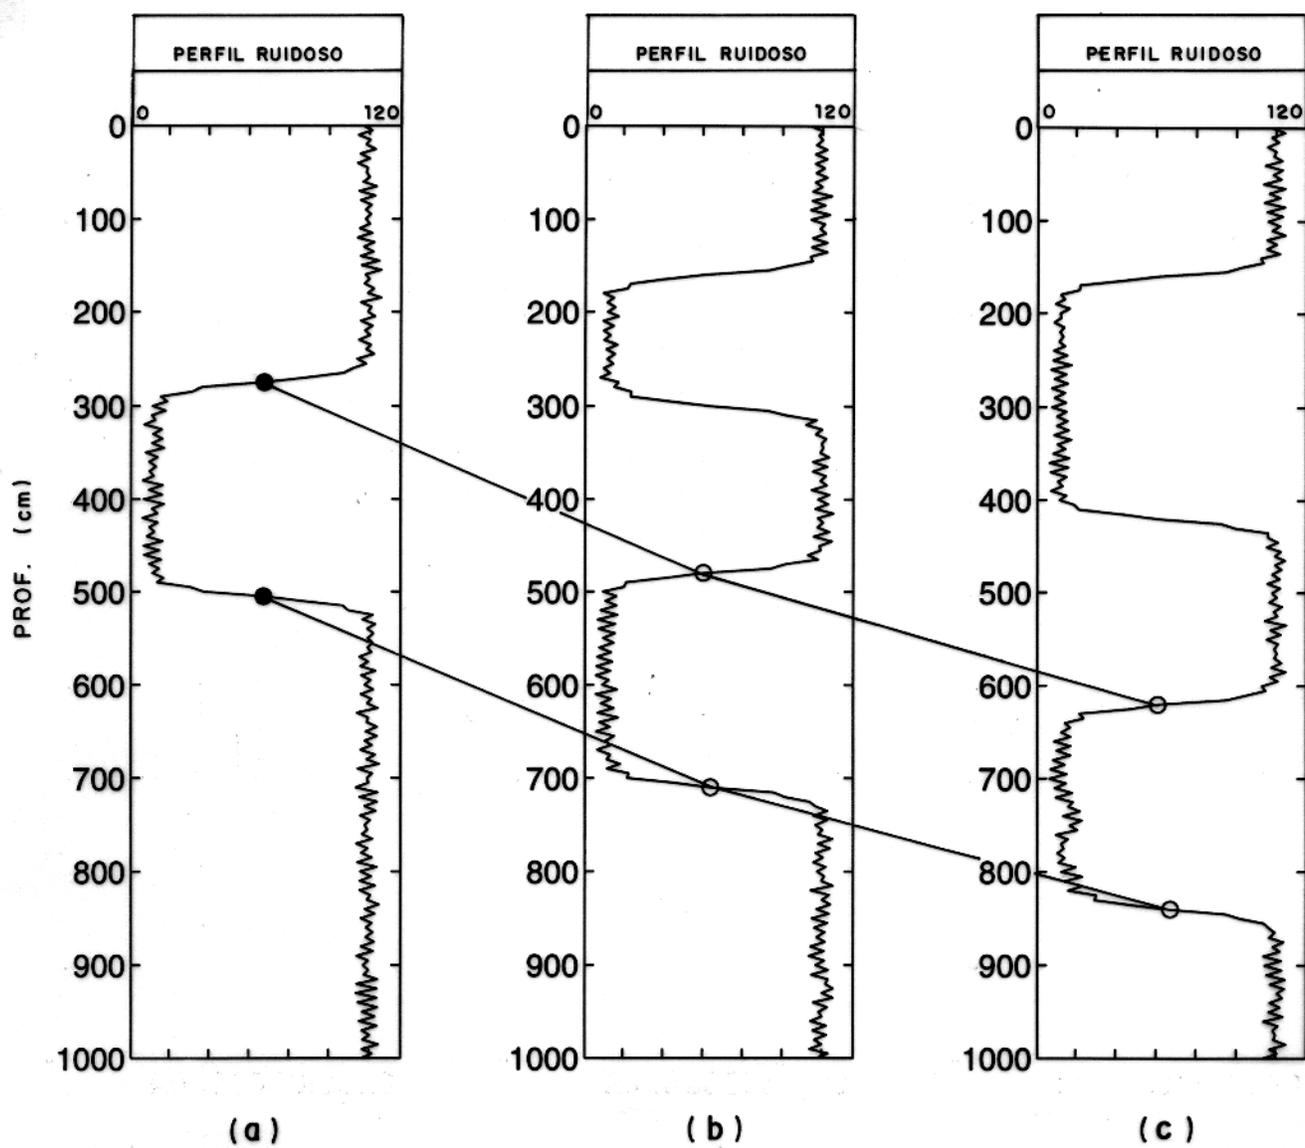


Figura 7.6 - Simulação da correlação poço-a-poço dos perfis de raio gama contaminados com ruído, obtidos nos poços I (a), II (b) e III (c). Os círculos escuros no perfil (a) mostram as interfaces utilizadas para o treinamento da rede.

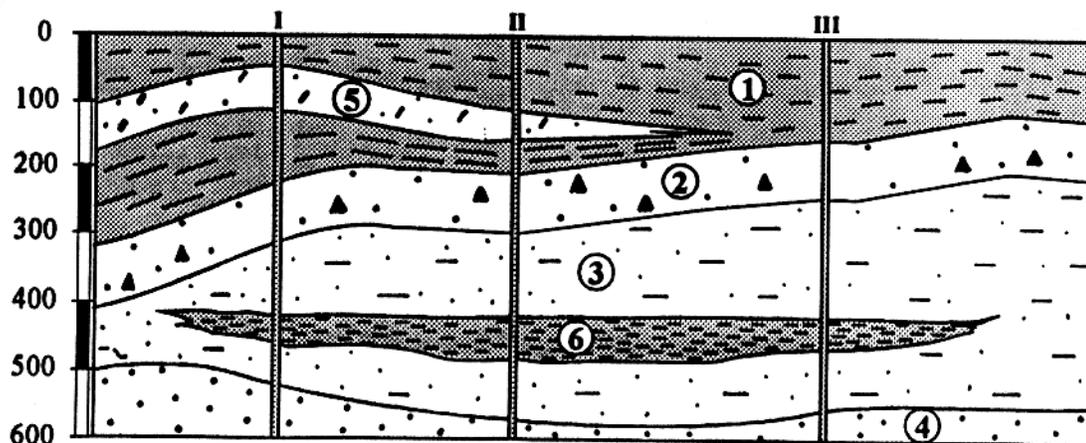
mostrado na Figura 7.8, foi treinada uma rede neuronal, segundo a arquitetura da Figura 7.2, com 20 neurônios na camada oculta. No treinamento o par estímulo-resposta foi apresentado 3000 vezes. Na Figura 7.9, mostra-se o resultado da correlação poço a poço, realizada pela rede neuronal, para a correlação da camada 5 na Figura 7.7.

7.3.2 Resultados sobre Dados Reais

Nesta seção, aplica-se a arquitetura de redes neuronais mostrada na Figura 7.2, para a simulação da tomada de decisão do intérprete para a realização da correlação estratigráfica em cinco poços da região de Lago Maracaibo, Venezuela (LUTHI et al, 1995).

No tratamento com dados reais, a rede neuronal foi projetada com 120 neurônios na camada oculta. Adotou-se o perfil de volume de argila do poço w1112, como perfil base e escolhemos o intervalo de treinamento mostrado na Figura 7.10, que mostra ainda quatro instantes do treinamento dessa rede. O treinamento se estendeu a um total de 4500 épocas.

Mostra-se os resultados da correlação estratigráfica realizada pela rede neuronal na Figura 7.11 e na Figura 7.12. Como também pode ser visto pela Tabela 7.1, onde mostra-se os resultados das profundidades de topo e base da camada correlacionada pela rede neuronal em comparação com a correlação efetuada visualmente por um interprete (LUTHI et al, 1995).

**LEGENDA****MINERALOGIA E FRAÇÕES VOLUMÉTRICAS(%)**

①		QUARTZO..... 20.00 MONTMORLONITA..... 60.00 ÁGUA..... 20.00 FOLHELHO
②		QUARTZO..... 58.00 MONTMORLONITA..... 26.00 ÁGUA..... 16.00 ARENITO MONTMORLONÍTICO
③		QUARTZO..... 64.00 ILITA..... 20.50 ÁGUA..... 15.50 ARENITO ILÍTICO
④		QUARTZO..... 80.00 ÁGUA..... 20.00 ORTOQUARTZITO
⑤		QUARTZO..... 61.00 MUSCOVITA..... 15.00 BIOTTA..... 4.00 ÁGUA..... 20.00 ARENITO MICACEO
⑥		QUARTZO..... 28.30 ILITA..... 51.70 ÁGUA..... 20.00 FOLHELHO

Figura 7.7 - Modelo geológico sintético II, perfilado nos poços I, II e III. (modificado de PANTUZZO, 1996)

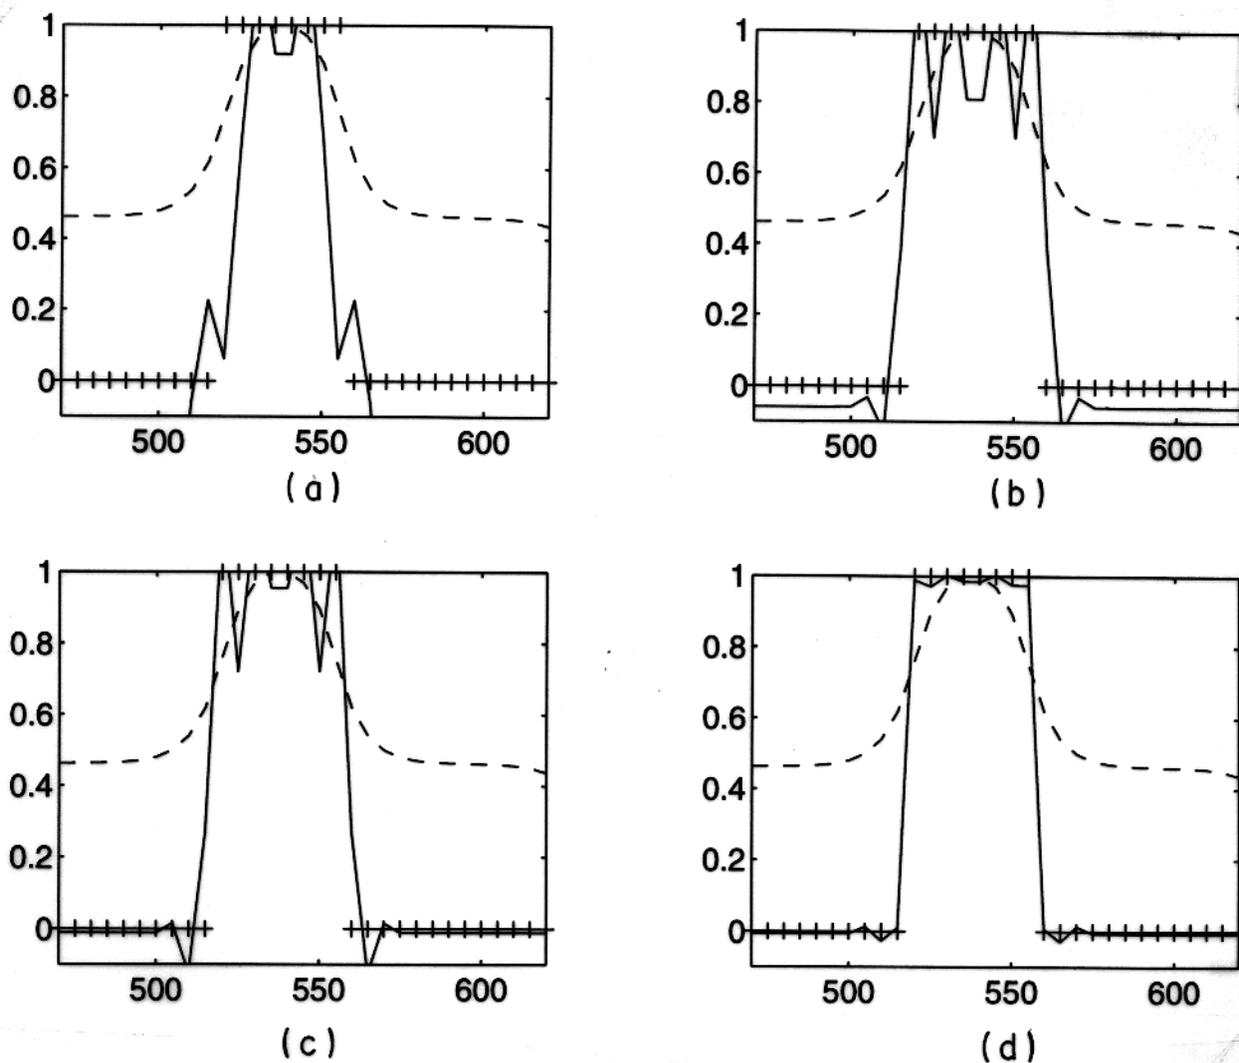


Figura 7.8 - Treinamento da rede neuronal. Nesta figura, no eixo horizontal estão marcadas as profundidades do intervalo de perfil adotado para o treinamento e no eixo vertical mostra-se a resposta da rede. O trecho do perfil de treinamento é marcado com linha tracejada, a resposta desejada esta marcada com cruces e a resposta da rede é marcada com a linha cheia. (a) 50 épocas. (b) 750 épocas. (c) 1 500 épocas. (d) 3000 épocas.

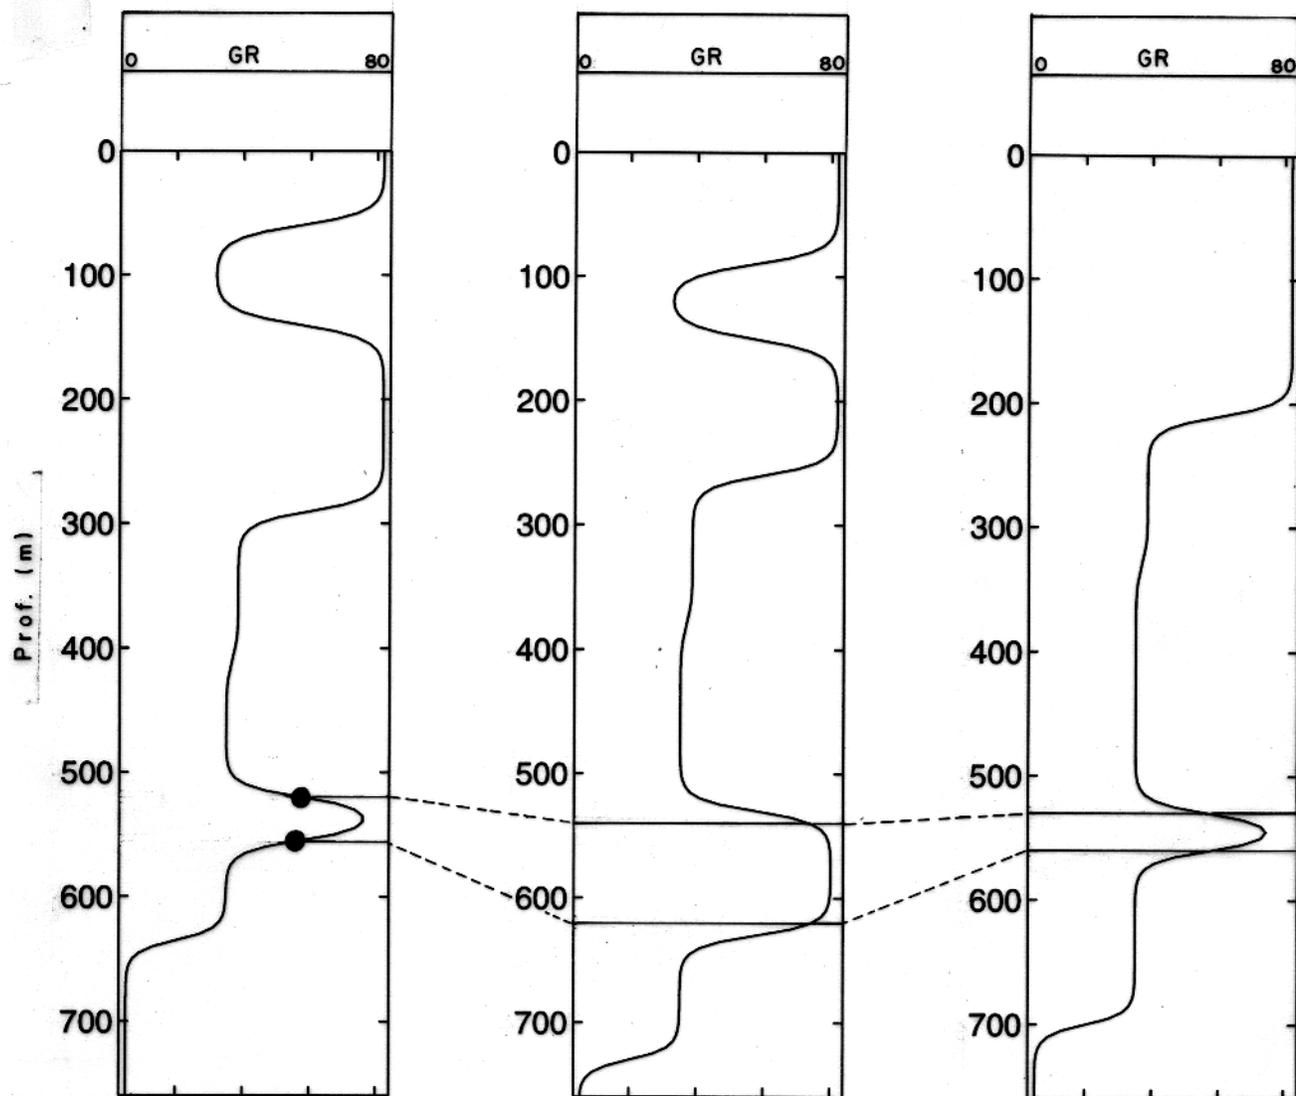


Figura 7.9 - Simulação da correlação poço-a-poço dos perfis de raio gama obtidos nos poços I (a), II (b) e III (c). Os círculos escuros no perfil (a) mostram as interfaces utilizadas para o treinamento da rede.

Tabela 7.1 - Comparação das profundidades (em metros) para a correlação poço-a-poço entre o interprete e a rede neuronal

Correlação Estratigráfica				
Poço	Interprete		Rede Neuronal	
	Topo	Base	Topo	Base
w1112	3 208,9	3 215,1	3 208,9	3 215,0
w991	3 224,7	3 232,1	3 224,4	3 231,9
w893	3 139,0	3 146,7	3 139,0	3 144,8
w866	3 290,0	3 295,4	3 290,9	3 296,3
w706	3 122,5	3 124,0	3 122,3	3 123,6

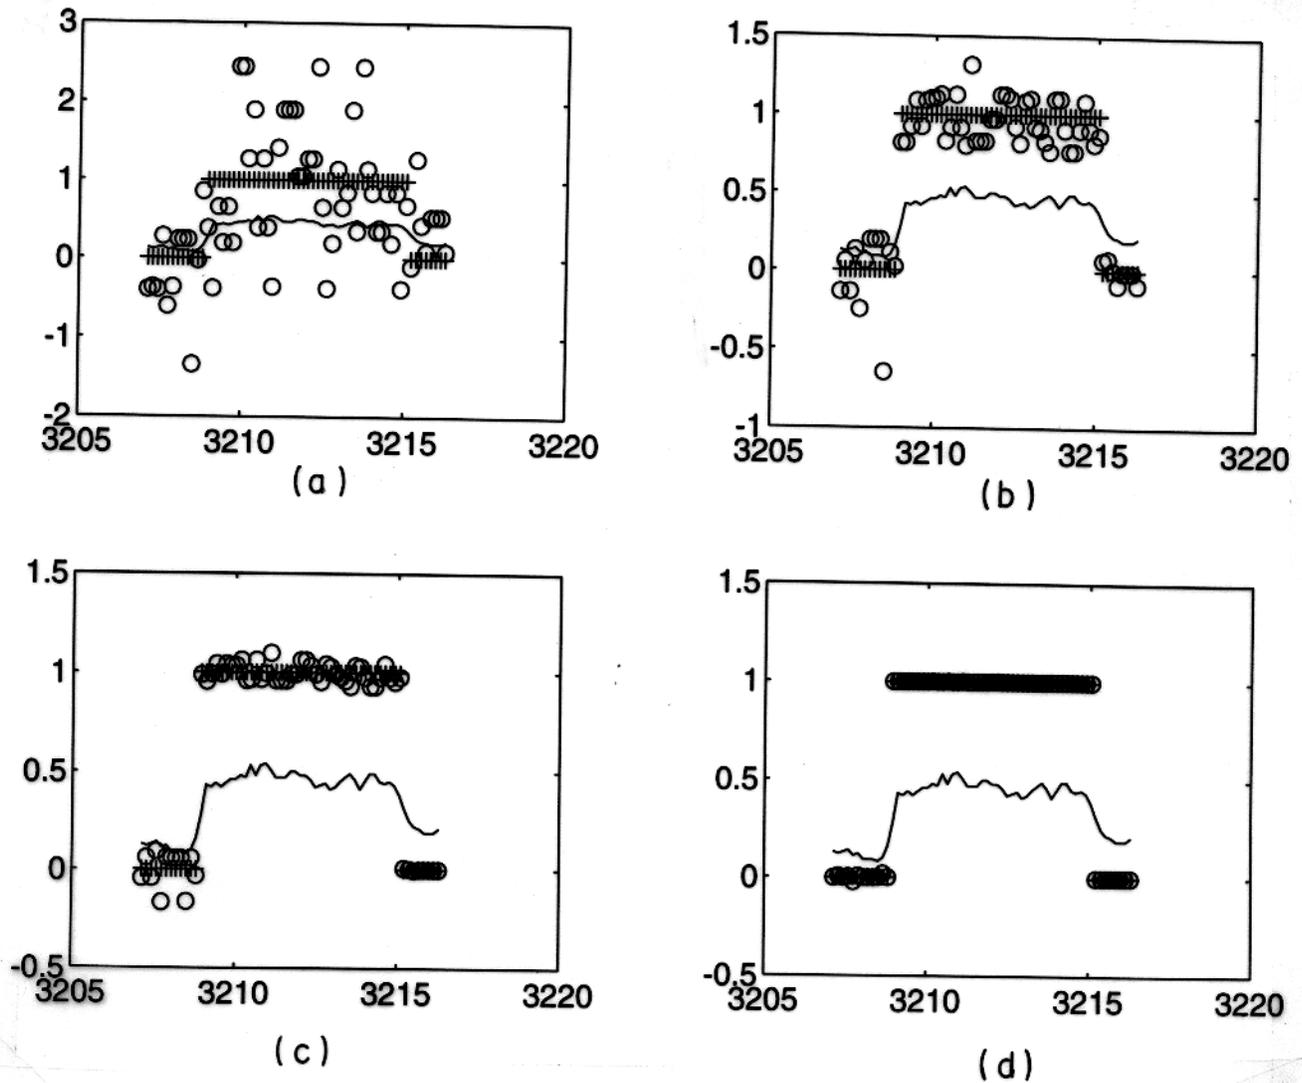


Figura 7.10 - Treinamento da rede neuronal. Nesta figura, no eixo horizontal estão marcadas as profundidades do intervalo de perfil adotado para o treinamento e no eixo vertical mostra-se a resposta da rede. O trecho do perfil de treinamento é marcado com linha tracejada, a resposta desejada esta marcada com cruzeiros e a resposta da rede é marcada com a linha cheia. (a) 50 épocas. (b) 750 épocas. (c) 2 500 épocas. (d) 4 500 épocas.

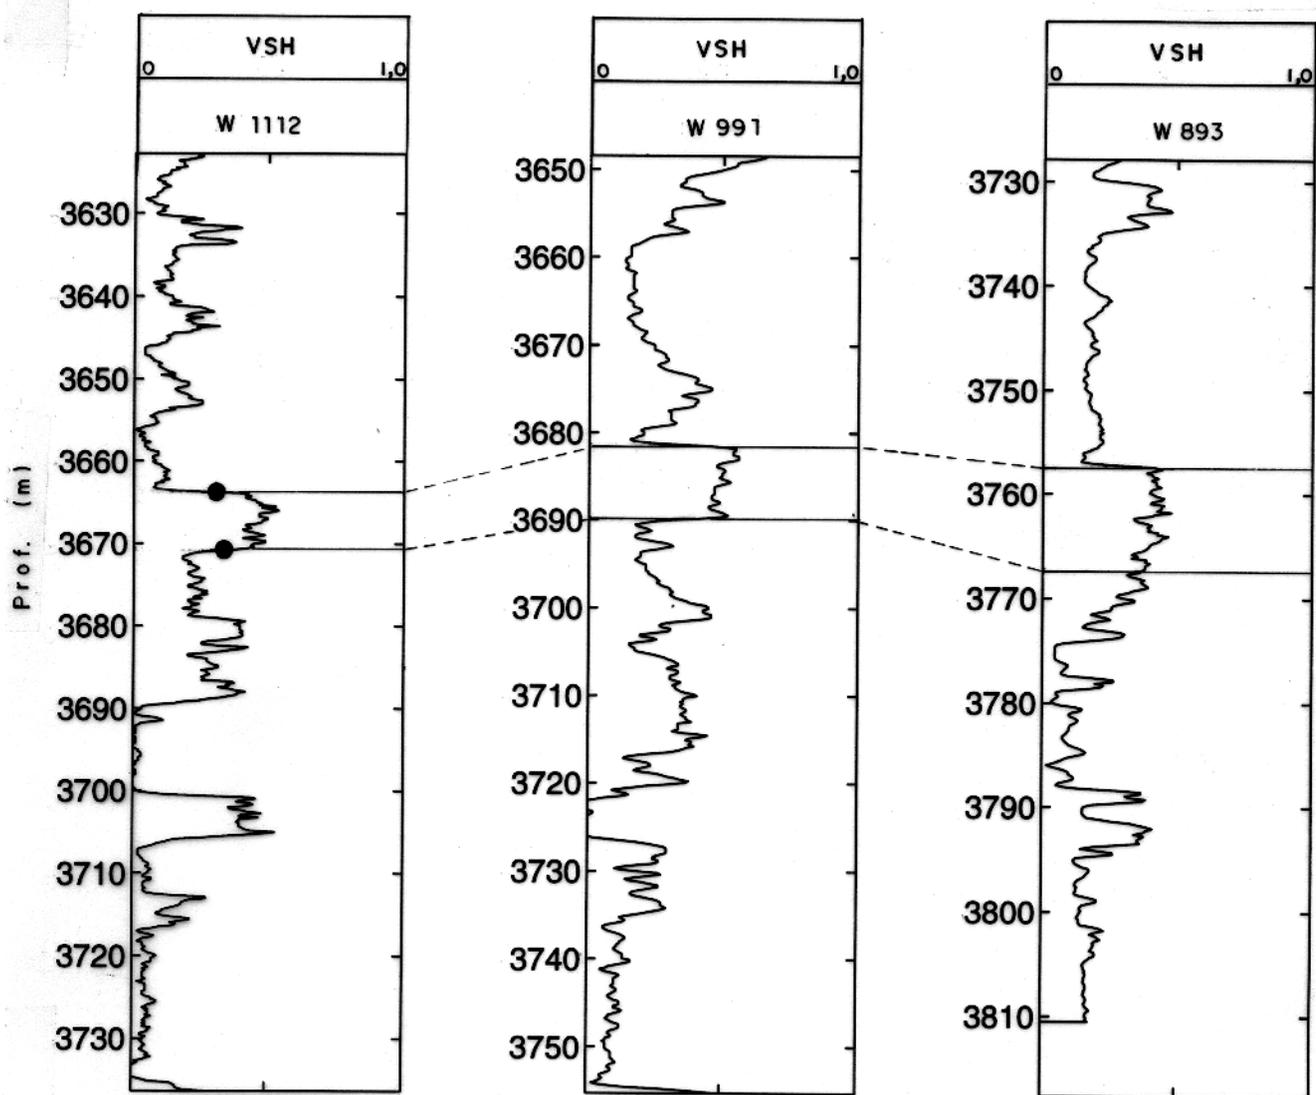


Figura 7.11 - Simulação da correlação poço-a-poço dos perfis reais de volume de argila dos poços w1112, w991, w866. (LUTHI et al, 1995)

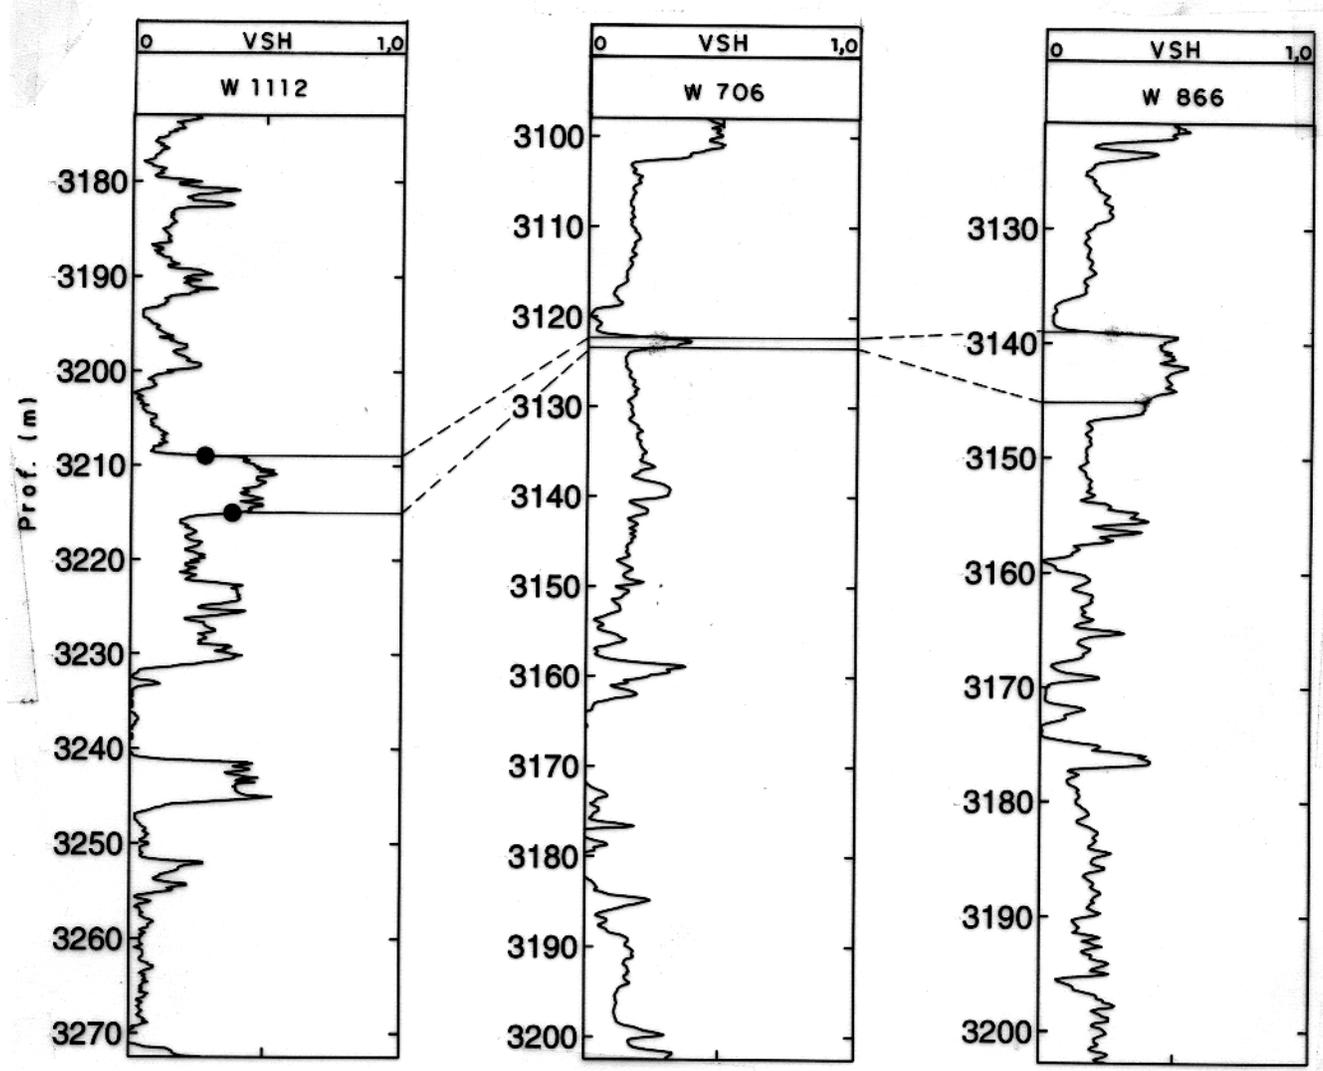


Figura 7.12 - Simulação da correlação poço-a-poço dos perfis reais de volume de argila dos poços w1112, w893, w706. (LUTHI et al, 1995)

8 - CONCLUSÃO

A principal aplicação de uma rede neuronal artificial é a de simular, ainda que de um modo bastante simplificado, o comportamento do sistema visual humano, em atividades como a do reconhecimento de padrões e de classificações. Com isto, a computação com uma rede neuronal artificial pode possibilitar, de forma eficiente, a automação dos processos mentais de tomada de decisão, que são peculiares ao ser humano mas completamente estranhos aos algoritmos sequenciais convencionais.

Sob este ponto de vista, a avaliação do comportamento ou do processamento de uma rede neuronal deve ser tratada de um modo diferente daquele dado aos processos computacionais convencionais. A correção, ou a qualidade, do processamento com uma rede neuronal não pode ser avaliada, simplesmente em função da comparação da resposta fornecida pela rede neuronal com aquela que se considera como resposta correta.

O resultado da aplicação do processamento de uma rede neuronal deve, então, ser avaliado no sentido de se obter uma verificação, mesmo que de forma qualitativa, da incorporação da informação contida no conjunto de treinamento, ou nos parâmetros livres estabelecidos para a rede neuronal e na sua capacidade de utilização deste conhecimento em situações inéditas.

A utilização do conhecimento adquirido pela rede, durante a fase de atualização dos seus parâmetros livres, foi aqui avaliada pela razão entre a quantidade de informação fornecida através do conjunto de treinamento e a quantidade de novas informações obtidas por meio do seu processamento.

Neste trabalho, apresentou-se a computação com as redes neuronais artificiais aplicada a três assuntos típicos da interpretação geológica de perfis de poço. Para que estes tópicos pudessem ser tratados de maneira conveniente por meio da computação conexionista, sob o ponto de vista de simular o comportamento do sistema visual do intérprete de perfil, eles foram definidos na forma de *problemas de decisão*.

O primeiro assunto abordado foi o da determinação das interfaces no perfil, o qual foi tratado sob dois pontos de vista. Em primeiro lugar por meio de uma rede neuronal direta multicamadas, onde se apresentou uma forma computacionalmente eficiente, para a arquitetura da rede neuronal direta multicamadas, aqui chamada de *forma vetorial*, associada a uma definição conveniente para o conjunto de treinamento. A aplicação dos dados de perfil nesta

Tabela 8.1 - Comparação das profundidades (em metros) das interfaces determinadas pelo intérprete, pela rede neuronal direta multicamadas e rede neuronal de HOPFIELD para o poço w1112.

Interprete	Rede Direta	Rede de HOPFIELD
3 190,3	3 190,8	3 194,1
3 200,1	3 198,0	3 202,0
3 209,0	3 209,0	3 210,1
3 215,3	3 215,3	3 218,1
3 224,8	3 223,1	3 226,0
3 231,0	3 229,8	3 232,3

arquitetura possibilitou a solução de problema de uma maneira eficiente, e com uma boa utilização da informação contida no conjunto de treinamento. Esta consistia da informação de apenas algumas das interfaces, e o processamento da rede neuronal foi capaz de encontrar praticamente todas as interfaces existentes ao longo do trecho de perfil.

Em segundo lugar, o problema da determinação das interfaces foi abordado a partir da definição de uma arquitetura de rede neuronal recorrente do tipo HOPFIELD. Obteve-se os seus parâmetros livres por meio da associação da função energia, que governa a dinâmica da rede neuronal, a uma função objeto obtida a partir da norma euclidiana, entre o dado real de perfil e o obtido por meio do modelo convolucional, o qual destacava a profundidade de localização das interfaces. O processamento com a rede de HOPFIELD leva a um decréscimo contínuo da função energia até que a variação dos estados dos neurônios seja desprezível. Com isto, a associação direta dos estados dos neurônios com a presença ou não de uma interface, levou a uma determinação satisfatória do posicionamento das interfaces em profundidade, em comparação com a determinação realizada por um intérprete.

A comparação direta entre o comportamento destas duas redes pode ser realizada em termos da eficiência computacional. Neste caso, a rede neuronal direta multicamadas apresentou uma grande vantagem em relação à rede de HOPFIELD, uma vez que ela não apresenta a necessidade da manipulação com matrizes de grandes dimensões. Por outro lado, esta comparação pode ser realizada em função da precisão dos resultados de ambas as redes, em comparação àqueles definidos pelo intérprete. Esta avaliação pode ser vista na Tabela 8.1 obtida para a determinação das interfaces para um trecho do poço w1112.

O segundo tópico da interpretação de perfis poço aqui abordado foi o problema da identificação de litologias através dos perfis de porosidade. Este assunto foi tratado sob um novo ponto de vista, onde uma arquitetura de rede neuronal contendo uma camada competitiva foi

aplicada para a automação da interpretação do gráfico M-N, visando simular o processo de tomada de decisão do intérprete nesta atividade. O comportamento da rede, quando aplicada diretamente sobre dados reais de perfil foi bastante satisfatório em comparação com a análise de testemunho realizada por um intérprete. Isto abre novas perspectivas para a aplicação das redes neuronais artificiais para a automação de uma das atividades mais rotineiras do intérprete de perfis que é a interpretação de gráficos e ábacos.

O terceiro tópico abordado foi o da correlação estratigráfica poço-a-poço de perfis. Este assunto é um dos mais nobres na interpretação da informação dos perfis geofísicos. A simulação do comportamento do intérprete se procedeu por meio da utilização da mesma arquitetura de rede neuronal direta multicamadas, desenvolvida para o caso da determinação das interfaces, em virtude da sua boa eficiência computacional. Isto associado à definição de um novo conjunto de treinamento propriamente desenvolvido para esta simulação. O método conforme apresentado, quando aplicado sobre dados sintéticos e reais, mostrou resultados bastante satisfatórios.

Todos os algoritmos utilizados nesta tese foram escritos sob o ambiente MATLAB, utilizando algumas das rotinas do *Neural Toolbox*, aplicados sobre uma plataforma RISC 6000.

O tratamento isolado dado a estes problemas de modo algum limita a possibilidade da associação destas redes neuronais, para a produção automática de uma primeira aproximação para o modelo geológico para o reservatório, como pode ser visto por meio do fluxograma mostrado na Figura 8.1.

A avaliação dos resultados das arquiteturas de redes neuronais para as aplicações aqui apresentadas mostraram um bom desempenho e indicam a possibilidade de um maior incremento da utilização das redes neuronais para o auxílio ao intérprete de perfis. Bem como, para a preparação de futuros trabalhos envolvendo a aplicação das redes neuronais artificiais para o caso geral da automação de várias das atividades dos intérpretes de outros dados geofísicos.

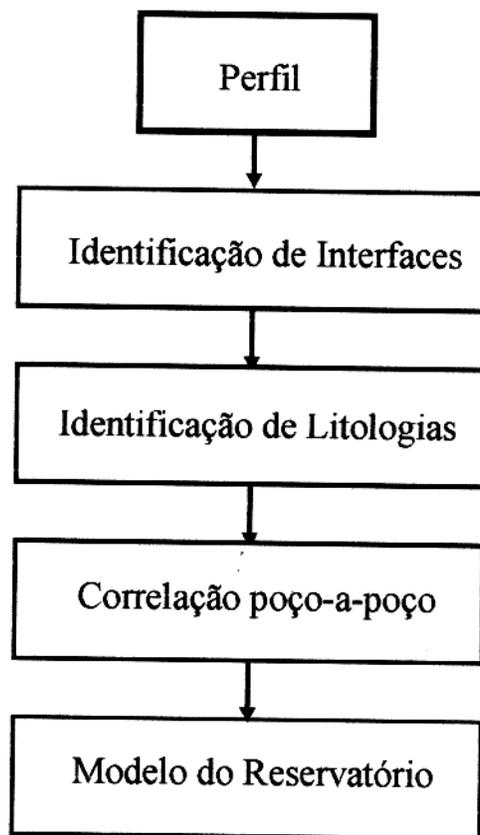


Figura 8.1 - Fluxograma, que mostra a associação em série das redes neuronais para a produção de uma primeira aproximação para o modelo do reservatório.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALEKSANDER, I. & MORTON, H. 1990 **An Introduction to Neural Computing**. London. Chapman & Hall.
- AMAREL, S. 1968 On Representation of Problems of Reasoning about Actions. **Machine Intelligence III** (D. Michie, editor). New York. Elsevier.
- AMARI, S. 1972 Characteristics of Random Nets of Analog Neuron-like Elements. **IEEE, Transactions on Systems, Man and Cybernetics, SMC-2**.
- ANDRADE, A. J. N. 1992 **Deconvolução de Perfis de Poço**, Dissertação de Mestrado. CPGf-UFPa, Belem, Pa, Brasil.
- ANDRADE, A. J. N. & LUTHI, S. M. 1993 **Deconvolução de Perfis de Poço**, **Anais do Terceiro Congresso Internacional da Sociedade Brasileira de Geofísica**, Vol II. Rio de Janeiro, Brasil.
- ANDRADE, A. J. N. & LUTHI, S. M. 1995 **Determinação de Interfaces em Perfis através da Rede Neuronal de Hopfield**. **Anais do Quarto Congresso Internacional da Sociedade Brasileira de Geofísica**, Vol II. Rio de Janeiro, Brasil.
- ARCHIE, G. E. 1942 The Electrical Resistivity Log as an Aid in Determining some Reservoir Characteristics. **American Institute of Mechanical Engineering Vol. 146**.
- BALDWIN, J. L. 1991 Using a Simulated Bidirectional Associative Neural Network Memory with Incomplete Prototype Memories to Identify Facies From Intermittent Logging Data Acquired in a Siliciclastic Depositional Sequence: A Case Study. **SPE Annual Technical Conference and Exhibition**. Dallas. USA.
- BALDWIN, J. L.; BATEMAN, R. M.; WHEATLEY, C. L. 1989a Application of a Neural Network to the Problem of Mineral Identification From Well Logs. **Third International Symposium on Borehole Geophysics for Minerals, Geotechnical and Ground Water Applications**. Las Vegas, USA.
- BALDWIN, J. L.; OTTE, D. N.; WHEATLEY, C. L. 1989b Computer Emulation of Human Mental Processes: Application of Neural Network Simulators to Problems in Well Log Interpretation. **SPE 64th Annual Technical Conference**, USA.

- BALDWIN, J. L.; OTTE, D. N.; BATEMAN, R. M.. 1989c Computer Emulation of Human Mental Processes: Application of Neural Network Simulators to Problems in Well Log Pattern Recognition. **Artificial Intelligence in Petroleum Exploration and Production Conference, USA.**
- BARBOSA, V. C. & CARVALHO, L. A. V. 1992 Uma Introdução à Computação por Redes Neurais. **Oitava CBA-UFPa, Belém, Pa, Brasil.**
- BRYANT, I. D. & VILLARROEL, H. G. 1994 Sedimentology of the Lower Lagunillas Reservoir, Pilot Area, Bloque IV, Lake Maracaibo, Venezuela. **Technical Report of Schlumberger-Doll Research. Ridgefield, USA.**
- BUCHEB, J. A. 1991 Aplicação de Tratamento Multivariante em Dados de Perfis de Poço da Bacia de Sergipe-Alagoas. Dissertação de Mestrado. CPGf-UFPa, Belem, Pa, Brasil.
- BURKE, J.; CAMPBELL, R. & SCHIMIDT, A. 1969 The Lithoporosity Crossplot. **SPWLA 10th Logging Symposium.**
- CICHOCKI A. & UNBEHAU R. 1995 **Neural Networks for Optimization and Signal Processing.** John Wiley & Sons. USA.
- COHEN, M. A. & GROSSBERG, S. 1983 Absolute Stability of Global Pattern Formation and Parallel Storage by Competitive Neural Networks, **IEEE, Transactions on Systems, Man and Cybernetics, SMC-13.**
- CYBENKO, G. 1989 **Approximation by Superposition of a Sigmoidal Function.** Urbana: University of Illinois.
- DOLL, H. G. 1949 Introduction to Induction Logging and Application to Logging of Wells Drilled with Oil Base Mud. **Petr. Trans. AIME, Vol 186.**
- DOLL, H. G. 1950 The Microlog - A New Electrical Logging method for Detailed Determination of Permeable Beds. **Petr. Trans. AIME, Vol 187.**
- DOLL, H. G. 1951 The Laterolog - A New Resistivity Logging with Electrodes Using an Automatic Focusing System. **Petr. Trans. AIME, Vol 192.**
- DOVETON, J. H. 1986 **Log Analysis of Subsurface Geology - Concepts and Computer Methods.** John-Wiley & Sons. USA.

- EECKMAN, F. H. & FREEMAN, W. J. 1986 The Sigmoid Nonlinearity in Neural Computation: An Experimental Approach. **Neural Networks for Computing** (J. Denker, editor), American Institute of Physics. New York. USA.
- ELLIS, D. V. 1987 **Well Logging for Earth Scientists**. Elsevier. USA.
- FISCHLER, M. A. & FIRSCHEIN, O. 1987 **Intelligence: The Eye, the Brain and the Computer**. Addison-Wesley, Reading MA.
- FONS, L. 1969 Geological Applications of Well Logs. **SPWLA Tenth Annual Logging Symposium**. USA.
- GIANNAKIS, G. B.; MENDEL, J. M.; ZHAO, X. F. 1989 A fast prediction-error detector for estimating sparse-spike sequences. **IEEE Trans. on geoscience and remote sensing**, 27.
- GONÇALVES, C. A.; HARVEY, P. K.; LOVELL, M. A. 1995 Using a Multilayer Neural Network and Statistical Techniques to Characterise Oceanic Crust. **Anais do Quarto Congresso Internacional da Sociedade Brasileira de Geofísica**, Vol II. Rio de Janeiro, Brasil.
- GROSSBERG, S. 1982 **Studies of Mind and Brain**. Reidel. Boston. USA
- HAYKIN, S. 1994 **Neural Networks -A Comprehensive Approach**. Macmillan College Publishing Company. USA.
- HEARST, J. R. & NELSON, P. H. 1985 **Well Logging for Physical Properties**. McGraw-Hill Book Company. USA.
- HEBB, D. O. 1949 **Organization of Behavior: A Neuropsychological Theory**. Wiley. New York.
- HECHT-NIELSEN, R. 1987 Kolmogorov's Mapping Neural Network Existence Theorem. 1st **IEEE International Conference on Neural Networks**. Vol 3. San Diego. USA.
- HECHT-NIELSEN, R. 1990 **Neurocomputing**. Addison-Wesley. Reading, MA. USA.
- HILTON, G. E. & NOWLAN, S. J. 1987 How Learning Can Guide Evolution. **Complex Systems I**.
- HOPFIELD, J. J. 1982 Neural Networks and Physical Systems with Emergent Collective Computational Abilities. **Proc. of the National Academy of Sciences of the USA**, 79.

- HOPFIELD, J. J. 1984 Neurons with Graded Response Have Collective Computational Properties like those of Two-state Neurons. **Proceedings of the National Academy of Sciences of the USA**, 81.
- HOPFIELD, J. J. & TANK, T. W. 1985 Neural Computation of Decisions in Optimization Problems. **Biological Cybernetics**, 52.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. 1989 Multilayer Feedforward Network are Universal Approximators. **Neural Networks**, 2.
- HUSH, D. R. & HORNE, B. G. 1993 Progress in Supervised Neural Networks: What is new since Lippmann, **IEEE Signal Processing Magazine**, 10.
- JACOBS, R. A. 1988 Increased Rates of Convergence through Learning Rate Adaptation. **Neural Networks**, 1.
- JANSSEN, P.; STOICA, P.; SONDERSTROM T.; EYKHOFF, P. 1988 Model Structure Selection for Multivariable System by Cross-Validation. **International Journal of Control**.
- KOHONEN, T., 1988 Self Organization and Associative Memory, 3rd ed. Springer-Verlag, New York. USA.
- KRAMER, A. H. & SANGIVANNI-VINCENTELLI, A. 1989 Efficient Parallel Learning Algorithms for Neural Networks. **Advances in Neural Information Processing Systems** (D. S. Touretzky, editor). Morgan-Kaufmann. San Mateo, USA.
- KUO T. B. & STARTZMAN R. A. 1987 An Artificial Intelligence Approach to Well Log Correlation. **SPWLA, 27th Annual Logging Symposium**. USA.
- LABO, J. 1987 **A Practical Introduction to Borehole Geophysics**. Geophysical Reference Series. Vol 2. SPE. USA.
- LANG, W. L. 1986 Correlation with Multiples Logs. **The Log Analyst**. Jan-Feb.
- LeCUN, Y.; BOSER, B.; DENKER, J.; HENDERSON, D.; HOWARD, R.; HUBBARD W.; JACKEL, L. 1990 Handwritten Digit Recognition with a Back-propagation Network. **Advances in Neural Information Processing Systems 2**. USA.
- LEE, Y.; OH, S.; KIM, M. 1991 **The Effect of initial Weights on Premature Saturation in Back-Propagation Learning**. International Joint Conference on Neural Networks. Vol 1. Seattle, USA.

- LUTHI, S. M.; BRYANT, I. D. 1997 Well Log Correlation Using Backpropagation Neural Networks. submitted to **Mathematical Geology**; in press.
- MCCORMACK, M. D. 1990 Seismic Trace Editing and First Picking Using Neural Networks. **SEG, 60th Annual International Meeting, USA.**
- McCULLOCH, W. S. & PITTS, W. 1943 A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, 5.
- MENKE, W. 1984 **Geophysical Data Analysis: Discrete Inverse Theory**, Academic Press, Inc. New York, USA.
- MINSKY, M. L. & PAPERT, S. A. 1969 **Perceptrons**. MIT Press. Cambridge, USA.
- NERI, G. G. 1990 **Perfilagem Geofísica de Poço Aberto**. Petrobras/SEDES. Brasil.
- OLEA, R. A. & DAVIS, J. C. 1986 An Artificial Intelligence Approach to Lithostratigraphic Correlation using Geophysical Well Logs. **SPE 60th Technical Conference**. USA.
- PANTUZZO F. L. 1996 **Modelo para Correlação de Litologias Complexas Utilizando os Perfis de Espectrometria de Raios Gama Naturais**. Dissertação de Mestrado. CPGf-UFPa, Belem, Pa, Brasil.
- PARKER, D. B. 1985 **Learning-logic: Casting the Cortex of the Human Brain in Silicon**. Technical Report TR-44, Center for Computational Research in Economics and Management Science. MIT Press, Cambridge, USA.
- PARKER, D. B. 1987 Optimal Algorithms for Adaptive Networks: Second Order Direct Propagation and Second Order Hebbian Learning. **IEEE, 1st International Conference on Neural Networks**. Vol. 2. San Diego, USA.
- PINEDA, F. J. 1988 Generalization of Back-propagation to Recurrent and higher Order Neural Networks. In **Neural Information Processing Systems**. (D. Anderson, editor). American Institute of Physics. New York, USA.
- POULTON, M.; STERNBERG, B.; GLASS, C. 1992 Neural Network Pattern Recognition of Subsurface EM Images. **Journal of Applied Geophysics**, N. 29. Elsevier Science Publishers B. V. Amsterdam.
- ROSENBLATT, F. 1962 **Principles of Neurodynamics**. Spartan Books. Washington, USA.

- RUI-LIN, L.; CHENG-DANG, Z.; ZHEN-WU, J. 1992 Lithofacies Sequence Recognition from Well Logs using Time-Delay Neural Networks. **SPWLA 33rd Annual Logging Symposium**, San Antonio, USA.
- RUMELHART, D. E. & McCLELLAND, 1986 **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. Vol 1. MIT Press. Cambridge, USA.
- SACKINGER, E.; BOSER, B.; JACKEL, L. 1992 A Neurocomputer Board Based on the ANNA Neural Network Chip Advances in **Neural Information Processing Systems 4** (J. Moody, editor). Morgan-Kaufmann. San Mateo, USA.
- SCHLUMBERGER LOG INTERPRETATION CHARTS, 1988.
- SEJNOWSKI, T.; YUHAS, B.; GOLDSTEIN, M.; JENKINS, R. 1990 Combining Visual and Acoustic Speech Signals with a Neural Network Improves Intelligibility. Advances in **Neural Information Processing Systems** (D. S. Touretzky, editor). Morgan-Kaufmann. San Mateo, USA.
- SERRA, O. & ABBOTT, H. T. 1980 The Contribution of Logging Data to Sedimentology and Stratigraphy. **SPE 55th Technical Conference**. USA.
- SILVA, J. C. 1993 **Simulação de Perfis Nucleares de Poço em Formações Complexas**. Tese de Doutorado. CPGf-UFPa. Brasil.
- SHEPHERD, G. M. & KOCH, C. 1990 Introduction to Synaptic Circuits. In **The Synaptic Organization of the Brain** (G. M. Shepherd, editor) Oxford University Press. New York, USA.
- WANG, D.; QINGYUAN, H.; XINMIAO, H. 1994 Feed-Forward Neural Network for the Lithofacies Recognition with Well Logs. **The Log Analyst**, Sep-Oct.
- WERBOS, P. J. 1974 **New Tools for Prediction and Analysis in the Behavioral Sciences**. Phd thesis, Harvard University. Cambridge, USA.
- WIDROW, B. & HOFF, M. E. 1966 **Adaptive Switching Circuits** IRE WESCOM Convention Record.
- WIELAND, A. & LEIGHTON, R. 1987 Geometric Analysis of Neural Networks Capabilities. **IEEE, 1st International Conference on Neural Networks**. USA.
- WYLLIE, M.; GREGORY, A.; GARDNER, G. 1956 Elastic Wave Velocities in Heterogeneous and Porous Media. **Geophysics** Vol 21 n. 1.

ZHOUBO, L.; SIXIN, L.; LINGE, S. 1994 Application of Neural Network to Fracture Zone in Metamorphic Rock. **The Log Analyst**. Sep-Oct.