

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

**DISSERTAÇÃO DE MESTRADO**

**DETERMINAÇÃO AUTOMÁTICA DA POROSIDADE E ZONEAMENTO DE PERFIS  
ATRAVÉS DE REDE NEURAL ARTIFICIAL COMPETITIVA**

**KLÉDSON TOMASO PEREIRA DE LIMA**



BELÉM – PA  
2000

*À memória de meu Pai Francisco.  
À minha mãe Antonia  
por seu amor, apoio e sabedoria.  
Aos meus irmãos e amigos  
Francisco Jr. e Hédson*

## AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão às várias pessoas que me deram sua ajuda e seu apoio durante o período que trabalhei nesta dissertação. Seria impossível mencionar a todas. Entretanto, estou especialmente grato:

A DEUS, por ter estado presente em todos os momentos, me dando inspiração para concluir e nunca pensar em desistir deste trabalho.

Ao meu orientador, Prof. Dr. André José N. Andrade, pela troca permanente de idéias; por enriquecedoras discussões em torno de questões fundamentais da geofísica e principalmente por ter assumido comigo este desafio.

Aos meus examinadores Profs. Drs. Stefan M. Luthi e Jadir C. da Silva pelas sugestões e correções que em muito contribuíram para melhorar esta tese.

À Universidade Federal do Pará que contribuiu para a minha formação acadêmica.

Ao convênio CNPq/UFPA, pelo suporte financeiro a este programa de Pós-Graduação.

À Empresa Maravem S.A. (Venezuela) por me fornecer dados, que foram fundamentais para a realização deste trabalho.

Ao corpo docente do Curso de Pós-Graduação em geofísica da Universidade Federal do Pará, por estimulantes discussões e pelo meu aperfeiçoamento em geofísica.

Aos Profs. Roberto Vizeu, Geraldo das Virgens, Francisco de Assis Matos de Abreu e Cândido Moura, responsáveis pela minha introdução à pesquisa científica.

Aos funcionários do Curso de Geofísica, pelo apoio e cooperação, em especial à secretaria do curso de Pós-Graduação, Benildes (Beny), que me ajudou a partir do momento da minha inscrição no curso, criando desde então uma bela amizade.

Aos grandes amigos Danielle, Michael, J. J. Baptista, Lindenberg e Cleive Maria, pelo companheirismo, dedicação e valiosos momentos de descontração.

A todos meus colegas de curso de mestrado, em particular Vitor, Syme, German e Samuel, que contribuíram no com sugestões e críticas.

Ao bibliotecário Hélio Braga Martins pela revisão do texto e das normas de editoração.

À minha Mãe e irmãos, pela compreensão pelos dias, noites, fins de semana e feriados em que estive ausente; e que compartilharam de minhas dificuldades me incentivando a prosseguir na jornada.

Enfim a todos que contribuíram direta ou indiretamente para a realização deste trabalho, um abraço por chegar não ao fim, mais ao início de uma longa caminhada, com profundo sentimento de gratidão dedico o meu mérito.

## SUMÁRIO

<b>DEDICATÓRIA</b> .....	i
<b>AGRADECIMENTOS</b> .....	ii
<b>RESUMO</b> .....	01
<b>ABSTRACT</b> .....	02
<b>1. INTRODUÇÃO</b> .....	03
<b>2. PROCESSOS DE DETERMINAÇÃO DA POROSIDADE</b> .....	05
2.1 – INTRODUÇÃO .....	05
2.2 – PERFIS DE POROSIDADE .....	06
2.2.1 – Perfil de Densidade .....	06
2.2.2 – Perfil Neutrônico .....	09
2.3 – CÁLCULO DA POROSIDADE .....	11
2.4 . GRÁFICO DENSIDADE-NETRÔNICO PARA O MODELO ARENITO-FOLHELHO	13
<b>3 – REDE NEURAL ARTIFICIAL</b> .....	16
3.1 – INTRODUÇÃO .....	16
3.2 – NEURÔNIO BIOLÓGICO HUMANO .....	17
3.3 – MODELO DE NEURÔNIO ARTIFICIAL .....	19
3.4 – REDE NEURAL ARTIFICIAL .....	20
3.4.1 – Arquitetura de Rede Neural Artificial com Camada Competitiva .....	22
3.4.1.1 – Aprendizado Competitivo .....	26
<b>4 – METODOLOGIA</b> .....	29
4.1 – ARQUITETURA DE REDE NEURAL .....	29

<b>4.1.1 – Dados de Entrada</b> .....	30
<b>4.1.2 – Camada Competitiva</b> .....	30
<b>4.1.3 – Regra de Treinamento</b> .....	31
<b>4.2 – APLICAÇÃO AO ZONEAMENTO DE PERFIS E AO CÁLCULO DA POROSIDA- DE EFETIVA</b> .....	33
<b>4.2.1 – Zoneamento do Perfil</b> .....	34
<b>4.2.2 – Cálculo da Porosidade Efetiva</b> .....	37
<b>4.2.3 – Apresentação Final dos Resultados</b> .....	40
<b>5 – RESULTADOS</b> .....	41
<b>6 – CONCLUSÕES</b> .....	55
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	57

## RESUMO

Duas das mais importantes atividades da interpretação de perfis para avaliação de reservatórios de hidrocarbonetos são o zoneamento do perfil (log zonation) e o cálculo da porosidade efetiva das rochas atravessadas pelo poço.

O zoneamento é a interpretação visual do perfil para identificação das camadas reservatório e, conseqüentemente, dos seus limites verticais, ou seja, é a separação formal do perfil em rochas reservatório e rochas selante. Todo procedimento de zoneamento é realizado de forma manual, valendo-se do conhecimento geológico-geofísico e da experiência do intérprete, na avaliação visual dos padrões (características da curva do perfil representativa de um evento geológico) correspondentes a cada tipo litológico específico.

O cálculo da porosidade efetiva combina tanto uma atividade visual, na identificação dos pontos representativos de uma particular rocha reservatório no perfil, como a escolha adequada da equação petrofísica que relaciona as propriedades físicas mensuradas da rocha com sua porosidade. A partir do conhecimento da porosidade, será estabelecido o volume eventualmente ocupado por hidrocarboneto. Esta atividade, essencial para a qualificação de reservatórios, requer muito do conhecimento e da experiência do intérprete de perfil para a efetiva avaliação da porosidade efetiva, ou seja, a porosidade da rocha reservatório, isenta do efeito da argila sobre a medida das propriedades físicas da mesma.

Uma forma eficiente de automatizar estes procedimentos e auxiliar o geofísico de poço nestas atividades, que particularmente demandam grande dispêndio de tempo, é apresentado nesta dissertação, na forma de um novo perfil, derivado dos perfis tradicionais de porosidade, que apresenta diretamente o zoneamento. Pode-se destacar neste novo perfil as profundidades do topo e da base das rochas reservatório e das rochas selante, escalonado na forma de porosidade efetiva, denominado perfil de porosidade efetiva zoneado

A obtenção do perfil de porosidade efetiva zoneado é baseado no projeto e execução de várias arquiteturas de rede neural artificial, do tipo direta, com treinamento não supervisionado e contendo uma camada de neurônios artificiais, do tipo competitivo. Estas arquiteturas são projetadas de modo a simular o comportamento do intérprete de perfil, quando da utilização do gráfico densidade-neutrônico, para as situações de aplicabilidade do modelo arenito-folhelho.

A aplicabilidade e limitações desta metodologia são avaliadas diretamente sobre dados reais, oriundos da bacia do Lago Maracaibo (Venezuela).

## ABSTRACT

Two of the most important activities of log interpretation, for the evaluation of hydrocarbon reservoirs are the log zonation and the effective porosity calculation of the rocks crossed by the well.

The log zonation is the visual log interpretation for the identification, in depth, of the reservoir layers and its vertical limits, that is to say, it is the formal separation in reservoir rocks and non reservoir rocks (shales). The log zonation procedure is accomplished in a manual way, being been worth of the geologic and geophysical knowledge, and of the experience of the log analyst, in the visual evaluation of the curve patterns (log characteristics) corresponding to each specific rock type.

The calculation of the effective porosity (porosity of the rock reservoir corrected by clay effects), combines a visual activity so much in the identification of the representative points of a reservoir rock in the log, as well as the adapted choice of the petrophysics equation, that relates the physical properties of the rock to the porosity. Starting from the knowledge of the porosity, the hydrocarbon volume will be established. This activity, essential for the reservoirs qualification, requests a lot of the knowledge and of the experience of the log analyst, for the effective porosity evaluation.

An efficient form of automating these procedures and assistant the log analyst, in these activities, that particularly demand a great expenditure of time, is presented in this dissertation, in the form of a new log, derived of the traditional porosity logs, that presents the log zonation, highlighting the top and base depths of the occurrences of reservoir rocks, and non reservoir rocks, scaled in form of effective porosity, called here, as "zoning effective porosity log".

The obtaining of the zoning effective porosity log, is based on the project and execution of several architectures of artificial neural feedforward networks, with not supervised training, and contends a layer of artificial competitive neurons. Projected in way to simulate the behavior of the log analyst, when he uses the neutron-density chart, for the situations of applicability of the shale-sandstone model.

The applicability and limitations of this methodology will be appraised on real data, originated from of Lago Maracaibo's basin (Venezuela).

## 1 - INTRODUÇÃO

Uma das mais importantes atividades da interpretação visual ou manual de perfis, realizada pelo geofísico de poço para avaliação de reservatórios de hidrocarbonetos é a identificação, em profundidade, das rochas reservatório (rochas com potencial para acumulação de hidrocarbonetos) e, conseqüentemente, dos seus limites verticais (topo e base). A partir disto, podemos determinar as espessuras passíveis de conter acumulações de fluidos. A este procedimento, dá-se o nome de zoneamento do perfil (*log zonation*), que é a separação formal das rochas reservatório, de interesse para o geofísico de poço, das rochas selantes, através da correspondência entre as propriedades físicas da rocha, mensurada pela ferramenta de perfilagem, e suas propriedades petrofísicas.

Todo procedimento de zoneamento é realizado de forma manual, valendo-se do conhecimento geológico e geofísico do intérprete, na avaliação visual dos padrões (características da curva representativa do perfil) correspondentes a cada tipo litológico específico.

A mais importante atividade quantitativa do intérprete de perfis, é a determinação dos parâmetros petrofísicos das rochas reservatório, com o intuito de identificar a presença e quantificar o volume de hidrocarbonetos na rocha. Este procedimento combina tanto uma atividade visual, na identificação dos pontos representativos de uma particular rocha reservatório no perfil, como a escolha adequada e a correta aplicação das relações petrofísicas que correlacionam determinadas medidas físicas das rochas com suas propriedades petrofísicas. Este procedimento recebe a denominação de avaliação de formação, a partir do qual o geofísico de poço está apto à identificar os reservatórios e a qualificá-los, ou seja, estabelecer uma estratégia de aproveitamento ou produção para o poço. Uma das principais propriedades petrofísicas é a porosidade. A partir do seu conhecimento, será estabelecido o volume passível de ser ocupado pelo hidrocarboneto.

No caso de ambientes geológicos simples, como no caso das seqüências transgressivas e regressivas, caracterizadas por depósitos cíclicos de arenitos e folhelhos, conceitua-se o chamado modelo arenito-folhelho (CRAIN, 1986). A ciclicidade litológica é refletida em uma seqüência cíclica de padrões nos perfis. O fator preponderante, para propiciar um correto zoneamento e uma eficiente avaliação de formação para este tipo de modelo geológico, é a correta determinação da porosidade dos reservatórios argilosos. A argila disseminada no espaço poroso influencia, em

muito, as respostas físicas das rochas, mensuradas pelas ferramentas de perfilagem e refletidas nos perfis de porosidade, tais como o perfil neutrônico e o perfil de densidade (raios gama induzidos).

Este tipo de atividade, essencial para a qualificação de reservatórios argilosos, requer muito do conhecimento e da experiência do intérprete de perfil para a efetiva avaliação da porosidade efetiva, ou seja, a porosidade da rocha isenta de argila.

Uma forma de automatizar este procedimento e auxiliar o geofísico de poço nestas atividades essenciais, e que demandam grande dispêndio de tempo, é apresentado nesta dissertação, na forma de um novo perfil, derivado dos perfis de porosidade tradicionais, que apresenta de forma automática e completamente independente da intervenção do intérprete, o zoneamento do poço. Destaca-se nele as profundidades de topo e base das rochas reservatório e de rochas selantes, escalonado na forma de porosidade efetiva, denominado perfil de porosidade efetiva zoneada.

A obtenção do perfil de porosidade efetiva zoneada se baseia no projeto e execução de várias arquiteturas de rede neural artificial, do tipo direta, com treinamento não supervisionado e contendo uma única camada processadora composta por neurônios artificiais, do tipo competitivo. Estas arquiteturas são projetadas de modo a simular o comportamento do intérprete de perfil, quando da utilização do gráfico densidade-neutrônico para as situações de aplicabilidade do modelo arenito-folhelho.

Esta dissertação está organizada em seis capítulos, incluindo esta introdução como o primeiro. O segundo capítulo trata da determinação de porosidade e como ela é realizada atualmente, através de seus métodos mais comuns. No capítulo três, é feita uma revisão dos conhecimentos de redes neurais artificiais, necessários à completa interpretação do quarto capítulo, onde apresenta-se a metodologia aqui desenvolvida e cujos resultados estão apresentados e discutidos no quinto capítulo. No sexto e último capítulo, apresenta-se as conclusões finais do trabalho e algumas de suas possíveis futuras extensões.

## 2- PROCESSOS DE DETERMINAÇÃO DA POROSIDADE

### 2.1 - INTRODUÇÃO

Em geral, a porosidade tende a ser menor em rochas mais antigas e profundas. Este decréscimo na porosidade é devido principalmente à cimentação e pressão das camadas sobrepostas. Porém, há muitas exceções a esse padrão, principalmente quando as condições normais de sobrecarga não prevalecem.

Os folhelhos seguem o mesmo padrão de porosidade dos arenitos, exceto por sua porosidade ser normalmente menor. Por exemplo, em lamas recentes, a porosidade fica em torno de 40%. Este valor decresce rapidamente com a pressão de sobrecarga até a profundidade de cerca de 3.000 m, onde as porosidades normais estão em torno de 5%. Isso ocorre porque os folhelhos são plásticos e, por esta razão, se comprimem muito mais facilmente que as areias.

Esta tendência básica do comportamento da porosidade com a profundidade não é observada nos carbonatos, onde a porosidade é mais função do ambiente deposicional e processos secundários, ambos não relacionados à profundidade ou soterramento.

A porosidade secundária é criada por outros processos como a cimentação primária ou compactação de sedimentos. Um exemplo de porosidade secundária pode ser encontrado na dissolução de calcário ou dolomita com a água subterrânea, um processo pelo qual são criados vulgos ou cavernas. O processo de fraturamento também gera porosidade secundária. A dolomitização resulta em uma redução no volume dos grãos, como resultado da transformação do calcário em dolomita, gerando um acréscimo correspondente na porosidade. Na maioria dos casos, a porosidade secundária resulta em uma permeabilidade muito maior que a permeabilidade primária granular.

Porosidade total é a soma da porosidade primária ou intergranular com a porosidade secundária e a água da parte argilosa da rocha.

Porosidade efetiva é a soma da porosidade primária com a secundária, desde que o espaço ocupado pela argila não contribua efetivamente para a performance ou volume do reservatório.

A porosidade derivada diretamente de um perfil, sem correção para o volume de argila, é denominada porosidade aparente ou total. Se a zona não possui argila, a porosidade total é igual a porosidade efetiva. Se a zona contiver argila, a correção deve ser aplicada para obter a porosidade efetiva. Não se usa leituras de perfis diretamente, a menos que o volume de argila seja zero. Esse

cuidado também se aplica a perfis efetuados em PU (*porosity units*), quando a escala do perfil não se iguala à litologia atual (CRAIN, 1986).

## 2.2 – PERFIS DE POROSIDADE

A expressão *Perfil de Porosidade* é um termo genérico e informal que se refere aos perfis geofísicos, registrados pelas ferramentas sônica, densidade e neutrônica. Cada uma dessas ferramentas mede diferentes propriedades físicas, sensíveis à matriz da rocha e à porosidade, como:

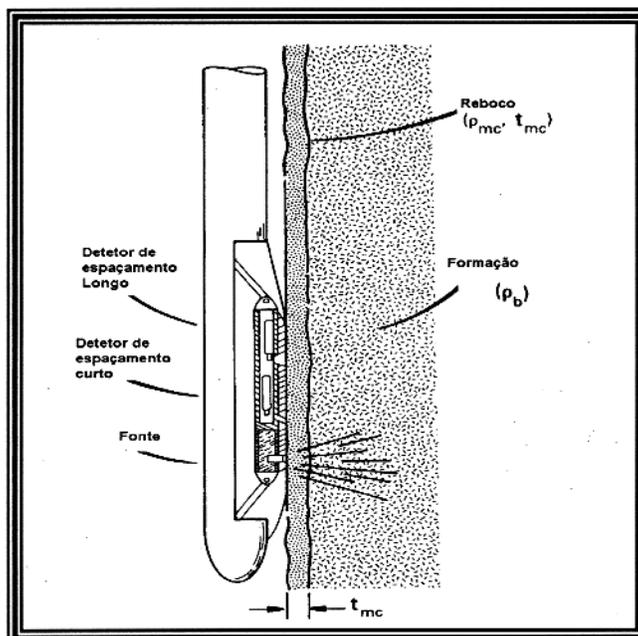
1. **Ferramenta de Densidade:** Densidade de elétron ( $\rho_e$ ), diretamente associada à densidade da matriz da rocha ( $\rho_b$ ) e à porosidade ( $\phi$ ).
2. **Ferramenta Sônica:** Tempo de trânsito da onda compressional ( $\Delta t$ ).
3. **Ferramenta Neutrônica:** Concentração relativa de hidrogênio, associado à presença de hidrocarboneto e água, principalmente no espaço poroso, portanto diretamente associada à porosidade ( $\phi$ ).

A interpretação integrada desses perfis é realizada principalmente com o auxílio de ábacos ou cartas específicas, desenvolvidas pela indústria do petróleo, que correlacionam as diversas propriedades físicas mensuradas com a litologia, porosidade e argilosidade.

### 2.2.1 – Perfil de Densidade

O perfil de densidade consiste em um registro contínuo das variações das massas específicas (densidade) das formações atravessadas por um poço. Nos casos de rochas reservatório (permo-porosa), a medição realizada pelo perfil inclui tanto a densidade da matriz da rocha, quanto a dos fluidos contidos no espaço poroso.

A ferramenta de densidade consiste de uma fonte radioativa de raios gama, geralmente Césio-137, montada em um mandril com patins metálicos, os quais são pressionados contra a parede do poço, como mostrado na Figura 2.1. A fonte é a responsável pela emissão de raios gama de alta energia, que interagem com os elétrons dos átomos da formação. Esta interação pode ser de três modos diferentes: efeito fotoelétrico, efeito Compton e produção do par elétron-pósitron; onde destacaremos apenas os dois primeiros, de interesse para a geofísica de poço.

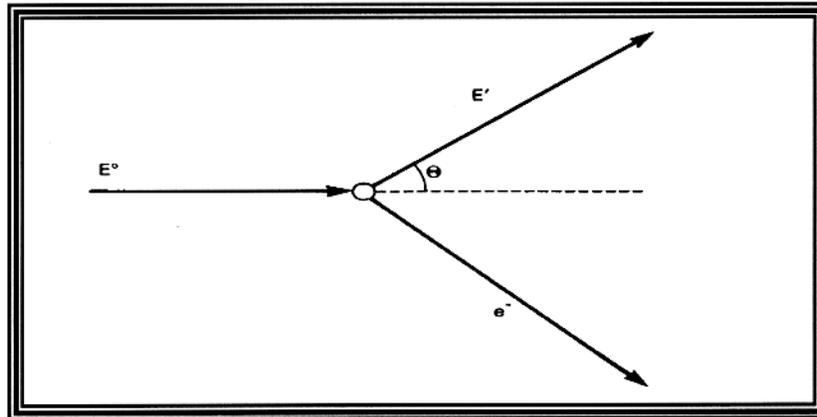


**Figura 2.1** – Modelo da ferramenta de densidade.

O efeito fotoelétrico resulta da interação do raio gama com um elétron, afastando-o do núcleo do átomo. Neste processo, o raio gama incidente é absorvido e transfere toda a sua energia para o elétron, que é ejetado de sua órbita natural. Se a energia do raio gama incidente é suficientemente grande, o elétron é expelido do átomo interagindo com o material adjacente. Normalmente o elétron ejetado é substituído por outro, próximo, com energia que depende do número atômico do material, porém geralmente abaixo de 100 keV.

O efeito Compton também envolve interações dos raios gama com os elétrons orbitais. É um processo no qual somente parte da energia do raio gama é cedida para o elétron. O efeito Compton é de grande importância em técnicas de medição e também como um mecanismo de interação entre raios gama e a formação. A Figura 2.2 ilustra o processo no qual um raio gama incidente interage com um elétron do material. A diferença entre a energia do raio gama incidente e a energia do raio gama dispersado é cedida para o elétron.

O processo Compton se evidencia no intervalo energético de 0,1 a 1,0 MeV, e é o modo preferencial de interação entre os raios gama e as rochas.



**Figura 2.2** - Representação esquemática do efeito Compton. O raio gama incidente transfere uma parte de sua energia ( $E^0$ ) para um elétron, e um raio gama de energia reduzida ( $E'$ ) deixa o local da colisão com a direção  $\theta$  em relação à direção de incidência.

A primeira geração da ferramenta de densidade era constituída de uma fonte de raio gama e um único detetor de radiação (Cintilômetros de *NaI*). Contudo, para compensar a constante interferência do filtrado de lama e do reboco, a segunda geração de ferramentas (Figura 2.1) incorporou dois detetores de radiação em um mandril para captar a radiação emitida pela fonte. A ferramenta é mantida em contato com a parede do poço por um braço hidráulico, que tem também como função fazer a leitura do diâmetro do poço, que auxiliará nas correções da densidade.

A estimativa de porosidade em um reservatório utiliza a relação de balanço de massas, na qual a densidade total de uma zona é a soma das densidades dos materiais desta zona, multiplicado por suas respectivas proporções volumétricas. Para uma formação sem argilosidade, a equação apropriada é escrita na forma:

$$\rho_b = \phi_D \cdot \rho_f + (1 - \phi_D) \rho_{ma}, \quad (2.1)$$

onde:

$\rho_b$  = Densidade total da zona.

$\rho_f$  = Densidade do fluido no espaço poroso.

$\rho_{ma}$  = Densidade da matriz mineral.

$\phi_D$  = Porosidade de densidade.

Quando se avalia reservatórios do tipo arenito argiloso, deve-se fazer uma correção da influência da argila na determinação da porosidade efetiva, através de uma expansão da equação básica, na forma:

$$\rho_b = \phi_D \cdot \rho_f + (1 - \phi_D - V_{sh}) \rho_{ma} + V_{sh} \cdot \rho_{sh}, \quad (2.2)$$

onde:

$\rho_{sh}$  = Densidade do folhelho sotoposto ao reservatório.

$V_{sh}$  = Proporção volumétrica de argila.

### 2.2.2 – Perfil Neutrônico

Os nêutrons são partículas destituídas de carga elétrica, com massa quase idêntica a do átomo de hidrogênio. Sendo partículas neutras, elas podem penetrar profundamente na matéria, atingindo os núcleos dos elementos que compõem a rocha, onde interagem através de choques elásticos e/ou inelásticos.

As ferramentas neutrônicas são constituídas por uma fonte de nêutrons e de 1 (um), 2 (dois) (Schlumberger, Figura 2.3) ou 4 (quatro) detetores. A fonte emite nêutrons rápidos que penetram nas camadas adjacentes ao poço. Através das sucessivas e múltiplas colisões elásticas, os nêutrons perdem parte da energia com que foram emitidos. Esta perda de energia depende da massa relativa ou da seção eficaz do núcleo com o qual o nêutron colide. Sabe-se que a maior quantidade de perda ocorre quando os nêutrons se chocam com núcleo de massa praticamente igual a sua, portanto, com um núcleo de hidrogênio.

Após sucessivas colisões os nêutrons diminuem sua energia (consequentemente também a velocidade), até atingir o nível termal do meio ( $KT \approx 0,025$  eV). A partir deste momento eles se difundem erráticamente, sem mais perda de energia, até serem capturados por átomos do meio, não obrigatoriamente de hidrogênio. O núcleo que o captura se torna excitado e emite raios gama característicos ao retornar ao seu estado fundamental (NERY, 1989).

Há uma relação exponencial da porosidade com a leitura neutrônica que possui a seguinte forma:

$$e^{-K\phi_N} = CN, \quad (2.3)$$

onde:

$\phi_N$  = Porosidade.

$N$  = Leitura neutrônica da zona.

$K$  e  $C$  = Constantes relacionadas à ferramenta, ao tamanho do poço e à litologia.

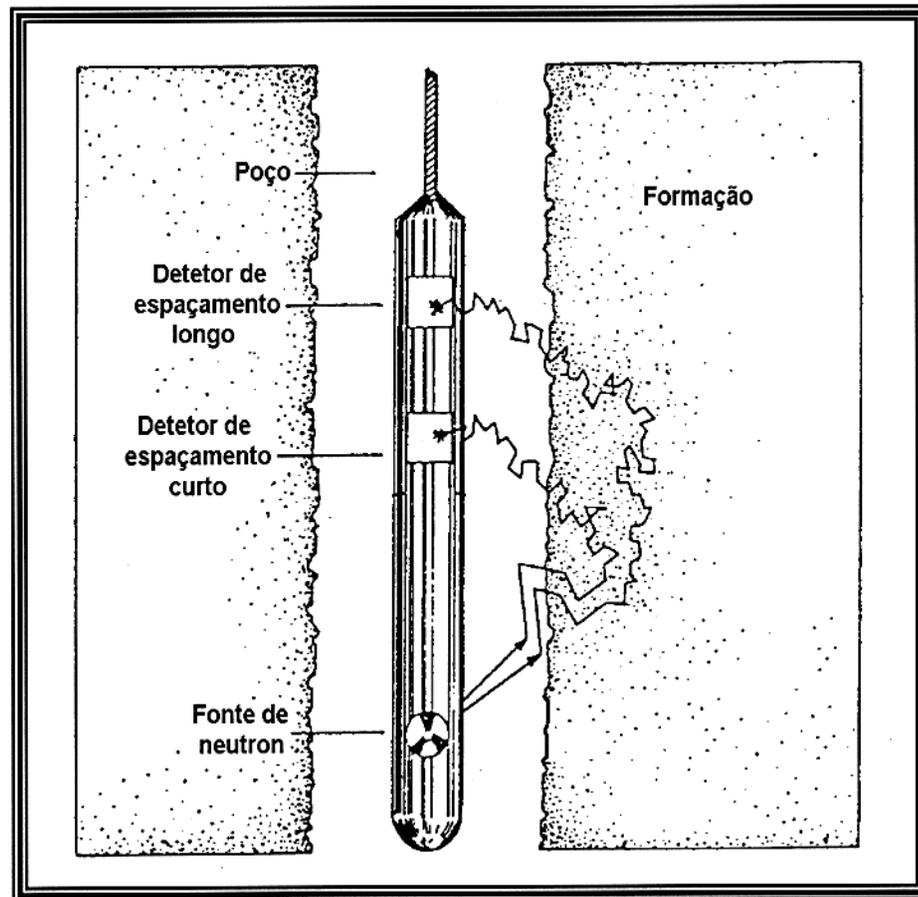
Esta relação (2.3) tem sido aproximada por uma equação logarítmica do tipo:

$$\log \phi_N = C - KN. \quad (2.4)$$

Esta equação é usada na calibração da escala neutrônica, em termos de unidade de porosidade, e requer no mínimo dois pontos para sua definição. Uma calibração sistemática pode ser feita igualando a contagem neutrônica das zonas com porosidades estimadas de outras fontes, como medidas de perfis ou testemunhos geológicos.

Já as ferramentas modernas são aritmética e diretamente escalonadas em unidade de porosidade equivalente, relacionadas à matriz de calcário, arenito e dolomita. Isto tem sido alcançado por novas ferramentas que possuem fonte e detetor montados em um patim de borracha que é pressionado diretamente contra a formação, reduzindo, deste modo, a influência da variação do diâmetro do poço. Ao mesmo tempo, o registro alcançado é transmitido a um computador ligado à ferramenta, que converte leitura neutrônica em unidade de porosidade equivalente, por contagem monitorada de nêutrons, levando em conta as variações do poço.

Para qualquer uma das ferramentas neutrônicas, o amortecimento do nível energético dos nêutrons rápidos depende da quantidade de hidrogênio por unidade de volume das camadas próximas às paredes do poço. O elemento hidrogênio é encontrado não somente na água, mas também nos hidrocarbonetos, preenchendo os espaços porosos das rochas. Alguns óleos, a depender de sua densidade, têm aproximadamente a mesma concentração de hidrogênio por unidade de volume que a água. Já o gás ou óleos leves (condensados) apresentam uma concentração de hidrogênio menor, fazendo com que esta ferramenta, combinada com a densidade, se torne uma ótima arma na identificação da presença de gás nas rochas reservatórios.



**Figura 2.3** – Representação esquemática de Ferramenta Neutrônica com dois detectores (adaptado de ELLIS, 1987).

### 2.3 – CÁLCULO DA POROSIDADE

A aplicação dos métodos numéricos para o cálculo da porosidade das rochas atravessadas pelo poço utiliza a álgebra matricial simples para o desenvolvimento de programas computacionais, com base nos valores registrados nos perfis de porosidade.

O cálculo convencional da porosidade envolve as soluções simultâneas da equação resposta para os dois perfis. A equação resposta para o perfil de densidade em PU é expressa na forma clássica:

$$\begin{aligned} \phi_D = & \phi_e * Sxo * \phi_{Dw} + \phi_e * (1 - Sxo) * \phi_{Dh} + \\ & + V_{sh} * \phi_{Dsh} + (1 - V_{sh} - \phi_e) * \sum_{i=1}^m (V_i * \phi_{Di}) \end{aligned} \quad (2.5)$$

onde:

- $\phi_{Dh}$  = *Leitura do perfil em 100% hidrocarboneto*
  - $\phi_{Di}$  = *Leitura do perfil em 100% no i – ésimo componente da matriz*
  - $\phi_D$  = *Leitura do perfil*
  - $\phi_{Dsh}$  = *Leitura do perfil em 100% folhelho*
  - $\phi_{Dw}$  = *Leitura do perfil em 100% água*
  - $\phi_e$  = *Porosidade efetiva*
  - $Sxo$  = *Saturação de água na zona invadida*
  - $V_i$  = *Volume do i – ésimo componente da matriz*
  - $V_{sh}$  = *Volume do folhelho*
- 

A equação resposta para o perfil neutrônico também segue a forma clássica:

$$\begin{aligned} \phi_N = & \phi_e * Sxo * \phi_{Nw} + \phi_e * (1 - Sxo) * \phi_{Nh} + \\ & + V_{sh} * \phi_{Nsh} + (1 - V_{sh} - \phi_e) * \sum_{i=1}^m (V_i * \phi_{Ni}) \end{aligned} \quad (2.6)$$

onde:

- $\phi_{Nh}$  = *Leitura do perfil em 100% hidrocarboneto*
  - $\phi_{Ni}$  = *Leitura do perfil em 100% no i – ésimo componente da matriz*
  - $\phi_N$  = *Leitura do perfil*
  - $\phi_{Nsh}$  = *Leitura do perfil em 100% folhelho*
  - $\phi_{Nw}$  = *Leitura do perfil em 100% água*
  - $\phi_e$  = *Porosidade efetiva*
  - $Sxo$  = *Saturação de água na zona invadida*
  - $V_i$  = *Volume do i – ésimo componente da matriz*
  - $V_{sh}$  = *Volume do folhelho*
-

Várias suposições são feitas para resolver estas duas equações (2.5 e 2.6) simultaneamente para a porosidade. A segunda variável determinada pelo par é geralmente o volume de argila ou densidade da matriz, que pode determinar o tipo de rocha. Se uma dessas é escolhida, a outra deve ser assumida ou previamente calculada.

#### 2.4 – GRÁFICO DENSIDADE - NEUTRÔNICO PARA O MODELO ARENITO - FOLHELHO

O ponto de origem do gráfico  $\phi_D$  x  $\phi_N$  (Figura 2.4) é um ponto de porosidade igual a zero, representando conseqüentemente a matriz da rocha. Os eixos de  $\phi_D$  e  $\phi_N$  aumentam de porosidade à medida que se afastam da origem. Assim, a interseção de  $\phi_D = 1,0$  e  $\phi_N = 1,0$  indica um ponto de água somente, isto é, um ponto cuja saturação de água é 100%. Se deslocarmos, ao longo da bissetriz (1), o ponto de matriz em direção ao ponto de água, à medida que diminui o volume da matriz, aumenta o volume de água. Assim, a bissetriz cuja equação é  $\phi_D = \phi_N$ , é uma reta onde cairão, obrigatoriamente, todos os pontos que contenham água ou um fluido de densidade próxima a ela. Esta reta, por suas próprias características, indica as porosidades efetivas, já que os seus pontos têm  $V_{sh} = 0\%$ .

Lançando agora um outro ponto, o de folhelho, escolhido nas zonas soto e sobrepostas àquela em que estamos estudando. De acordo com o que já foi explicado, suas coordenadas serão  $(\phi_{Nsh}, \phi_{Dsh})$ . Podemos unir este ponto à origem do gráfico, formando a reta dos folhelhos (2).

O ponto origem do gráfico é, como já dissemos, o de matriz somente. Assim se deslocamos um ponto desde a origem do gráfico até o ponto de folhelho, nada mais estamos fazendo do que diminuindo o volume da matriz enquanto aumentamos a quantidade de argila. Em outras palavras, saímos de zero até 100% de folhelho. A equação que define esta reta (2) é:

$$\phi_D = \frac{\phi_{Dsh}}{\phi_{Nsh}} \cdot \phi_N \quad (2.7)$$

Qualquer ponto localizado em uma reta paralela a reta  $\phi_D = \phi_N$  terá um volume de folhelho calculado através da equação desta reta, dada por:

$$\phi_D = \phi_N + V_{sh}(\phi_{Dsh} - \phi_{Nsh}), \quad (2.8)$$

que é a reta de isoargilosidade (4), de onde conclui-se que

$$V_{sh} = \frac{\phi_N - \phi_D}{\phi_{Nsh} - \phi_{Dsh}} = V_{shND} \quad (2.9)$$

Qualquer ponto localizado ao longo de uma reta paralela a reta dos folhelhos (Figura 2.4), terá um  $V_{sh}$  calculado pela fórmula acima. Sua porosidade efetiva, medida na reta  $\phi_D = \phi_N$ , será determinada através da equação da própria reta:

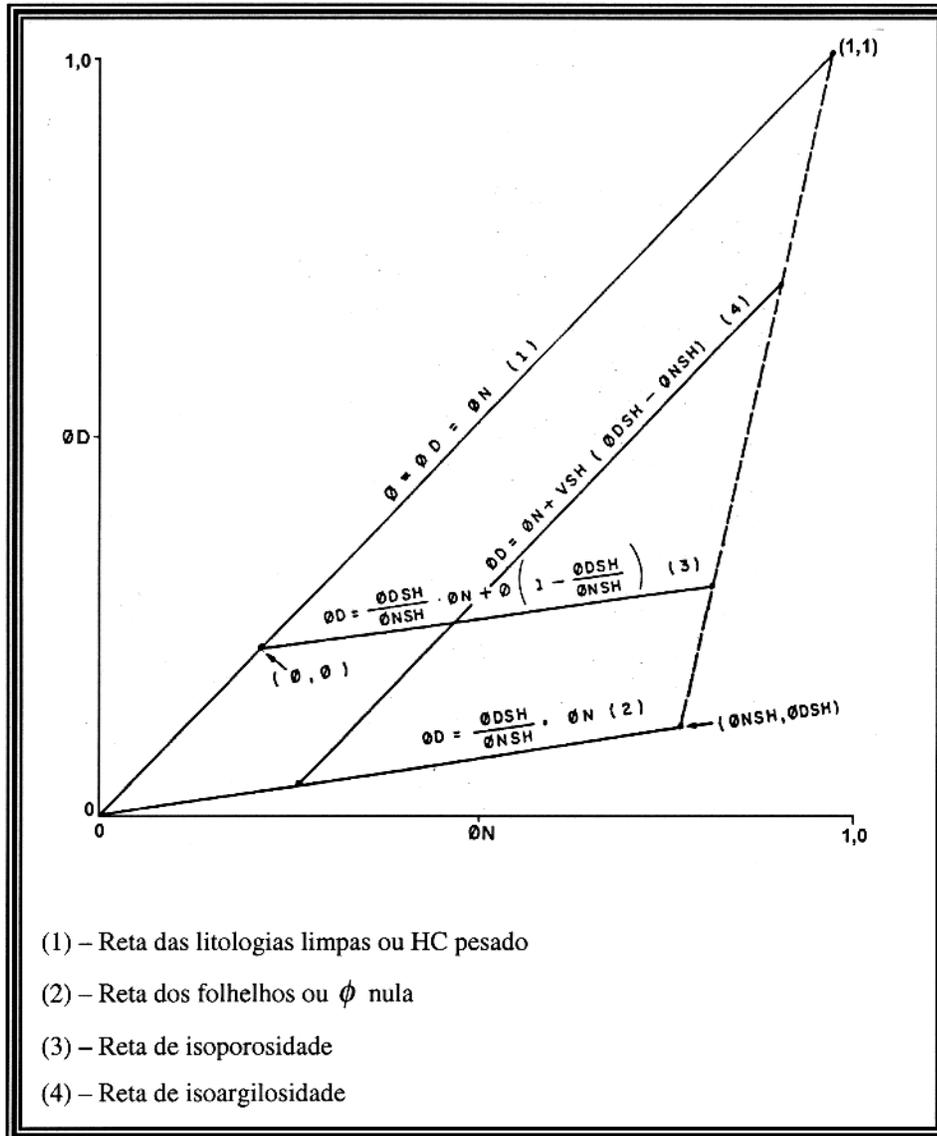
$$\phi_D = \frac{\phi_{Dsh}}{\phi_{Nsh}} \cdot \phi_N + \phi \left( 1 - \frac{\phi_{Dsh}}{\phi_{Nsh}} \right), \quad (2.10)$$

que é a reta de isoporosidade (3), de onde conclui-se que

$$\phi = \frac{\phi_D \cdot \phi_{Nsh} - \phi_N \cdot \phi_{Dsh}}{\phi_{Nsh} - \phi_{Dsh}} \quad (2.11)$$

Assim, um ponto qualquer de coordenadas  $\phi_D$  e  $\phi_N$ , lidas nos perfis e expressas em uma mesma litologia (para igual comparação), que caia abaixo da bissetriz, é um ponto que contém argilosidade passível de ser corrigida através da equação (2.10) e porosidade através da equação (2.11).

Um ponto que caia acima da bissetriz poderá ser visto, então, como um ponto contendo hidrocarboneto que se afastará cada vez mais da mesma, a depender da quantidade e densidade do hidrocarboneto. Isto não impede, todavia, que ele tenha sofrido os dois grandes efeitos, argilosidade e presença de gás.



**Figura 2.4** – Gráfico densidade-neutrônico para o modelo arenito folhelho.

### **3 - REDE NEURAL ARTIFICIAL**

#### **3.1- INTRODUÇÃO**

O cérebro humano é um computador paralelo, não linear e altamente complexo. Ele possui a capacidade de organizar suas células para executar certas tarefas como reconhecimento de padrão, coordenação motora, etc., várias vezes mais rápido que o mais veloz computador existente atualmente. Considere por exemplo a visão humana, que é um processo de tratamento de informação (MARR, 1982; LEVINE, 1985; CHURCHLAND & SEJNOWSKI, 1992). A representação do ambiente que nos cerca é gerado pelo sistema visual. Para obter informações ele necessita de uma interação com o meio. Para ser mais específico, o cérebro realiza tarefas de reconhecimento habitualmente (reconhecer um rosto familiar em uma cena totalmente estranha) na ordem de 100-200 ms, enquanto que, tarefas de menor complexidade levariam dias em um computador convencional moderno (CHURCHLAND, 1986).

As redes neurais artificiais (RNA) são sistemas computacionais baseados nos princípios do processamento mental humano, e têm como características fundamentais o aprendizado através de exemplos e a capacidade de generalização e adaptação. A RNA tem como objetivo fundamental a simulação do comportamento humano, por meios de algoritmos, na solução de problemas triviais para a mente humana, porém de grande complexidade para uma análise com computação seqüencial

A RNA é um processo distribuído de forma altamente paralela, que tem a propensão de armazenar conhecimentos experimentais e torná-los disponíveis para uso. Isto a torna parecida com o cérebro humano em dois aspectos:

- O conhecimento adquirido pela rede é através de processos de aprendizado
- As forças de conexões entre os neurônios, conhecidas como peso sináptico, são usadas para armazenar conhecimento

O método de rede neural é diretamente influenciado pelas modificações dos pesos sinápticos. Tal método é considerado o mais próximo da teoria linear do filtro adaptável, que já é aplicado com sucesso em diversos campos como comunicação, controle de radar, sonar, sismologia, engenharia biomédica, padrão de reconhecimento e memória associativa (WINDROW & STEARNS, 1985; HAYKIN, 1991). Porém, uma rede neural também pode modificar sua própria topologia, a qual é motivada pelo fato de que neurônios no cérebro humano podem morrer e novas conexões sinápticas podem ser geradas (HAYKIN, 1994).

O poder computacional da rede neural se deve, primeiramente, ao fato de sua estrutura ser distribuída de forma paralela e, segundo, pela sua habilidade de aprender e posteriormente generalizar. Essa generalização se refere à produção de sinais de saídas razoáveis, para sinais de entrada que não estão presentes durante o treinamento(aprendizado). Na prática, porém, rede neural não pode operar independentemente; é necessário uma integração dentro de um sistema de engenharia de aproximação consistente. Especificamente, um problema complexo de interesse pode ser decomposto em um número relativamente simples de tarefas, onde as redes neurais nomeiam um subconjunto de tarefas que emparelham suas capacidades inerentes.

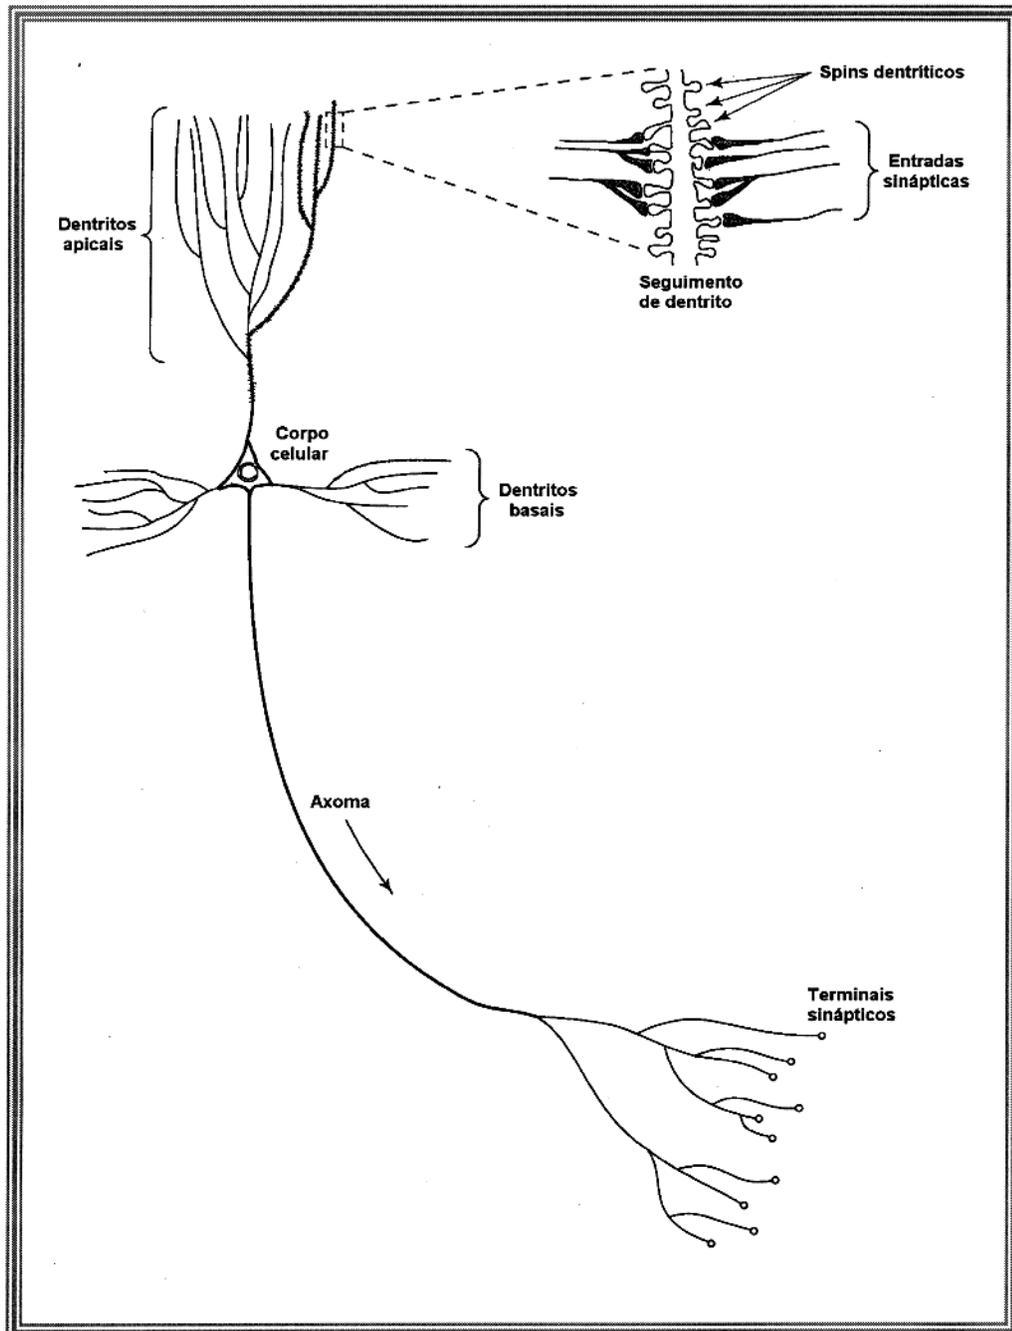
### 3.2 – NEURÔNIO BIOLÓGICO (HUMANO)

Os neurônios são unidades fundamentais e se apresentam em diversas formas e tamanhos nas diferentes partes do cérebro. A Figura 3.1 ilustra a célula piramidal, que é uma das mais comuns no córtex. O corpo celular de um neurônio contém o núcleo e o citoplasma, como as outras células, porém o que o diferencia é a presença de *axônio e dentritos*.

*Axônios*, são linhas de transmissão que conduzem impulsos para fora do corpo celular nervoso. *Dentritos* são zonas que recebem impulsos de axônios de outras células para o interior do corpo celular. Possuem várias ramificações que prolongam o corpo do neurônio.

As estruturas responsáveis pela conexão entre os neurônios são conhecidas como *sinapse*, e estão localizadas no contato das terminações nervosas de um ramo do dentrito de uma célula com as pontas do axônio de outra. Elas caracterizam, desta forma, uma zona receptora de impulsos (detalhe na Figura 3.1).

Um impulso, quando atinge uma sinapse, provoca produção de estímulo na célula nervosa próxima. Através do processo de adição de várias sinapses, produzem-se interconexões altamente flexíveis.



**Figura 3.1** – Célula nervosa do tipo piramidal, caracterizando os principais componentes do neurônio, e no detalhe as microcavidades das sinapses.

### 3.3 - MODELO DE NEURÔNIO ARTIFICIAL

O neurônio é a unidade processadora de informação fundamental na operação de RNA. McCULLOH & PITTS (1943) estabeleceram um modelo de neurônio artificial (Figura 3.2), onde se observa uma analogia ao modelo bioneurológico.

Um conjunto sináptico, formado por um grupo de valores (pesos) caracteriza a conexão entre dois neurônios quaisquer e opera basicamente da seguinte maneira: um sinal  $x_j$  da saída sináptica de um neurônio  $j$  é conectado ao neurônio  $k$  e processado pelo peso sináptico  $w_{kj}$ . Este conjunto corresponderia ao dendritos. Além disso, tem-se um elemento processador, para combinar linearmente as entradas de sinais e pesos sinápticos; uma função ativação, para limitar a amplitude de saída de um neurônio nos intervalos fechados  $[0,1]$  ou alternativamente  $[-1,1]$ . Este conjunto corresponderia ao núcleo celular. O correspondente ao axônio, seria o sinal de saída deste neurônio artificial.

Ao modelo de neurônio mostrado na Figura 3.2 também é aplicado uma entrada externa  $b_k$ , que tem a função de incrementar de forma positiva ou negativa a função ativação.

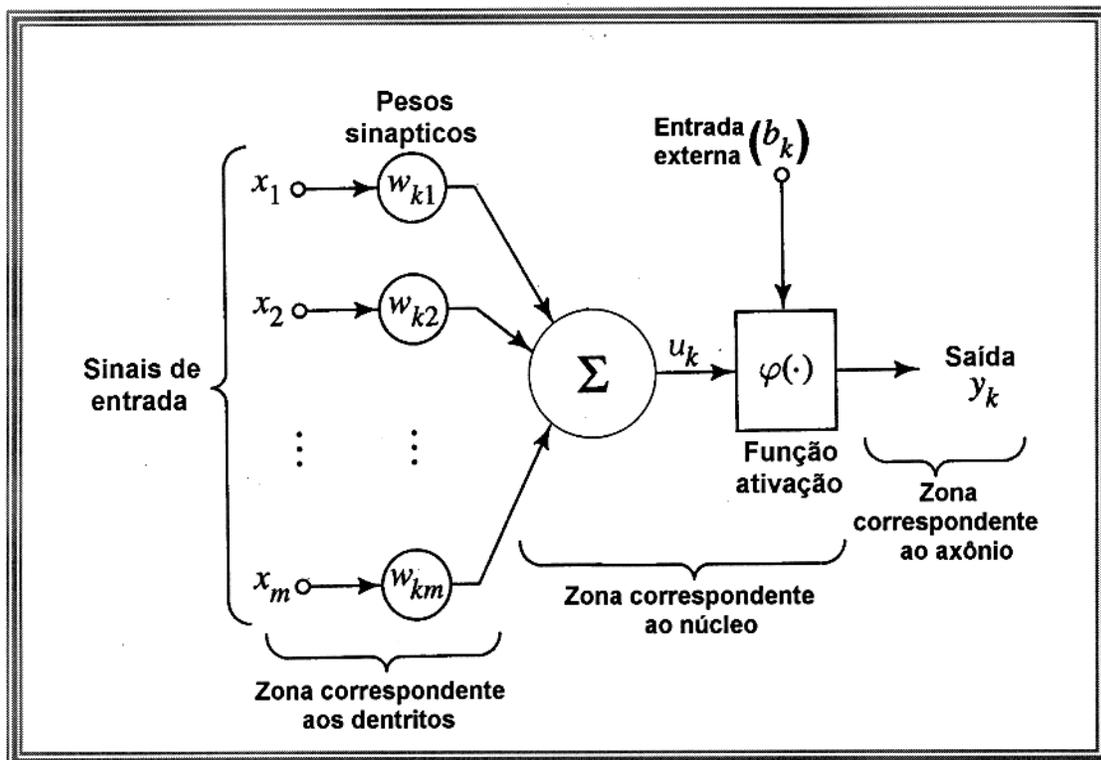


Figura 3.2 – Modelo de neurônio artificial, caracterizando seus principais componentes.

Em termos matemáticos, pode-se descrever o sinal de saída de um neurônio  $k$  com base nas seguintes de equações:

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

$$v_k = u_k - b_k, \quad (3.2)$$

e

$$y_k = \varphi(v_k) \quad (3.3)$$

onde  $x_1, x_2, \dots, x_p$  são sinais de entrada;  $w_{k1}, w_{k2}, \dots, w_{kp}$  são pesos sinápticos do neurônio  $k$ ;  $u_k$  é a combinação linear da entrada conhecida como potencial de entrada;  $b_k$  é a entrada externa;  $\varphi(\cdot)$  é função ativação e  $y_k$  é o sinal de saída do neurônio. O uso da entrada externa  $b_k$  tem o efeito de aplicar uma transformação afim para a saída  $y_k$ , no modelo de neurônio da Figura 3.2, mostrado pela expressão (3.2).

### 3.4 – REDE NEURAL ARTIFICIAL

HECHT-NIELSEN (1988) define RNA como “Uma estrutura de processamento de informação paralela e distribuída, que consiste de elementos de processamento (que podem possuir memória local e efetuar operações de processamento de informações locais) interconectados via canais unidirecionais chamados conexões. Cada elemento de processamento possui uma única saída que pode ser conectadas a tantas outras quanto se deseje (cada uma utilizando o mesmo sinal de saída). O sinal de saída do elemento de processamento deve ser completamente local; isto é, ele deve somente depender dos valores do sinal de entrada, no momento, e dos valores armazenados na memória local do elemento de processamento.”

A RNA opera basicamente com elementos processadores, chamados neurônios artificiais, que são interligados por conexões neuronais ou sinapses. Estas conexões caracterizam a distribuição paralela, e são diretamente responsáveis por uma das principais características da RNA, que é adaptar-se aos diversos tipos de problemas, de acordo com as variações sofridas por essas conexões.

Com base nesta analogia constante entre neurônio artificial e humano, pode-se dizer que o modelo de RNA é baseado em informações sobre o funcionamento do cérebro humano. Daí poder ser citados os seguintes aspectos para consubstanciar essa analogia:

- A obtenção de conhecimento é realizada por processos de aprendizagem.
- Os pesos sinápticos (conexão entre neurônios) são utilizados para o armazenamento deste aprendizado (memória).
- O neurônio possui vários caminhos de entrada e somente um caminho de saída.

A RNA possui uma série de neurônios (interligados por conexões especiais), que recebem estímulos e são processados e enviados a outros neurônios, gerando deste modo um sistema cíclico configurando o aprendizado.

A função básica do neurônio em uma RNA é efetuar uma combinação linear dos sinais de entrada, que posteriormente serão modificados por uma função ativação. Esses neurônios quando arranjados em grupos de forma ordenada, possuem o nome de camadas (Figura 3.3), que se classificam em:

*Camadas de entrada* – constituídas por neurônios que têm como função (exclusiva) receber os estímulos do meio e transmiti-los para o interior da rede.

*Camadas ocultas* – são todas as camadas encontradas entre as camadas de entrada e saída, e são formadas por elementos responsáveis por todo o processamento que ocorre no interior da rede.

*Camadas de saída* – são constituídas por elementos processadores, e que são responsáveis pelo retorno do sinal processado para o meio.

A forma pela qual os neurônios estão distribuídos, e como eles se conectam entre si e entre as camadas, recebe o nome de arquitetura ou topologia, podendo ser de formas diversas, dependendo do problema a ser resolvido. A arquitetura da RNA juntamente com os pesos sinápticos determinam a eficiência da rede em solucionar um problema particular.

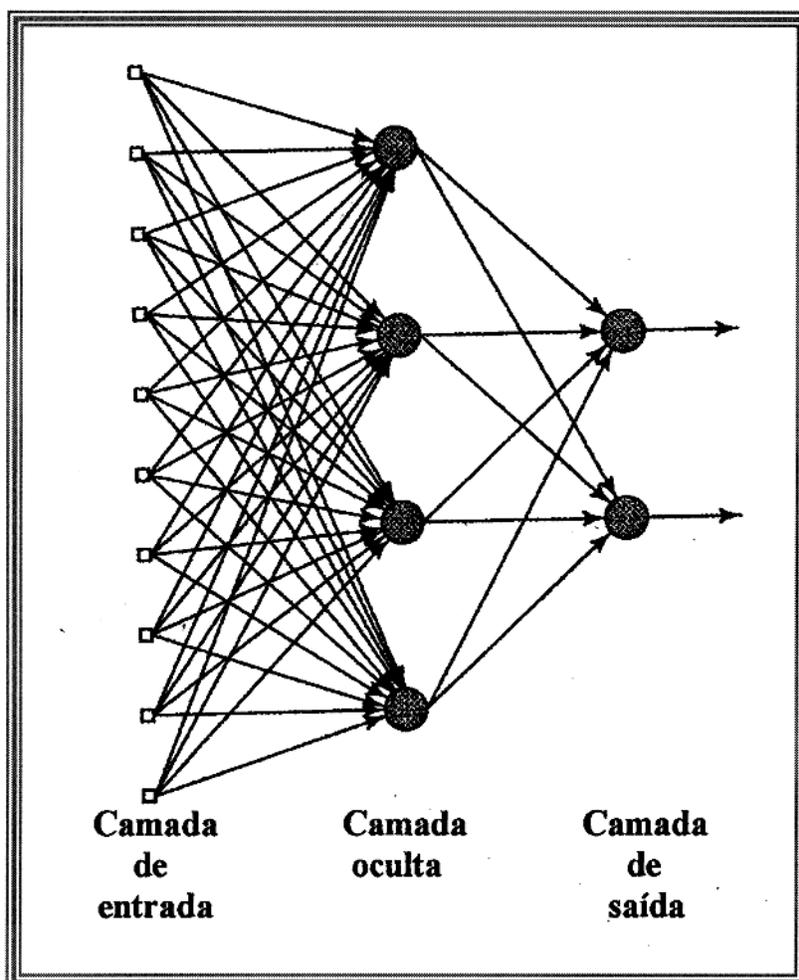


Figura 3.3- Disposições de camadas, configurando uma RNA.

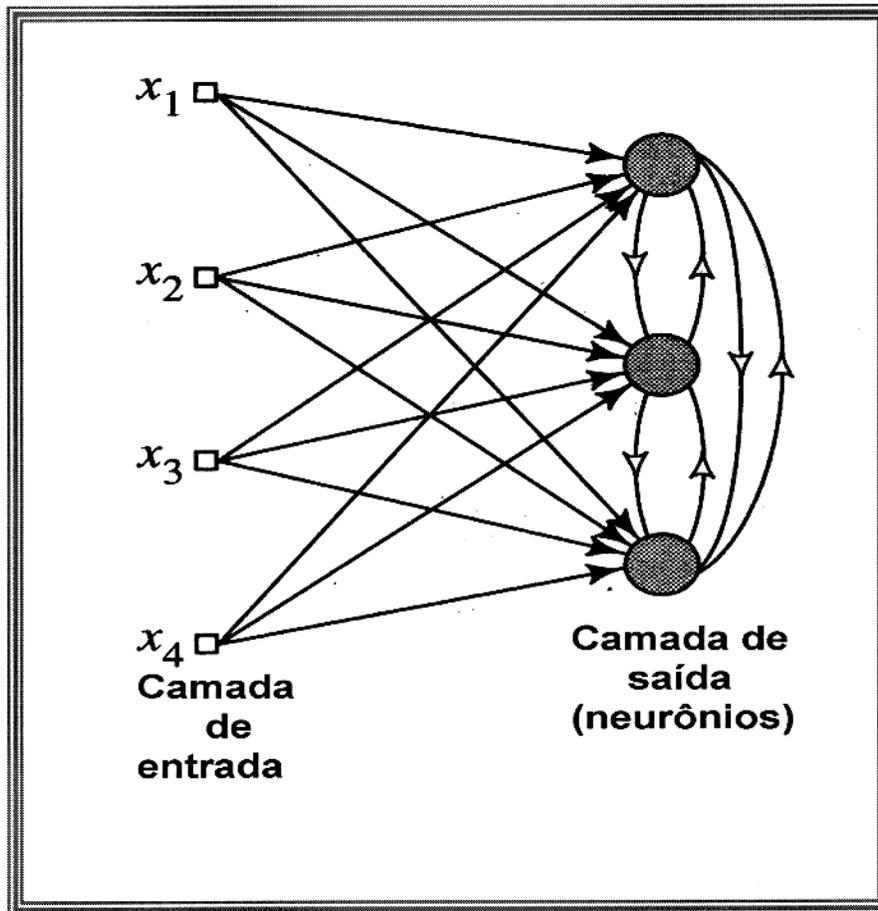
### 3.4.1 – Arquitetura de Rede Neural Artificial com Camada Competitiva

A arquitetura de rede neural com camada competitiva é formada fundamentalmente por duas camadas (Figura 3.4):

- 1 . Camada de entrada – possui elementos sensoriais, responsáveis pelo recebimento dos sinais de entrada da rede.
- 2 . Camada competitiva – esta camada, que caracteriza a rede, é composta por neurônios que são estimulados a competir entre si, de modo que apenas um neurônio permaneça ativo (neurônio vencedor).

A RNA de camada competitiva também é caracterizada pelas suas conexões, como pode ser observado na Figura 3.4. São elas:

- 1 . Conexão direta – é a conexão do sinal de entrada com a camada competitiva, gerando a primeira fonte de estímulos nos neurônios.
- 2 . Conexões laterais – são conexões entre os neurônios da camada competitiva (entrada externa). Estas conexões produzirão os efeitos excitatório ou inibitório, de acordo com a distribuição entre os neurônios na camada competitiva.



**Figura 3.4** – Modelo de rede neural com arquitetura de camada competitiva.

Para obter um sinal de saída de um neurônio  $j$ , pode-se utilizar a seguinte expressão:

$$y_k = \varphi \left( u_k + \sum_{j=-j}^j c_{jk} y_{k+j} \right), \quad k=1,2,3, \dots, N \quad (3.4)$$

onde,

$c_{j, -k}, \dots, c_{j, 0}, \dots, c_{j, k}$	-	-	pesos de conexão laterais,
$k$	-	-	número de neurônios envolvidos na competição ( $k \leq N$ )
$y_1, \dots, y_N$	-	-	sinais de saída da rede neural
$N$	-	-	número de neurônios na rede

Nesta equação,  $\varphi$  é uma função não linear de ativação, responsável pela quantificação do sinal de saída no intervalo  $[0,1]$ . O termo  $u_j$  é o potencial de entrada do neurônio  $j$ , na forma:

$$u_j = \sum_{l=1}^p w_{jl} x_l, \quad (3.5)$$

onde

$x_1, \dots, x_p$	-	-	sinais de entrada (estímulos aplicados na rede neural)
$w_{1j}, \dots, w_{jp}$	-	-	pesos sinápticos do neurônio $j$
$p$	-	-	número de terminais de entrada

A Figura 3.4 mostra a arquitetura de camada competitiva, onde se observa que os sinais de entrada são aplicados em paralelos aos neurônios. Este tipo de arquitetura possui dois tipos de conexões:

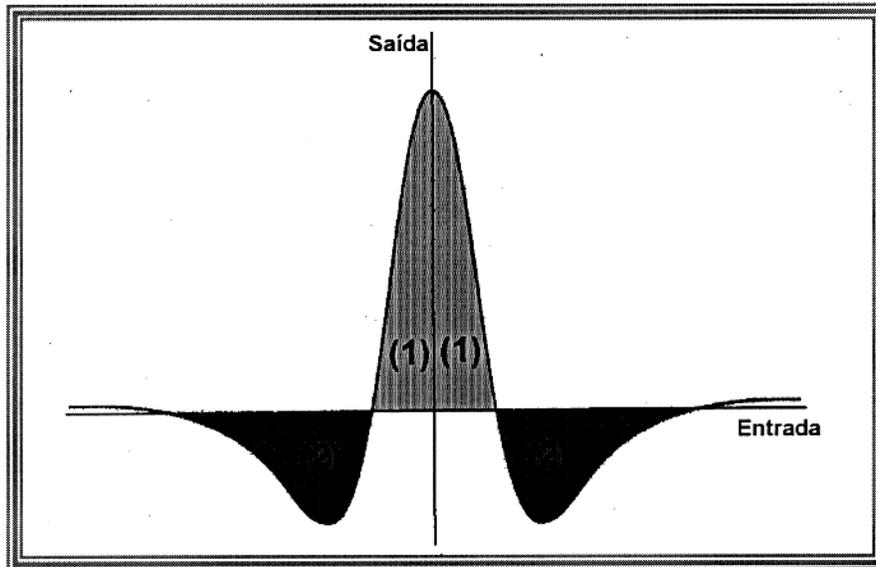
- Conexão direta – provém de fonte primária de excitação
- Conexão interna – também conhecida como conexão lateral, ocorre no interior da rede.

Estes dois tipos de conexões têm diferentes funções. O peso da soma dos sinais de entrada é designado para fornecer as características de detecção. Conseqüentemente, cada neurônio produz uma resposta seletiva, para um determinado grupo de sinais de entrada. As conexões laterais, por outro lado, produzem efeitos excitatórios ou inibitórios, dependendo da distância ao neurônio.

Seguindo a analogia com a bioneurologia, observa-se que a conexão lateral pode ser descrita como função chapéu mexicano, conforme Figura 3.5. De acordo com esta figura, nota-se duas áreas distintas de interação lateral entre os neurônios:

- (1) Área mais próxima ao eixo  $x$ , conhecida como excitatória
- (2) Área de ação inibitória ou penumbra

A RNA descrita aqui possui duas importantes características. Primeira, a rede tende a concentrar suas atividades elétricas em grupos, denominados de bolhas de ativação (KOHONEN, 1988). Segundo, a localização destas bolhas de ativação é determinada pela natureza dos sinais de entrada.



**Figura 3.5** – Áreas de interações laterais, representando uma função chapéu mexicano

A solução para a equação não linear (3.4) é encontrada iterativamente, usando a técnica de relaxação, de forma que a equação reformulada fique

$$y_k(n+1) = \varphi \left( U_k + \beta \sum_{j=-j}^j c_{jk} y_{j+k}(n) \right), \quad j=1,2,\dots,N \quad (3.6)$$

onde  $n$  indica tempo discretizado. Desta forma,  $y_j(n+1)$  representa o sinal de saída do neurônio  $j$  no tempo  $n + 1$ , e  $y_{j+k}(n)$  é o sinal de saída do neurônio  $j+k$  no tempo prévio  $n$ . O parâmetro  $\beta$  no argumento do lado direito da equação (3.6) controla o raio de convergência do processo de relaxação (HAYKIN, 1994).

### 3.4.1.1 –Aprendizado Competitivo

No aprendizado competitivo, como o próprio nome indica, os neurônios de saída de uma rede neural competem entre si para se tornar o único neurônio ativo (vencedor). Deste modo, considerando que em uma rede neural baseada no aprendizado de Hebbian, vários neurônios de saída podem ser ativados simultaneamente. No caso de aprendizado competitivo, somente um único neurônio de saída é ativado a um determinado tempo. Esta é a característica que torna o aprendizado competitivo altamente adaptável para descobrir características estatísticas a ser usadas na classificação de um grupo de padrões de entrada.

A idéia de aprendizado competitivo pode ser relacionada aos primeiros trabalhos de von der MALSBERG (1973) sobre auto-organização de orientação sensitiva de células nervosas no córtex estriado, FUKUSHIMA (1975) na auto-organização de rede neurais de múltiplas camadas, conhecido como: *cognitron*, WILLSHAW & von der MALSBERG (1976) na formação de conexões neurais padronizadas por auto – organização e GROSSBERG (1972, 1976a e 1976b) na classificação de padrão adaptável. Há também, há uma evidência substancial para o funcionamento do aprendizado competitivo como importante papel na formação de mapas topográficos no cérebro (DURBIN et al., 1989). Em um trabalho experimental recente realizado por AMBROS-INGERSON et al. (1990) são fornecidas justificativas neurobiológicas para aprendizado competitivo.

Há três elementos básicos para uma regra de aprendizado competitivo (RUMELHART & ZIPSER, 1985):

- Um conjunto de neurônios que é sempre o mesmo, exceto por alguns pesos sinápticos distribuídos fortuitamente, e que então responde diferentemente para um conjunto de neurônios dado.
- Um limite imposto na "força" para cada neurônio.
- Um mecanismo que permite que os neurônios compitam pela melhor resposta para um dado subconjunto de entradas, tal que somente um neurônio de saída, ou somente um neurônio por grupo, seja o ativo, a um determinado tempo. O neurônio que vence a competição é chamado *winner-takes-all*.

Consequentemente, o neurônio individual da rede aprende a se especializar em um conjunto de padrões, e assim se torna um detetor de características.

Na forma mais simples de aprendizado competitivo, a rede neural possui uma única camada de neurônios de saída, cada qual é totalmente conectado aos nodos de entradas. A rede pode também incluir conexões laterais ao longo dos neurônios, como indicado na Figura 3.4. Na arquitetura de rede descrita neste trabalho, a conexão lateral funciona como laterais inibitórias. O resto das conexões sinápticas na rede da Figura 3.4 são excitatórias.

Para o neurônio  $j$ , considerado como vencedor, sua atividade interna na rede de nível  $v_j$ , para um padrão de entrada especificado  $\mathbf{x}$ , deve ser o maior entre todos os neurônios da rede. O sinal de saída  $y_j$  do neurônio vencedor  $j$  é um conjunto igual a 1 (um); os sinais de saída de todos os neurônios que perdem a competição possuem um conjunto igual a 0 (zero).

Consideremos que  $w_j$  represente o peso sináptico conectando o nodo de entrada  $i$  ao neurônio  $j$ . Cada neurônio é dividido entre pesos sinápticos (todos os pesos sinápticos são positivos), os quais são distribuídos entre seus nodos de entrada que é

$$\sum_i w_{ji} = 1 \quad \text{para todo } j.$$

Um neurônio aprende por troca de pesos sinápticos, de seus nodos de entrada inativos para seus nodos ativos. Se um neurônio não responde a um padrão particular de entrada, nenhum aprendizado ocorre neste neurônio. Se um neurônio particular vence a competição, então, cada nodo de entrada do neurônio renuncia alguma proporção de seu peso sináptico, e o peso renunciado é então distribuído igualmente entre os nodos ativos de entrada. De acordo com a regra padrão de aprendizado competitivo, a variação  $\Delta w_{ji}$ , aplicada ao peso sináptico  $w_j$ , é definida por

$$\Delta w_{ji} = \eta(x_i - w_{ji}) \quad \text{se a variação } \Delta w_{ji} \text{ } j \text{ vencer a competição,}$$

$$\Delta w_{ji} = 0 \quad \text{se a variação } \Delta w_{ji} \text{ } j \text{ perder a competição,}$$

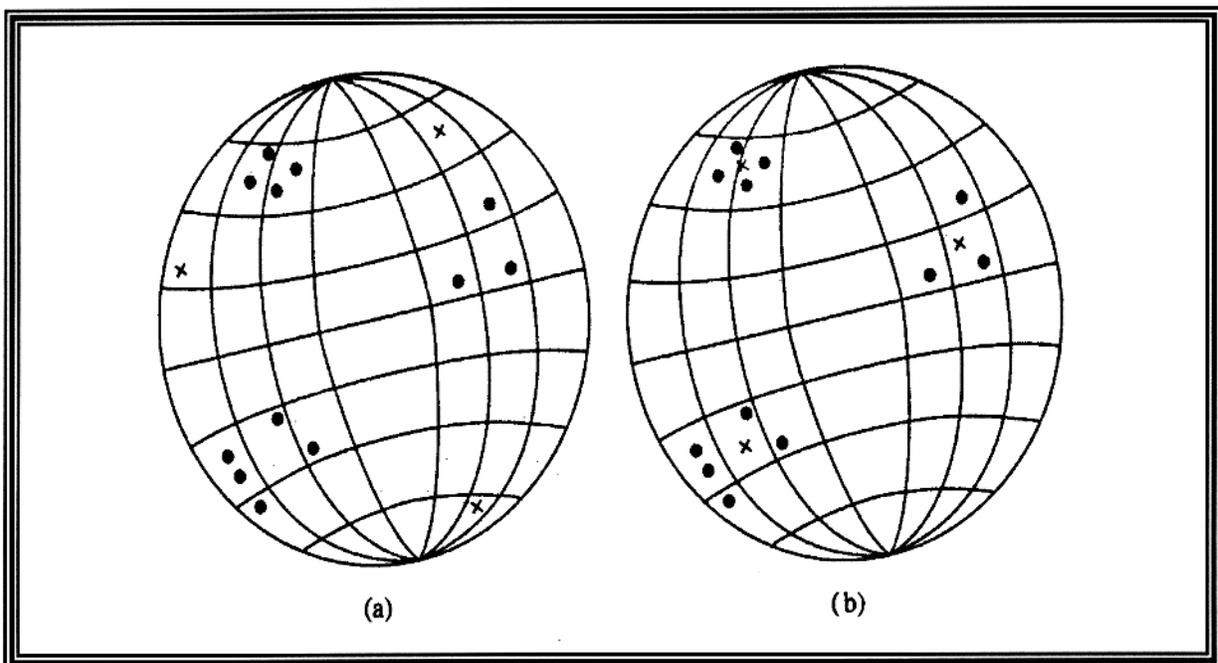
onde  $\eta$  é o parâmetro aprendizado/razão. Esta regra tem o efeito global de movimentar o vetor  $w_j$  do peso sináptico do neurônio vencedor  $j$  em direção do padrão de entrada  $\mathbf{x}$ .

Para ilustrar a essência do aprendizado competitivo, podemos usar uma analogia geométrica, descrita na Figura 3.6 (RUMELHART & ZIPSER, 1985). Nela é assumido que cada

padrão de entrada  $x$  tem uma duração constante, que deve ser visualizada como um ponto em uma unidade esférica  $n$ -dimensional, onde  $n$  é o número de nodos de entrada e também a dimensão de cada peso sináptico de vetor  $w_j$ . Posteriormente é assumido que todos os neurônios na rede são induzidos a ter o mesmo valor euclidiano (norma), dado por

$$\sum_j w_{ji}^2 = 1 \text{ para todo } j,$$

Deste modo, quando o peso sináptico é corretamente escalonado, forma-se um conjunto de vetores que caem na mesma unidade de esfera  $n$ -dimensional. Na Figura 3.6a são mostrados três agrupamentos (*cluster*) de padrões de estímulos, representados pelos pontos. Esta figura também inclui um possível estado inicial de rede (representada pelas cruzes) que deve existir antes do aprendizado. A Figura 3.6b mostra um estado final típico da rede que resulta do uso do aprendizado competitivo. Em particular, cada neurônio de saída descobre um agrupamento de entrada, por movimentações no vetor do peso sináptico, para o centro de gravidade do agrupamento descoberto. (RUMELHART & ZIPSER, 1985; HERTZ et al., 1991).



**Figura 3.6** - Interpretação geométrica do processo de aprendizado. Os pontos ( • ) representam os vetores de entrada, e as cruzes ( + ) os vetores peso sinápticos dos três neurônios de saída. (a) Estado inicial da rede. (b) Estado final da rede.

## **4 – METODOLOGIA**

O zoneamento, ou seja, a separação em profundidade das rochas reservatório das rochas selantes, bem como o cálculo da porosidade efetiva, serão realizados a partir do desenvolvimento de uma arquitetura de rede neural artificial com camada competitiva que busca simular o comportamento do sistema visual do intérprete de perfis, quando da utilização do gráfico densidade-neutrônico, para o modelo arenito-folhelho.

O gráfico densidade-neutrônico foi especificamente concebido para a determinação gráfica da porosidade em litologias limpas, sem no entanto, considerar a posição em profundidade de cada ponto lançado no gráfico, o que é de fundamental importância para a obtenção do zoneamento do perfil. No entanto, e especificamente para o modelo arenito-folhelho, ocorre uma distribuição particular dos pontos representativos do arenito em relação aos pontos característicos do folhelho, que possibilita o zoneamento ou a classificação destes pontos nas duas litologias.

A situação de simples classificação dos pontos lançados no gráfico densidade-neutrônico é verdadeira apenas para o caso de arenitos limpos, ou sem argilosidade. Para a grande maioria das situações reais, os arenitos sempre apresentam alguma argilosidade ou argila nos seus espaços porosos. A argilosidade dos arenitos torna a classificação ou o zoneamento muito mais complexos e interfere diretamente no cálculo da porosidade, a qual deve ser corrigida para a obtenção da porosidade efetiva.

Neste capítulo explora-se o desenvolvimento da arquitetura e o treinamento não supervisionado da rede neural com camada competitiva e sua aplicação ao zoneamento de perfis e determinação da porosidade efetiva.

### **4.1 – ARQUITETURA DA REDE NEURAL**

Os conceitos fundamentais envolvidos no projeto de uma arquitetura para a rede neural artificial com camada competitiva foram apresentados na seção 3.4.1.

Para a aplicação desses conceitos a um problema real da interpretação de dados geofísicos de poço é necessário a discussão de três tópicos:

- 1- Dados de entrada.
- 2- Camada competitiva.
- 3- Regra de treinamento.

#### **4.1.1 – Dados de Entrada**

Para o projeto de uma arquitetura de rede neural artificial com treinamento não supervisionado, como é o caso da rede neural com camada competitiva, é de fundamental importância o perfeito conhecimento das características dos dados a serem processados, pois serão estas características, as únicas responsáveis pela qualidade do treinamento e consequentemente, do produto final ou processamento da rede. Da feita que o único objetivo do treinamento não supervisionado é o de extrair estas características da distribuição dos dados de entrada no plano ou no espaço.

Por outro lado o número de tipos diferentes de dados de entrada define diretamente o número de unidades sensoriais, os neurônios da camada de entrada e, consequentemente, a dimensão do espaço de onde serão extraídas as características da distribuição de pontos, de modo que cada tipo de dado será representado por um eixo neste espaço.

Para o caso da interpretação de dados geofísicos de poço não é de interesse apenas o conhecimento das características da distribuição dos dados de perfil, mas sim sua relação com alguma propriedade petrofísica ou geológica. Este relacionamento é fornecido pelas cartas ou gráficos interpretativos, neste caso o gráfico densidade-neutrônico, o qual define também a dimensão do espaço de classificação, na forma de um plano. Deste modo, torna-se então necessário a determinação de duas unidades sensoriais para a formação da camada de entrada da RNA, uma unidade sensorial será responsável pela entrada do perfil de densidade, que definirá o eixo das ordenadas e a outra se responsabilizará pela entrada do perfil neutrônico, que definirá o eixo das abscissas.

As regiões demarcadas na carta definem, por sua vez, o relacionamento entre a distribuição dos dados de perfil no plano com a litologia e a porosidade, segundo o modelo arenito-folhelho.

#### **4.1.2 – Camada Competitiva**

O projeto da camada competitiva trata, fundamentalmente, da definição do número de neurônios processadores que a compõe. Uma vez que adotou-se a mais simples arquitetura para a rede neural artificial, com uma única camada competitiva.

Para a sua aplicação na interpretação de dados de perfil é de fundamental importância a definição explícita do significado geológico-geofísico do sinal de saída de cada neurônio da camada competitiva, que a cada iteração seja o vencedor da competição interneurônios.

Para o zoneamento e determinação da porosidade, a determinação do significado geofísico da saída do neurônio vencedor é obtido diretamente do gráfico densidade-neutrônico, a partir da associação do sinal de saída do neurônio vencedor a um único valor de porosidade, definido segundo a escala de porosidades adotada sobre a reta característica dos arenitos limpos. Deste modo, como cada neurônio estará associado a um específico valor de porosidade, o número de pontos (valores de porosidade) da reta dos arenitos limpos define o número de neurônios da camada competitiva.

Adotando-se uma precisão para o cálculo da porosidade igual a 0,01 (1%) e um intervalo de porosidades esperada de 0 (zero) a 40 (quarenta), em porcentagem, para o escalonamento da reta dos arenitos limpos, ter-se-á então uma camada competitiva constituída por 41 (quarenta e um) neurônios.

#### 4.1.3 - Regra de Treinamento

A regra de treinamento define a estratégia de adaptação dos pesos sinápticos entre a camada de entrada e a camada competitiva. Com o objetivo de explicar o fenômeno do aprendizado humano, GROSSBERG (1982) desenvolveu dois tipos de neurônios competitivos, denominados *instar* e *outstar*.

O neurônio *instar*, como mostrado na Figura 4.1, pode ser treinado para reconhecer um vetor, e o neurônio *outstar* pode ser treinado para produzir um vetor (GROSSBERG, 1982).

Considere o neurônio *instar*. O seu treinamento se processa por uma alteração da regra de HEBB (1949) através de uma mudança na variação contínua dos pesos sinápticos.

A regra de treinamento de um neurônio competitivo *instar* estabelece que a razão de decaimento dos pesos sinápticos é igual a razão de aprendizado dos neurônios. Assim, o decaimento somente ocorre quando o neurônio está ativado, segundo a expressão

$$\Delta w(i, j) = \eta \cdot y(i) \cdot x(j) - (\eta \cdot y(i) \cdot w(i, j)). \quad (4.1)$$

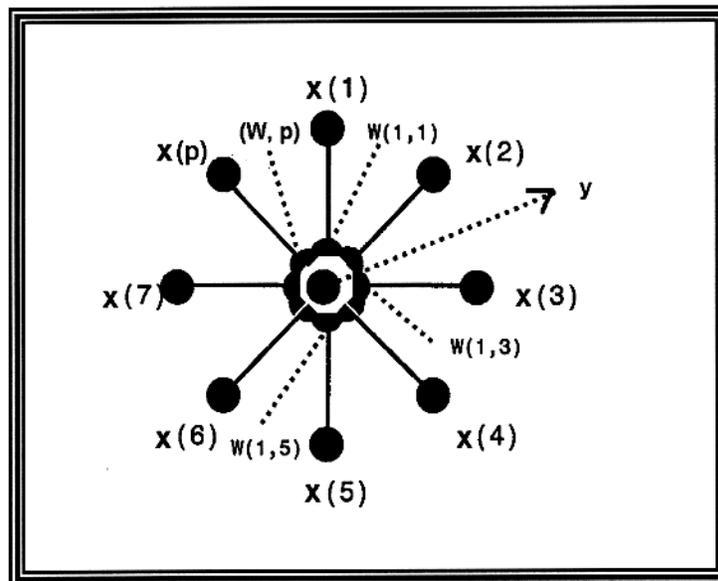
Na expressão 4.1,  $\Delta w(i,j)$  é a variação do peso sináptico ( $w(i,j)$ ), entre o neurônio  $j$  da camada de entrada e o neurônio  $i$  da camada competitiva;  $\eta$  é a razão de treinamento,  $y(i)$  é o sinal de saída do neurônio  $i$  e  $x(j)$  é o sinal de saída do neurônio  $j$ , ou sinal de entrada no neurônio  $i$ .

Assim, o valor da alteração do peso sináptico permanece inalterado até que o neurônio a ele associado se torne ativo. Isto significa que um neurônio não esquecerá algo que tenha aprendido, a menos que ele aprenda algo mais novo.

Rescrevendo a regra de aprendizado de um neurônio *instar*, é possível examinar suas propriedades

$$\Delta w(i, j) = \eta \cdot y(i) \cdot (x(j) - w(i, j)). \quad (4.2)$$

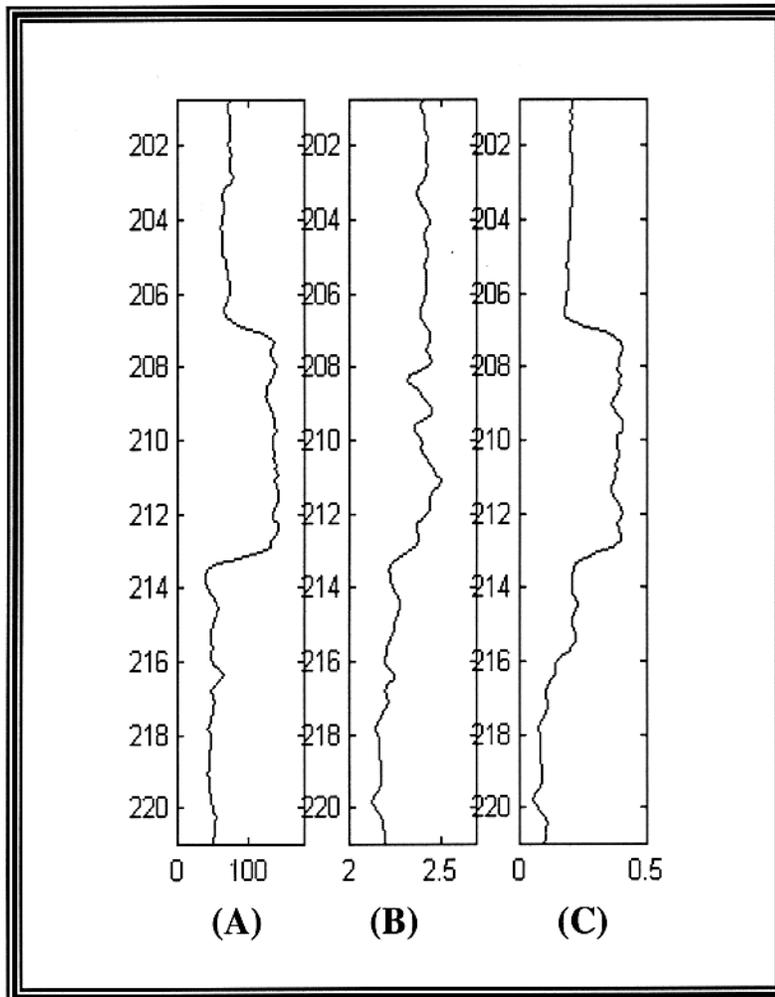
A expressão 4.2 torna claro o sistema de aprendizado do neurônio *instar* e o que ele aprende. Ocorre a variação do peso sináptico, apenas enquanto seus neurônios estão ativos ou  $y(i) > 0$ . O aprendizado continua até que cada neurônio se torne inativo, ou o valor do peso sináptico se torne igual ao sinal de entrada,  $x(j) = w(i, j)$ .



**Figura 4.1** – Neurônio Competitivo do tipo *Instar*.

#### 4.2 – APLICAÇÃO AO ZONEAMENTO DE PERFIS E AO CÁLCULO DA POROSIDADE EFETIVA

A aplicação prática da rede neural artificial com camada competitiva e treinamento não supervisionado pela regra do neurônio *instar* (GROSSBERG, 1982) é apresentada através da utilização de um trecho modelo de um perfil real, como mostrado na Figura 4.2, onde na primeira coluna aparece o perfil de raios gama natural para a simples visualização de uma camada de folhelho, ao centro, ladeada por duas camadas de arenito. Na segunda coluna é mostrado o perfil de densidade e na terceira o perfil de porosidade neutrônica, que serão tomados como dados de entrada para a rede neural.



**Figura 4.2** – Perfis Geofísicos, (A) Raio Gama; (B) Densidade e (C) Porosidade Neutrônica.

#### 4.2.1 – Zoneamento do Perfil

A Figura 4.3 mostra o gráfico densidade-neutrônico adotado para o zoneamento e cálculo da porosidade efetiva. Os pontos marcados por cruces (+) representam os pontos correspondentes ao trecho de perfil mostrados na Figura 4.2. A Figura 4.3 mostra também uma representação gráfica da rede neural artificial com camada competitiva, através dos pesos sinápticos correspondentes aos neurônios da camada competitiva, representados pelo símbolo (x), coincidentes com os pontos representativos da reta dos arenitos limpos. Cada ponto, equivalente a uma porosidade de 1,0%, numa escala de 0 a 40%, representa um neurônio da camada competitiva, que fica então composta por 41 neurônios.

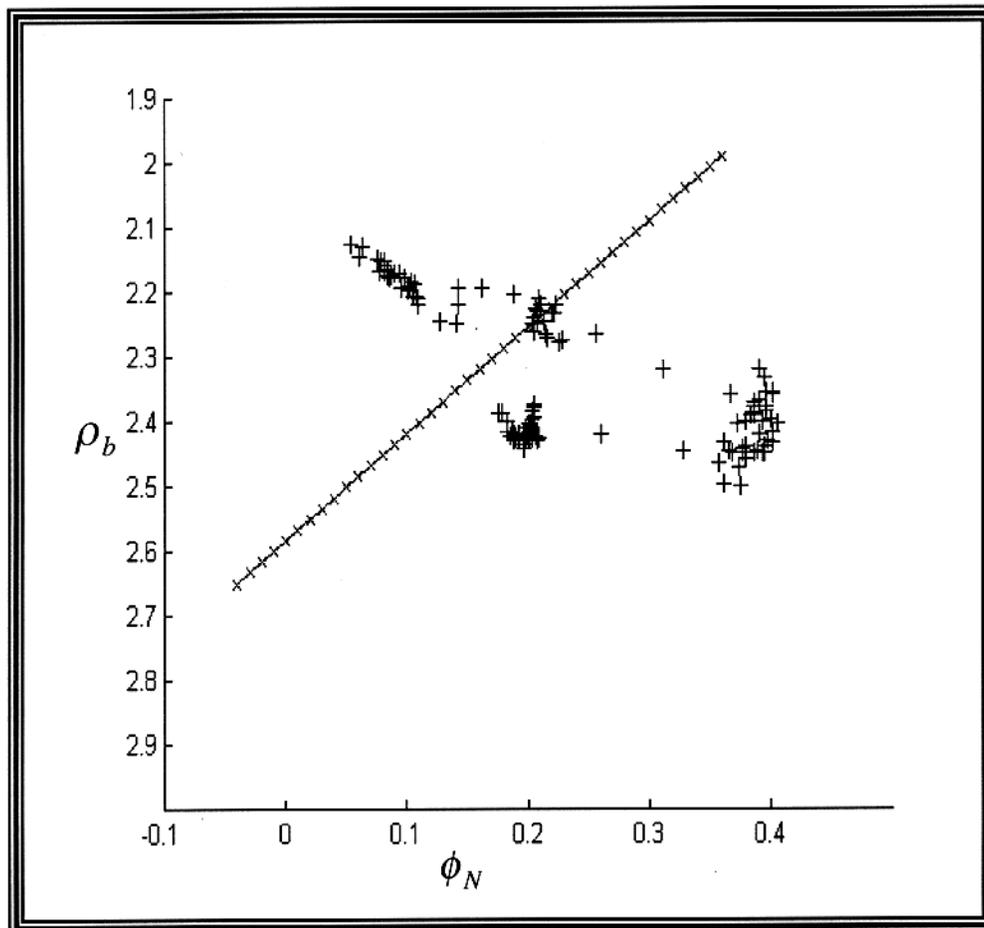
Inicia-se o treinamento não supervisionado da rede, permitindo-se a variação dos valores dos pesos sinápticos, a partir dos valores iniciais coincidentes com os valores da reta dos arenitos limpos. Neste treinamento, somente é permitido iguais deslocamentos dos pesos sinápticos, em cada eixo e proporcionais aos valores iniciais, ao longo dos eixos do gráfico densidade-neutrônico. Deste modo, o treinamento funciona como um deslocamento de toda a reta para a direita ou para a esquerda, a partir da posição original da reta dos arenitos. Fixando-se os valores dos pesos nas posições de maior concentração de pontos. São permitidos apenas três deslocamentos, um à esquerda e dois à direita da posição original da reta dos arenitos limpos.

A partir do modelo interpretativo, que é o arenito-folhelho para o gráfico densidade-neutrônico, se estabelece as regras de zoneamento do perfil:

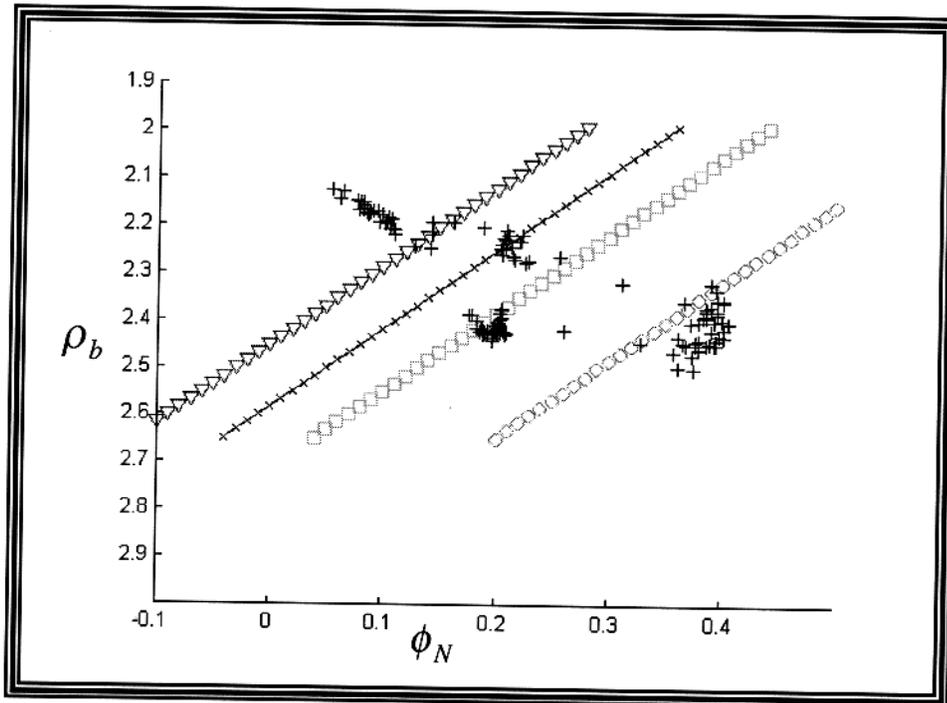
- 1- A reta mais a direita é representativa dos pesos sinápticos associados aos folhelhos.
- 2- A reta na posição intermediária entre a posição original e a reta dos folhelhos é representativa dos arenitos sujos.
- 3- A reta mais a esquerda é representativa dos arenitos contendo hidrocarboneto.

O instante final do treinamento da rede neural sobre os dados de perfil representados por cruces na Figura 4.4, mostra também as posições finais dos pesos sinápticos, na forma de três retas paralelas à reta dos arenitos limpos. Na Figura 4.4, está representado pelo símbolo (x) a reta dos arenitos limpos; por triângulos, a reta dos arenitos contendo hidrocarboneto. A reta dos arenitos sujos é representada por quadrados e a reta dos folhelhos aparece representada por círculos.

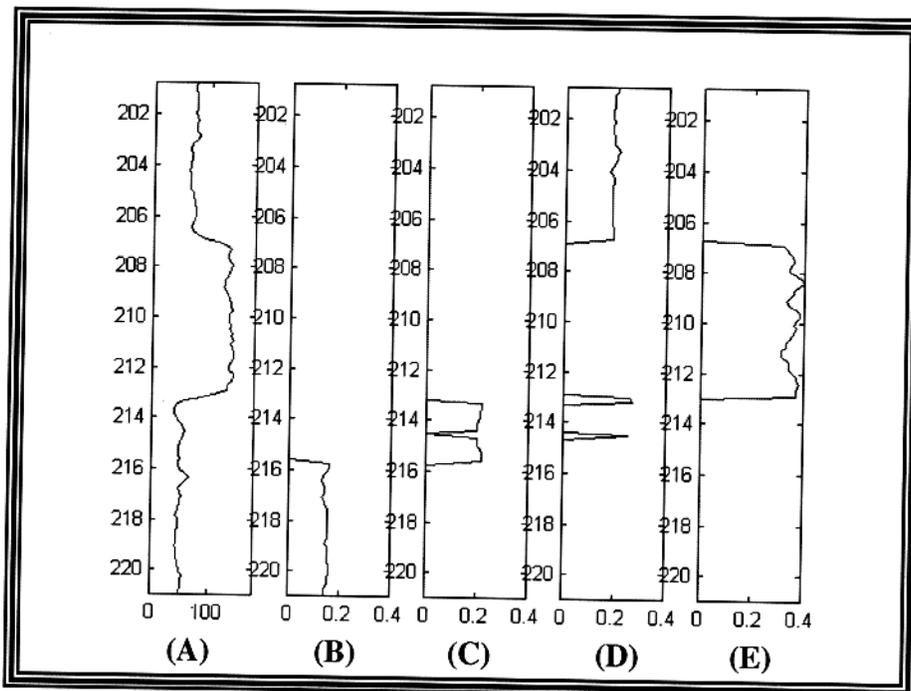
Estas retas e os pesos sinápticos associados a elas formaram as quatro redes neurais com camada competitiva adotadas para o zoneamento do perfil ou a classificação dos pontos de perfil distribuídos no plano do gráfico densidade-neutrônico, como mostrado na Figura 4.5. Na primeira coluna aparece o perfil de raios gama; na segunda, o perfil de porosidade aparente dos arenitos com hidrocarboneto; na terceira, o perfil de porosidade total dos arenitos limpos; na quarta, o perfil de porosidade aparente dos arenitos sujos e na quinta, as porosidades aparentes do folhelho. Observa-se, a partir de comparação direta, um bom acordo entre a zoneamento do perfil, expresso em termos de porosidade e a curva de raios gama natural.



**Figura 4.3** – Gráfico Densidade – Neutrônico; onde as cruzes (+) representam os pontos correspondentes ao trecho de perfil da figura 4.2 e o símbolo (x) representa os pesos sinápticos.



**Figura 4.4** – Gráfico Densidade – Neutrônico, (+) representando o instante final do treinamento da RNA; (x) reta dos arenitos limpos, ( $\Delta$ ) reta dos arenitos com hidrocarbonetos, ( $\square$ ) reta dos arenitos sujos e (O) reta dos folhelhos.



**Figura 4.5** – Resultado do zoneamento em escala de porosidade – (A) Raio Gama, (B) Porosidade aparente dos arenitos com hidrocarbonetos, (C) Porosidade total dos arenitos limpos, (D) Perfil de porosidade aparente dos arenitos sujos e (E) Porosidade aparente dos folhelhos.

#### 4.2.2 – Cálculo da Porosidade Efetiva

Todas as curvas da Figura 4.5, derivadas do processamento da rede neural com camada competitiva, são apresentadas em uma escala de porosidade total obtida a partir do gráfico densidade-neutrônico. No entanto, o valor de porosidade de interesse para a geofísica de poço é o valor de porosidade efetiva, obtido a partir da correção do valor da porosidade total pelo efeito da argilosidade.

A argilosidade ou o volume de argila ( $V_{SH}$ ) é obtido a partir do perfil de raios gama natural, segundo a expressão

$$V_{SH} = \frac{GR_{Log} - GR_{MIN}}{GR_{MAX} - GR_{MIN}} \quad (4.3)$$

Na expressão 4.3,  $GR_{Log}$  é o valor de raios gama natural lido no perfil;  $GR_{MAX}$  é o valor representativo da radiação gama natural nos folhelhos e  $GR_{MIN}$  é o valor representativo da radiação gama natural nos arenitos limpos.

A correção pelo efeito da argilosidade sobre a porosidade obtida a partir do perfil de densidade é fornecida pela expressão

$$\phi_{DC} = \phi_D - V_{SH}\phi_{DSH} \quad (4.4)$$

Na expressão 4.4,  $\phi_{DC}$  representa a porosidade obtida a partir do perfil de densidade corrigida pelo efeito da argilosidade;  $\phi_D$  indica a porosidade calculada do perfil de densidade e o parâmetro  $\phi_{DSH}$  indica o valor de porosidade obtido do perfil de densidade, representativo dos folhelhos.

A correção da argilosidade aplicada ao perfil de porosidade neutrônica assume a forma

$$\phi_{NC} = \phi_N - V_{SH}\phi_{NSH} \quad (4.5)$$

Na expressão 4.5,  $\phi_{NC}$  representa a porosidade obtida a partir do perfil neutrônico corrigida pelo efeito da argilosidade;  $\phi_N$  indica a porosidade lida do perfil neutrônico e o parâmetro  $\phi_{NSH}$  indica a o valor de porosidade no perfil neutrônico, representativo do folhelho.

A aplicação direta das expressões 4.4 e 4.5 necessita do estabelecimento dos parâmetros  $\phi_{DSH}$  e  $\phi_{NSH}$ . Da observação do gráfico densidade-neutrônico, esses parâmetros resultam no chamado ponto do folhelho.

Para a determinação do ponto do folhelho, projetou-se uma nova arquitetura de rede neural com camada competitiva, contendo um único neurônio na camada competitiva e apresentando duas unidades sensoriais em sua camada de entrada.

Os dados de entrada da rede são formados unicamente pelos pontos do gráfico densidade-neutrônico, selecionados anteriormente como pontos representativos do folhelho.

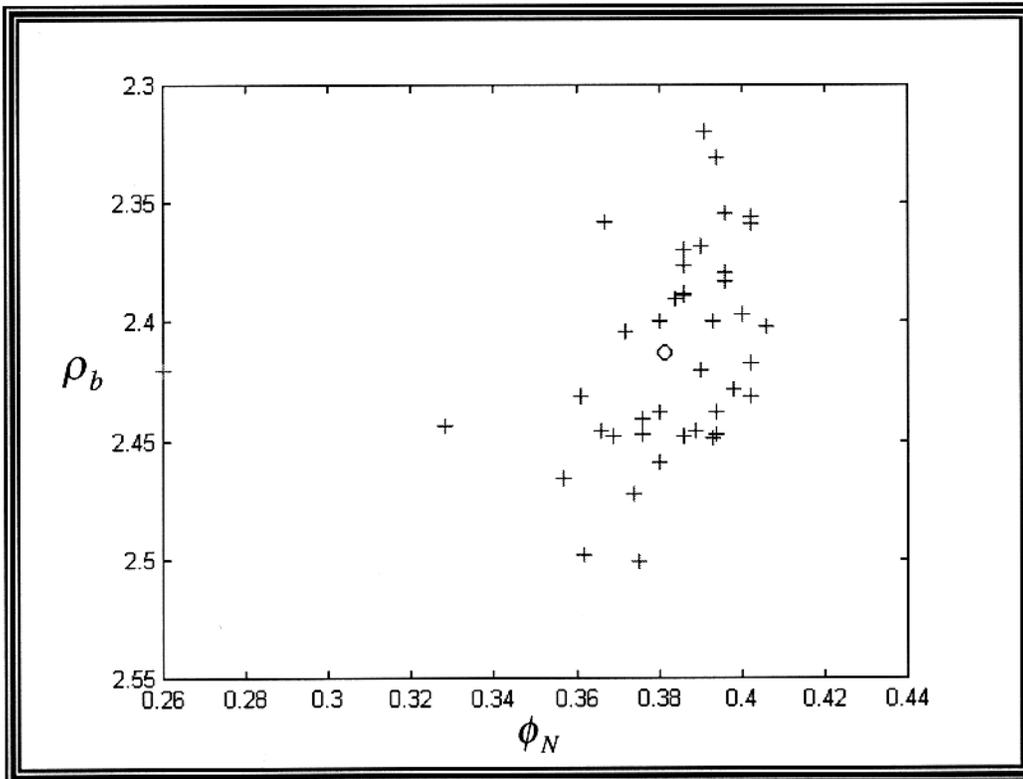
O treinamento de um único neurônio competitivo do tipo *instar*, leva à determinação de um par de pesos sinápticos que marcam um ponto localizado no centro de massa da população de pontos que compõe o conjunto de teinamento (GROSSBERG, 1982). Deste modo, estes valores de pesos sinápticos são adotados como as coordenadas do ponto do folhelho no gráfico densidade-neutrônico, como visto na Figura 4.6, que mostra o instante final do treinamento, após 100 ciclos. Na Figura 4.6, os pontos classificados como folhelho aparecem representados por cruces e o ponto do folhelho aparece representado por um círculo.

A partir do conhecimento das coordenadas do ponto do folhelho, procede-se à correção dos perfis do efeito da argilosidade através das expressões 4.4 e 4.5.

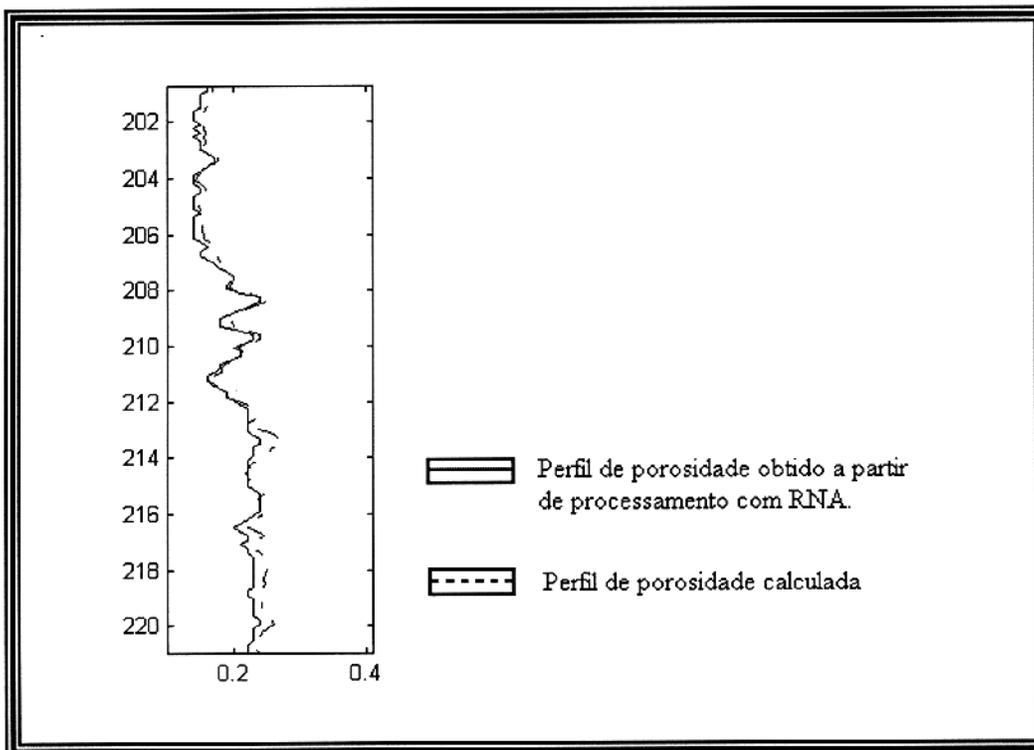
Uma vez que o efeito da argilosidade foi retirado de todos os pontos anteriormente classificados como arenitos. Tem-se a situação da presença teórica de apenas arenitos limpos, uma vez que não foi aplicada nenhuma correção para o efeito do hidrocarboneto sobre o perfil de densidade e o perfil neutrônico.

A obtenção da porosidade efetiva é realizada por uma nova rede neural com camada competitiva, em tudo semelhante à rede utilizada para o zoneamento dos arenitos limpos, considerando agora todos os pontos dos perfis.

A Figura 4.7 apresenta uma comparação entre a porosidade, obtida através do processamento com as redes neurais com camada competitiva (linha cheia), e a porosidade obtida pelos métodos tradicionais de cálculo (linha tracejada). A proximidade das duas curvas é evidente.



**Figura 4.6** – Gráfico Densidade – Neutrônica, onde as cruzes (+) representam os pontos classificados como folhelhos, e o círculo (O) representa o ponto do folhelho.

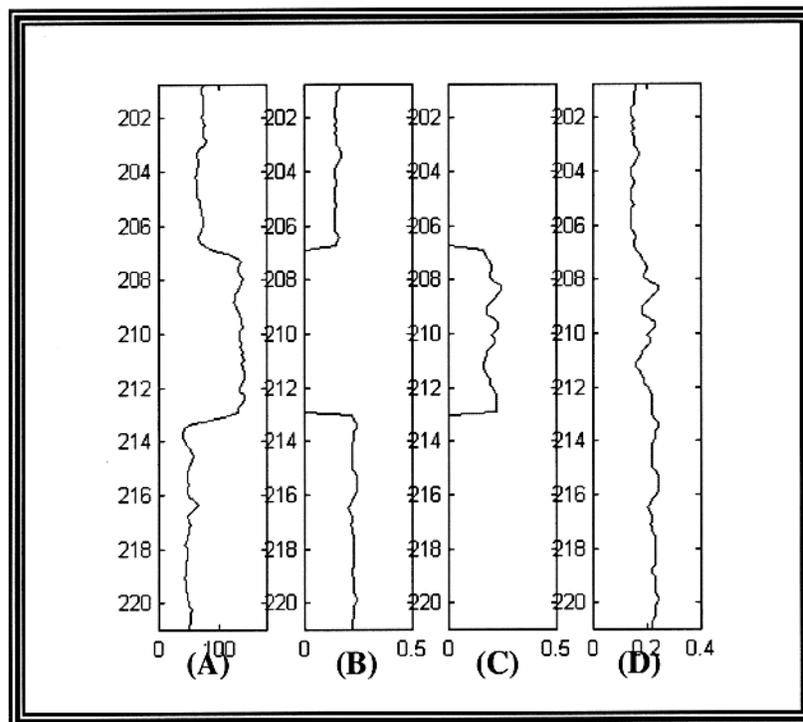


**Figura 4.7** – Comparação entre os dois cálculos de porosidades.

### 4.2.3 – Apresentação Final dos Resultados

Da constatação direta, em todos os testes realizados para o estabelecimento desta metodologia, verificou-se uma alta sensibilidade do zoneamento dos perfis em quatro classes aos ruídos presentes nos perfis de porosidade neutrônica e principalmente nos perfis de densidade. Apesar do interesse do geofísico de poço, principalmente pelo zoneamento com uma pré-indicação da presença de hidrocarbonetos, a sensibilidade ao ruído verificada no processamento da rede, até o momento, inviabiliza esta possibilidade. Em função disto optou-se pelo zoneamento tradicional, em termos das unidades litológicas.

A Figura 4.8 apresenta a forma adotada para a apresentação dos resultados, mostrando na primeira coluna o perfil de raios gama, para a simples visualização da coerência do zoneamento, o qual é mostrado na segunda coluna em termos da porosidade efetiva dos arenitos e na terceira coluna, em termos da porosidade aparente dos folhelhos. Na quarta coluna é vista a curva de porosidade obtida pelo processamento com a rede neural artificial com camada competitiva.



**Figura 4.8** – Apresentação dos resultados, (A) Raio Gama, (B) Porosidade efetiva dos arenitos, (C) Porosidade aparente dos folhelhos e (D) Perfil de porosidade.

## 5 – RESULTADOS

Os dados de campo utilizados para a avaliação da aplicabilidade e das limitações da metodologia apresentada nesta dissertação, para a obtenção do perfil de porosidade zoneada, são oriundos da bacia do Lago Maracaibo, localizada na região noroeste da Venezuela e são representativos do membro Lagunillas, o qual se caracteriza pela presença predominante de arenitos limpos e sujos, com indícios da presença de hidrocarboneto, intercalados por camadas descontínuas de folhelhos (BRYANT, 1989).

O membro Lagunillas representa, geologicamente, um ciclo transgressivo, limitado por duas camadas espessas de folhelhos. Sua porção inferior (primeira porção) é caracterizada pela presença de arenito sujo, com granulometria grossa, bem selecionada e presença de hidrocarboneto (óleo e gás). Esta camada representa o início do ciclo transgressivo onde os sedimentos depositados eram de ambiente costeiro. Posteriormente, observa-se a presença de uma camada de folhelho, com pouca continuidade lateral, que precede uma camada de arenito caracterizada por uma alta permeabilidade. A camada superior é arenítica com granulometria grosseira e com a presença, isolada de folhelhos, sendo representativo de um ambiente lagunar deltáico. Posteriormente se observa uma camada bastante representativa de folhelho, que está presente em todos os perfis analisados. Esta camada divide o reservatório em duas porções. A segunda porção (porção superior) inicia-se com um arenito de alta permeabilidade, que foi depositado sob influência de sistemas de canal. E finalmente a camada, que delimita superiormente este membro, caracterizada pela presença de folhelhos com sedimentos marinhos finos representando o final do ciclo transgressivo.

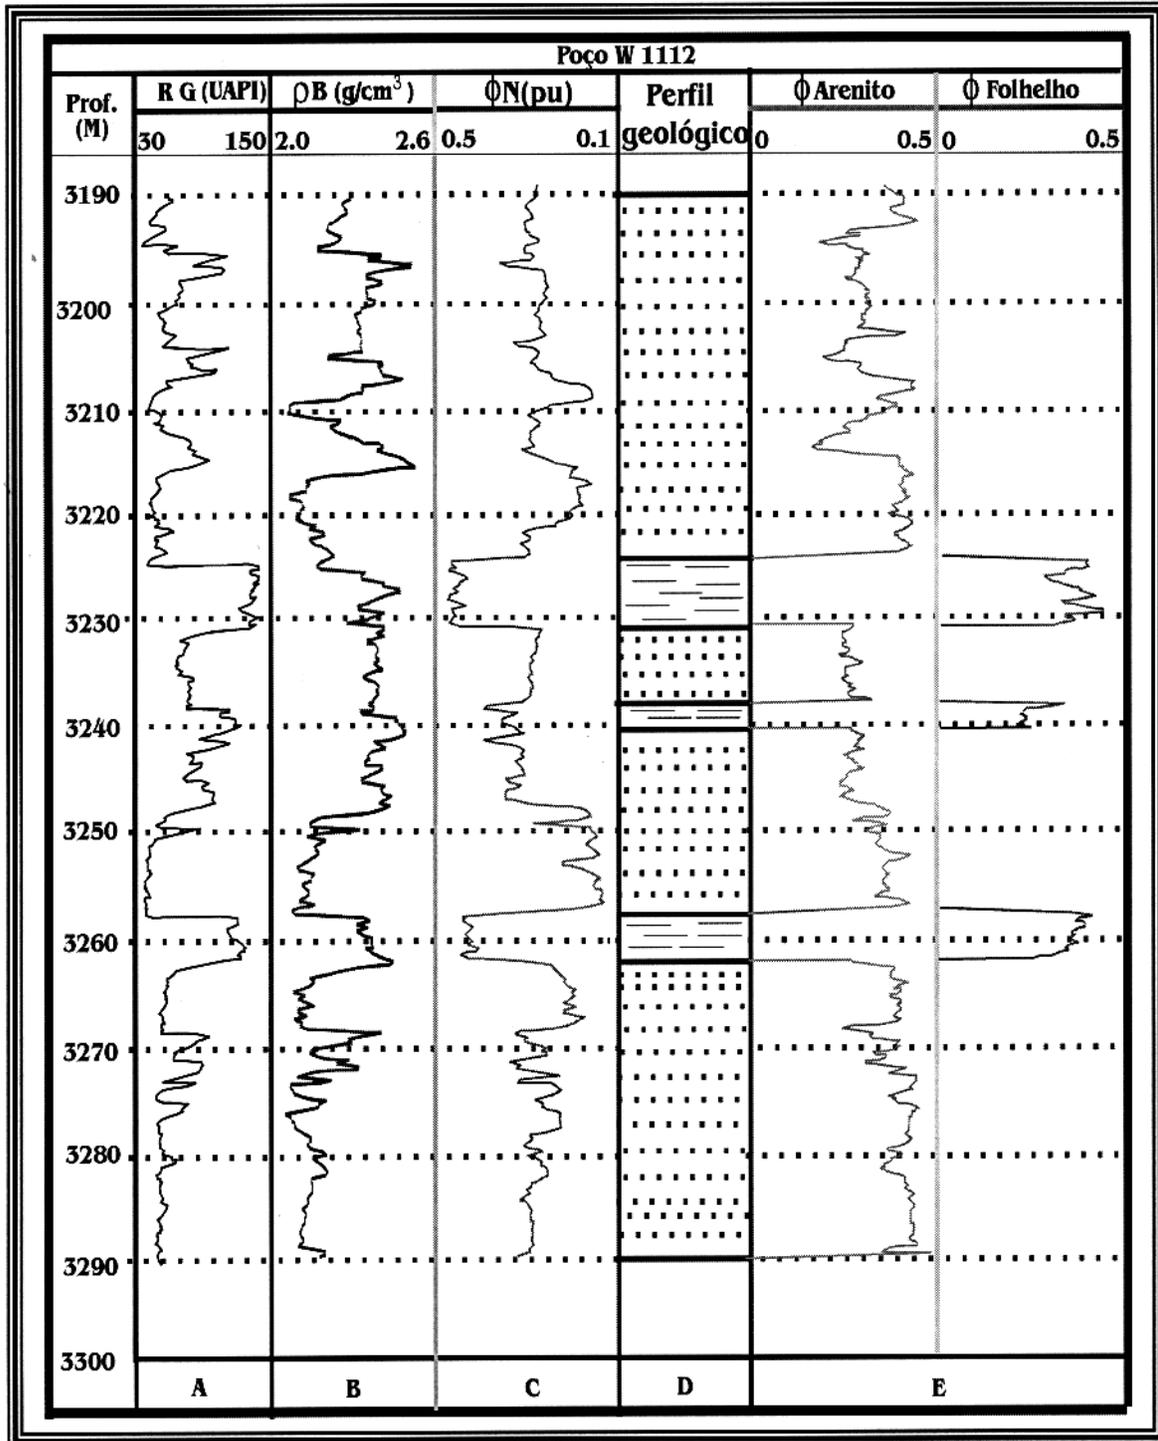
Estas informações geológicas serviram para a elaboração das colunas geológicas apresentadas nas Figuras 5.1a, 5.2a, 5.3a, 5.4a, 5.5a e 5.6a.

A apresentação formal dos resultados da aplicação da metodologia aqui apresentada, sobre os dados de perfil de seis poços, perfurados na bacia do Lago Maracaibo, no intervalo de profundidades relativos ao membro Lagunillas é mostrado através de figuras auto-explicativas, discriminadas como: Figuras 5.1, 5.2, 5.3, 5.4, 5.5 e 5.6. Cada figura é representativa de um poço e separadas em (a) e (b). As figuras (a) apresentam o perfil de porosidade efetiva zoneada (coluna E), na forma de um perfil duplo, com a primeira coluna mostrando a porosidade efetiva dos arenitos e a segunda, a porosidade aparente dos folhelhos. As colunas A, B e C são

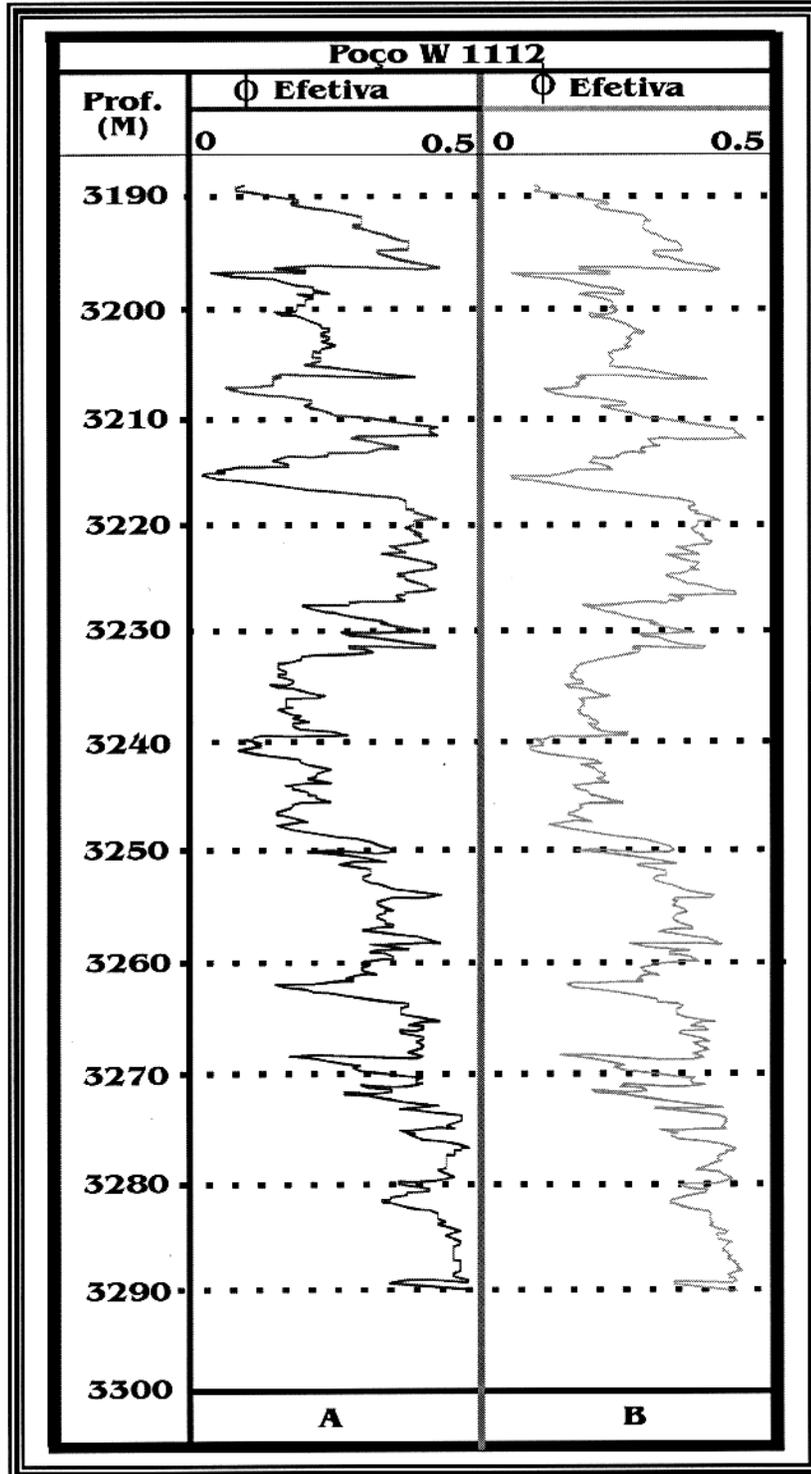
complementares e mostram, respectivamente, o perfil de raios gama natural, o perfil de densidade e o perfil de porosidade neutrônica.

A simples avaliação visual desse conjunto de figuras evidencia a adequação e a aplicabilidade das redes neurais artificiais com camada competitiva, no auxílio à interpretação dos perfis de porosidade.

As figuras discriminadas pela letra (b) mostram a comparação formal entre o perfil de porosidade efetiva, obtido a partir do processamento aqui apresentado, e o perfil de porosidade normalmente obtido através da interpretação manual dos perfis de porosidade. Observa-se claramente a comprovação da automatização do cálculo da porosidade efetiva.



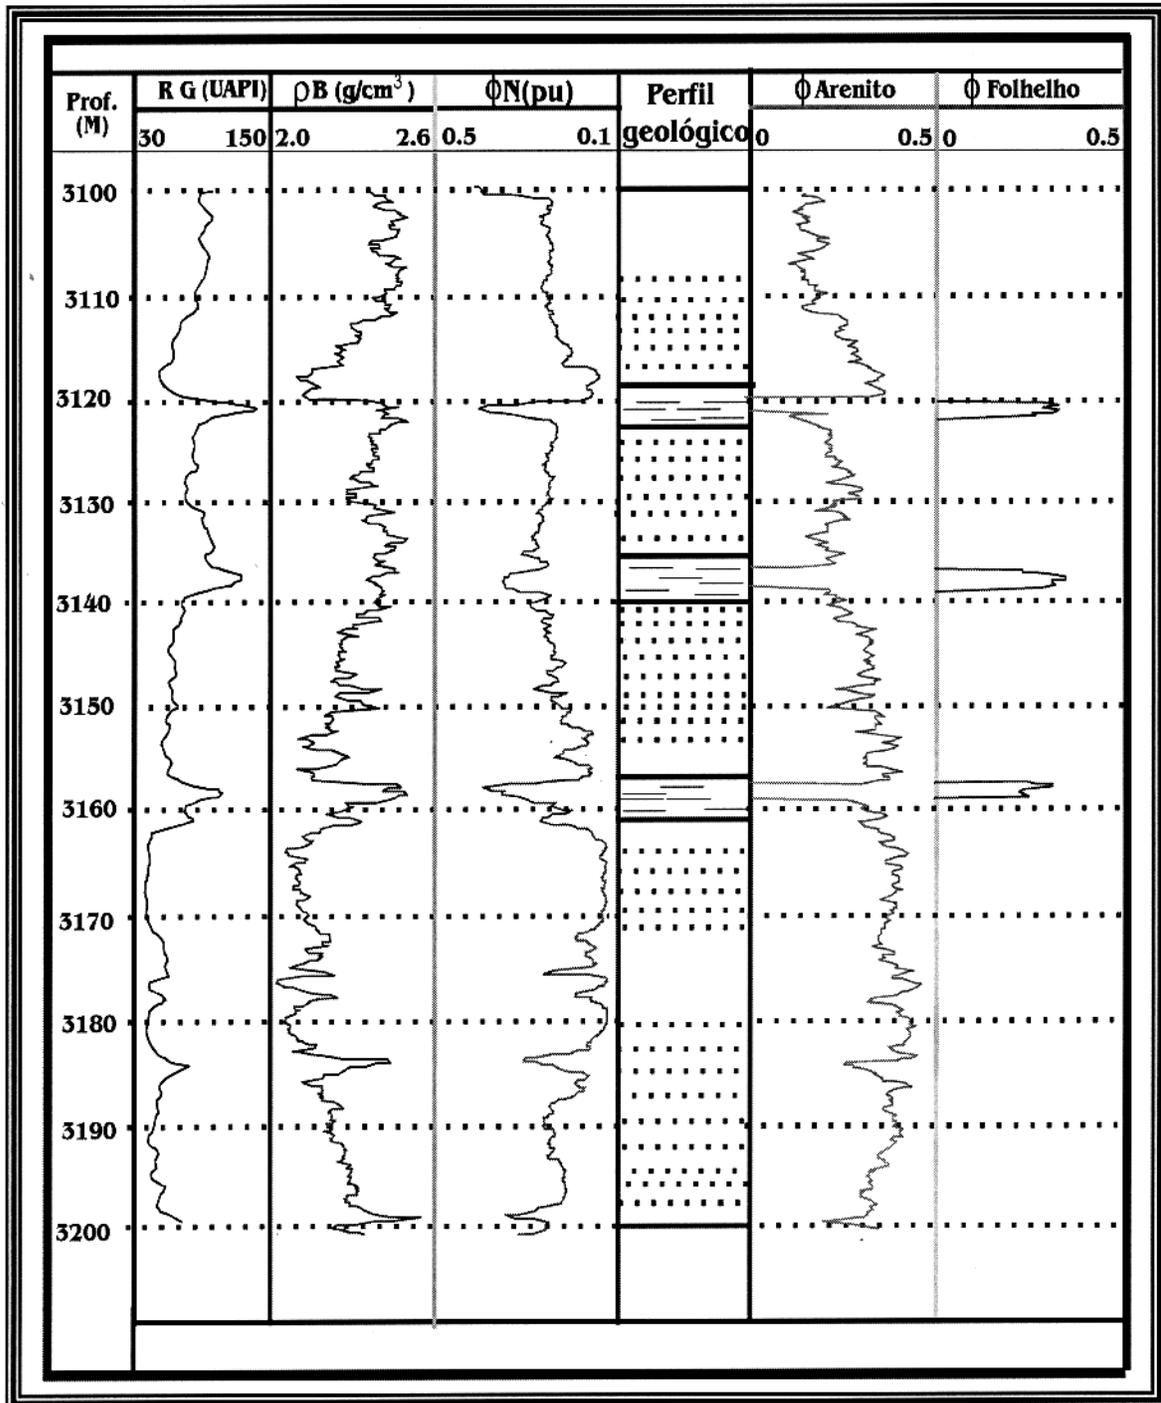
**Figura 5.1a** – Perfil de Porosidade Zoneada para o poço W1112. A - Perfil de Raio Gama natural, B – Perfil de Densidade, C – Perfil de Porosidade Neutrônico, D – Perfil Geológico e E – Perfil de Porosidade Zoneada.



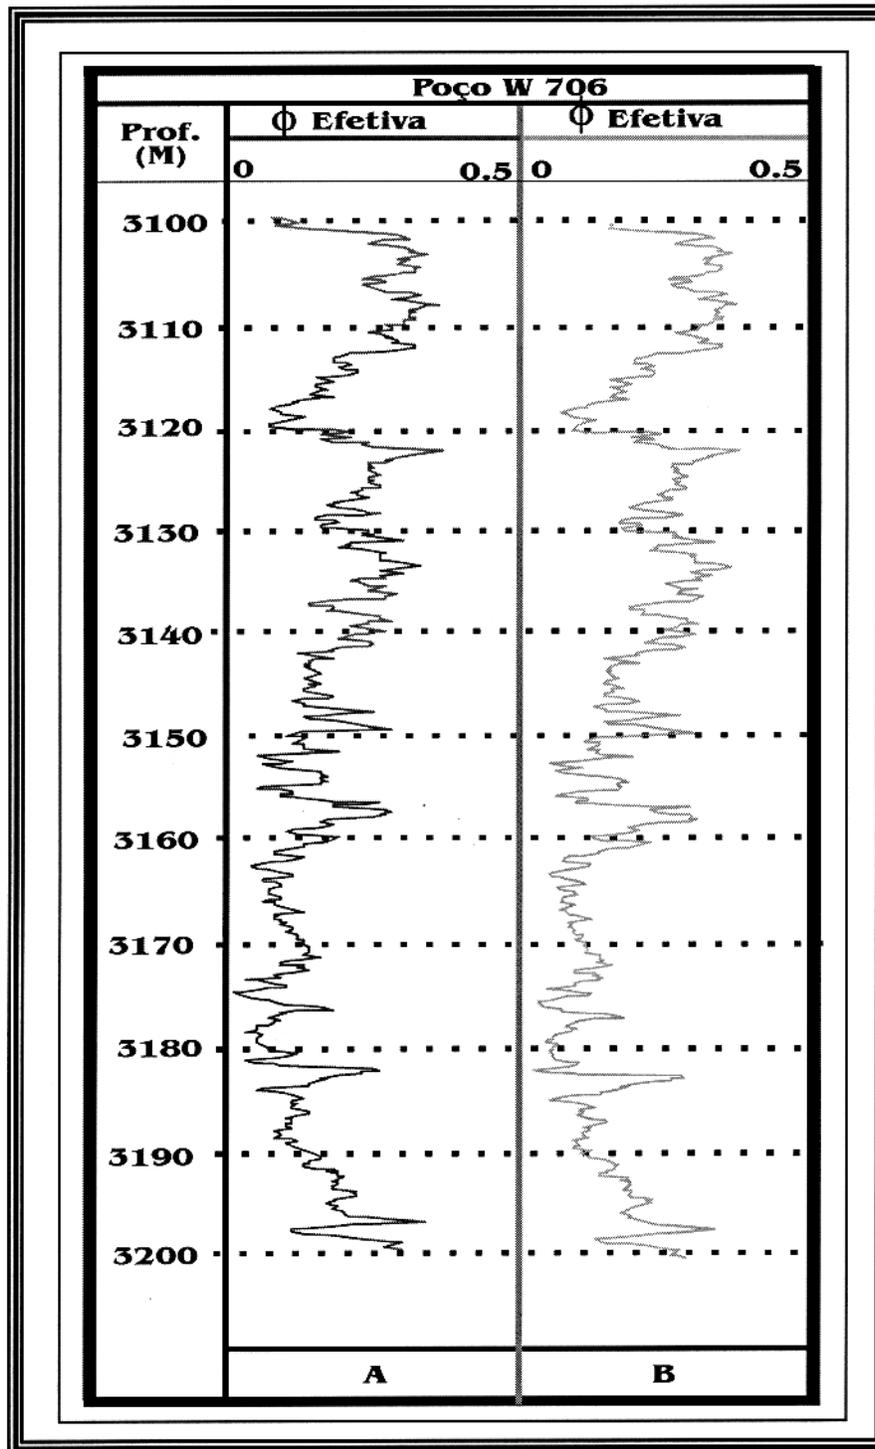
**Figura 5.1b** – Perfil de Porosidade Efetiva para o poço W1112. A – Perfil de Porosidade efetiva obtido através do processamento com RNA, B - Perfil de Porosidade efetiva convencional.



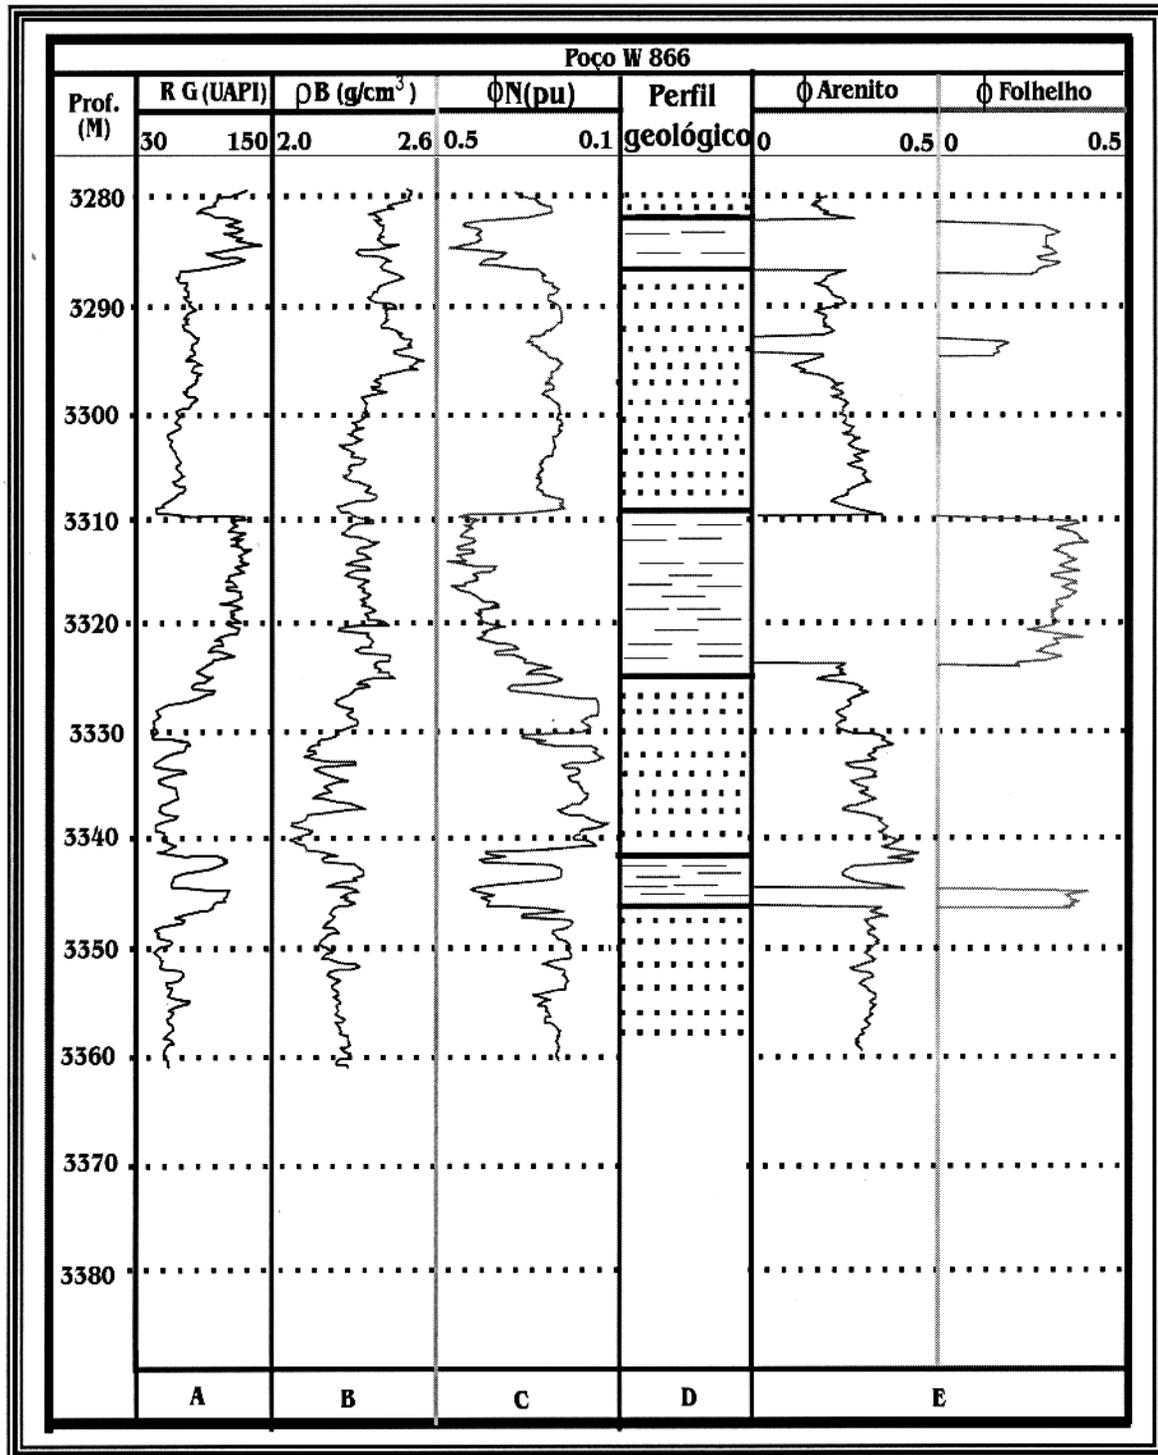




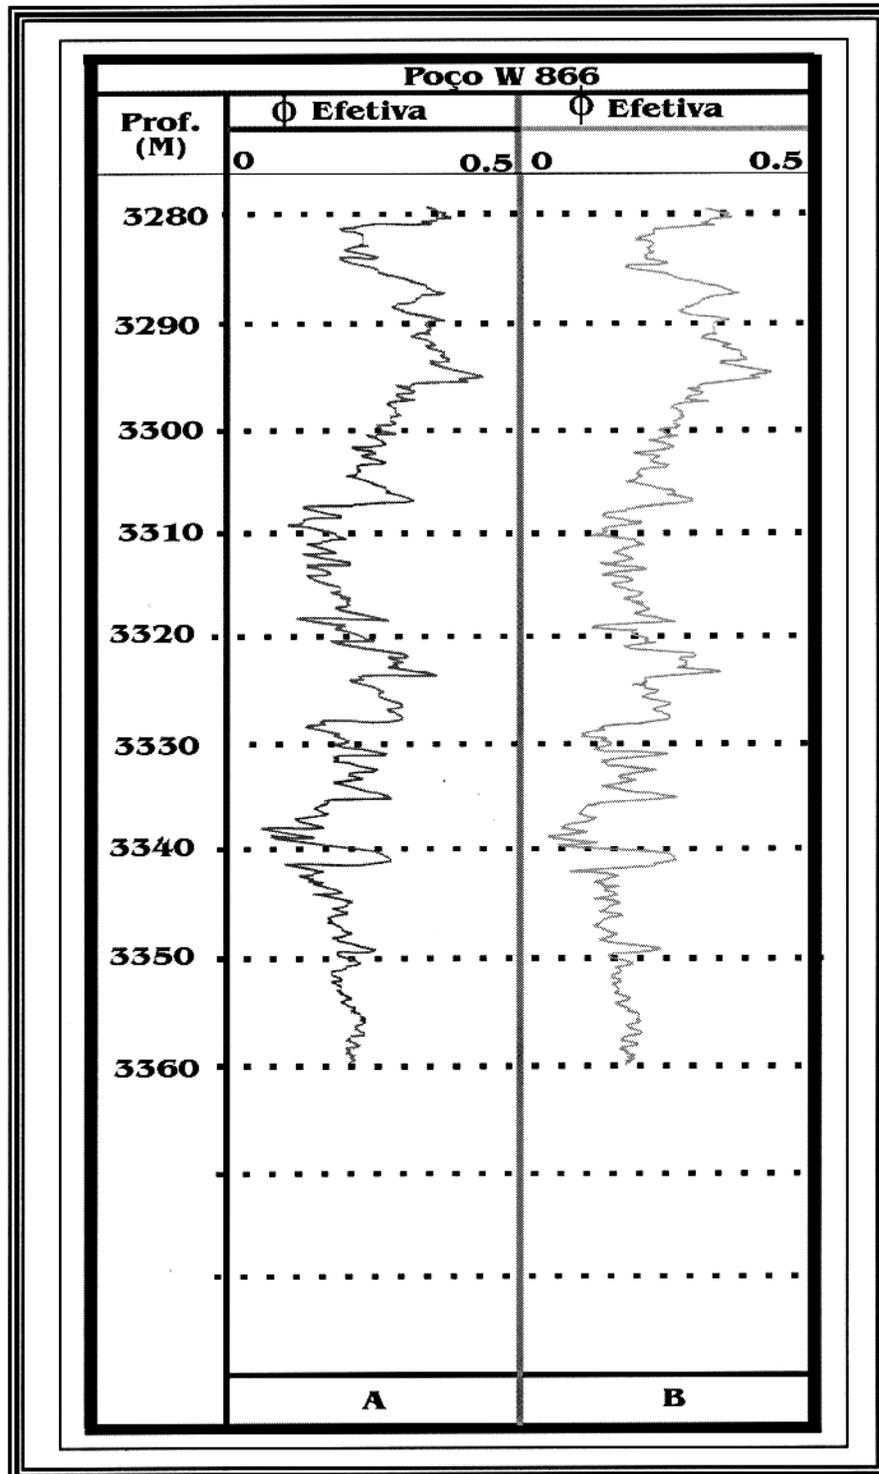
**Figura 5.3a** – Perfil de Porosidade Zoneada para o poço W706. A - Perfil de Raio Gama natural, B – Perfil de Densidade, C – Perfil de Porosidade Neutrônica, D – Perfil Geológico e E – Perfil de Porosidade Zoneada.



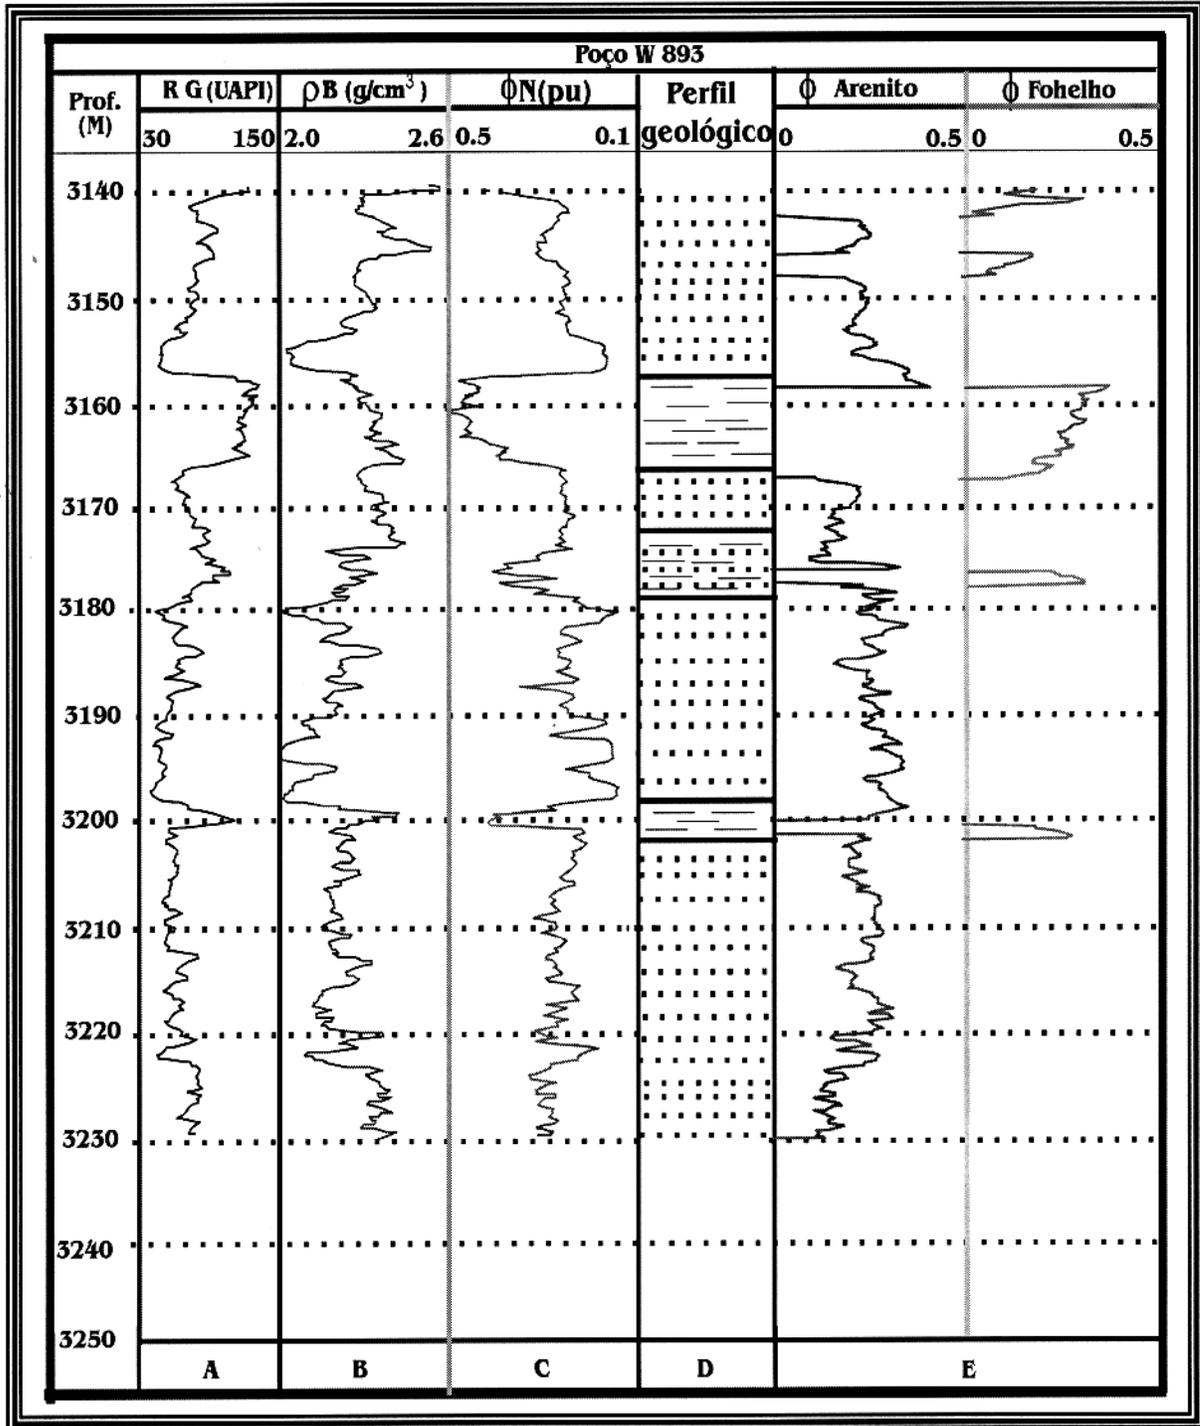
**Figura 5.3b** – Perfil de Porosidade Efetiva para o poço W706. A – Perfil de Porosidade efetiva obtido através do processamento com RNA, B - Perfil de Porosidade efetiva convencional.



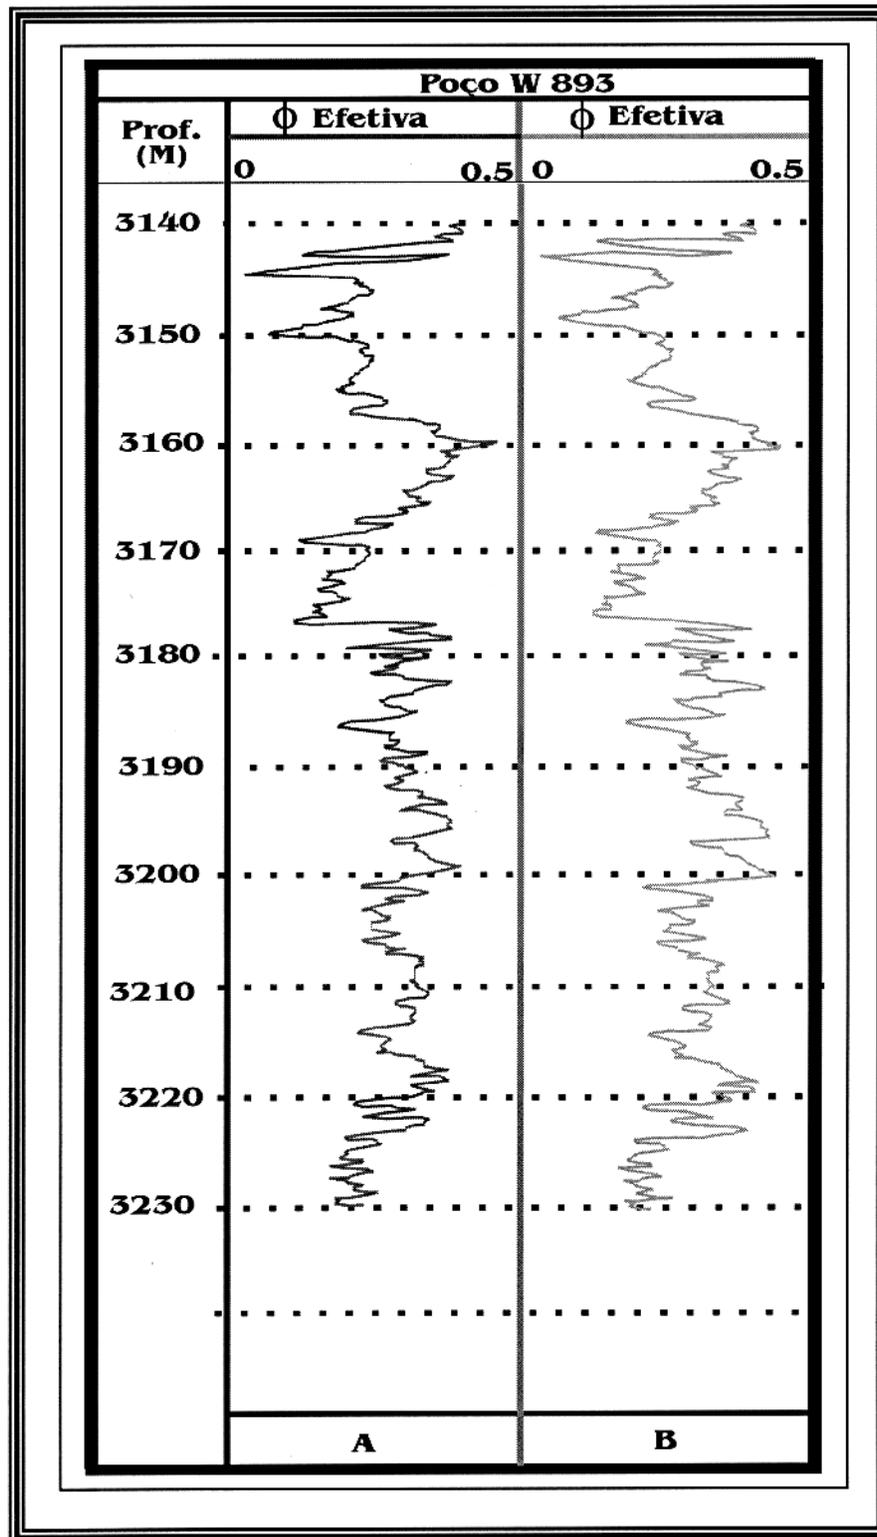
**Figura 5.4a** – Perfil de Porosidade Zoneada para o poço W866. A - Perfil de Raio Gama natural, B – Perfil de Densidade, C – Perfil de Porosidade Neutrônica, D – Perfil Geológico e E – Perfil de Porosidade Zoneada.



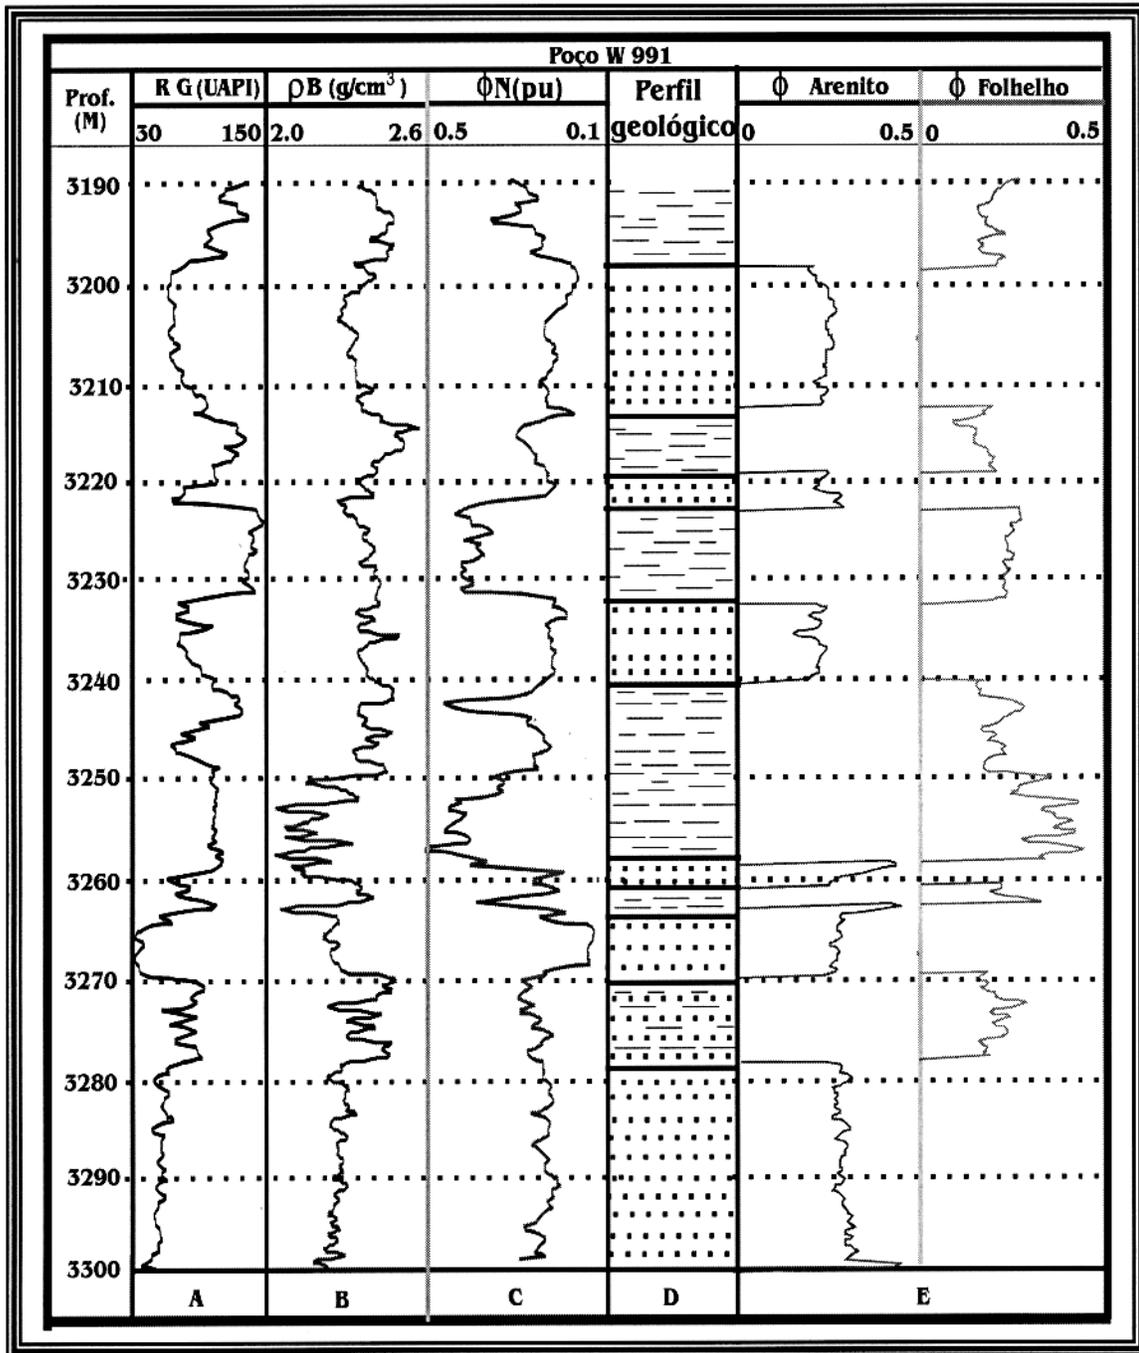
**Figura 5.4b** – Perfil de Porosidade Efetiva para o poço W866. A – Perfil de Porosidade efetiva obtido através do processamento com RNA, B - Perfil de Porosidade efetiva convencional.



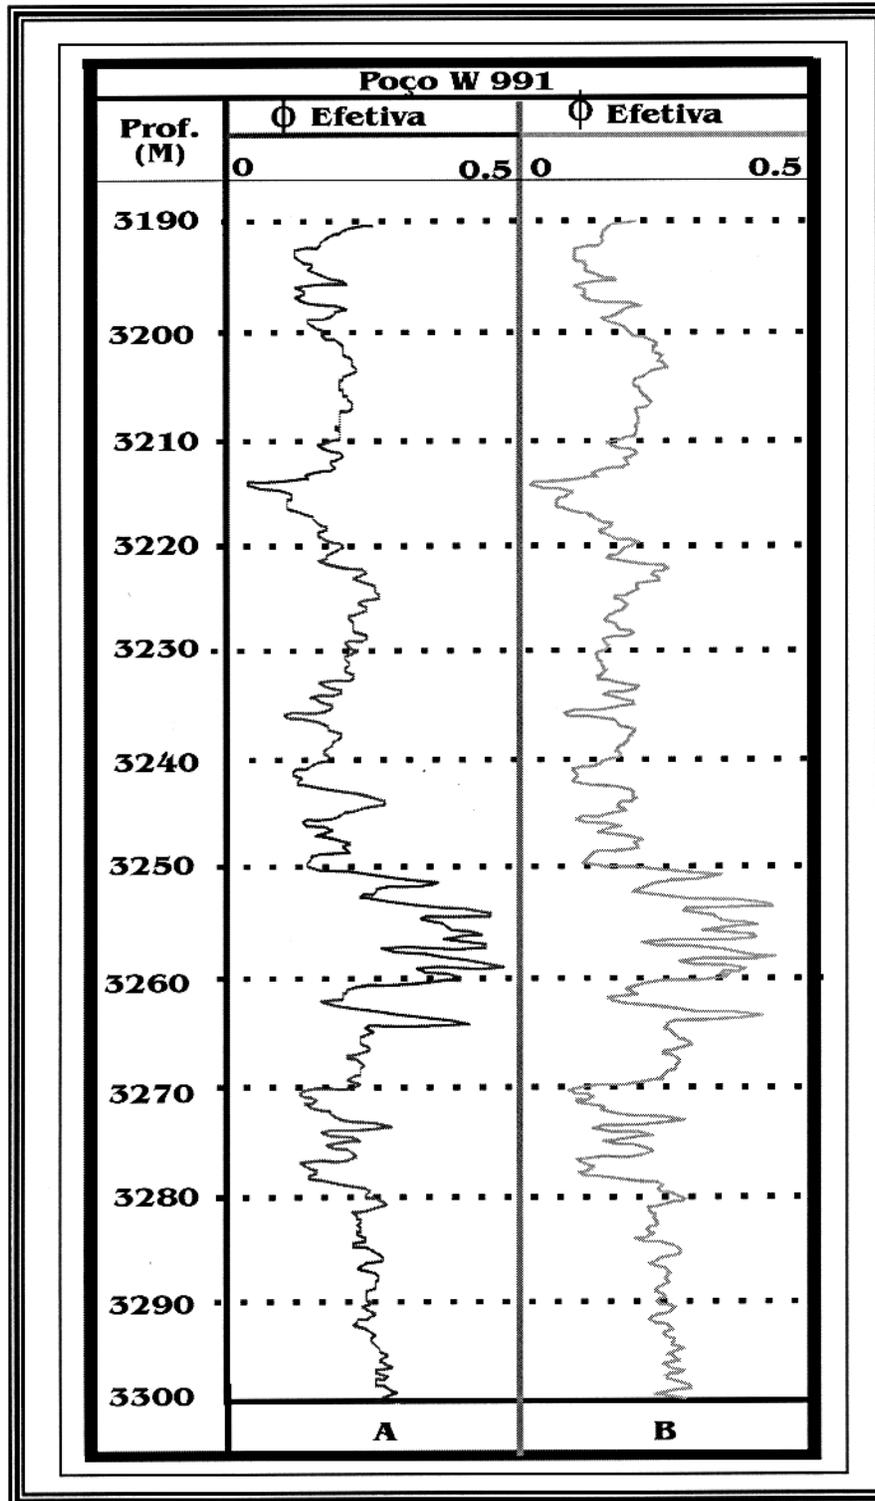
**Figura 5.5a** – Perfil de Porosidade Zoneada para o poço W 893. A - Perfil de Raio Gama natural, B – Perfil de Densidade, C – Perfil de Porosidade Neutrônica, D – Perfil Geológico e E – Perfil de Porosidade Zoneada.



**Figura 5.5b** – Perfil de Porosidade Efetiva para o poço 893. A – Perfil de Porosidade efetiva obtido através do processamento com RNA, B - Perfil de Porosidade efetiva obtido através de método numérico convencional.



**Figura 5.6a** – Perfil de Porosidade Zoneada para o poço W 991. A - Perfil de Raio Gama natural, B – Perfil de Densidade, C – Perfil de Porosidade Neutrônica, D – Perfil Geológico e E – Perfil de Porosidade Zoneada.



**Figura 5.6b** – Perfil de Porosidade Efetiva para o poço 991. A – Perfil de Porosidade efetiva obtido através do processamento com RNA, B - Perfil de Porosidade efetiva obtido através de método numérico convencional.

## 6 - CONCLUSÕES

A interpretação dos perfis geofísicos de poço aberto é, ainda hoje, um processo puramente manual, que demanda um excessivo tempo do intérprete, mas de fundamental importância na avaliação da presença e quantificação de hidrocarbonetos em subsuperfície, bem como para a viabilização do modelo geológico do reservatório, que direcione a estratégia de produção.

Em função da grande massa de dados de poço disponível e necessária à melhor compreensão da geologia do reservatório é que se insere a dissertação aqui apresentada, a qual demonstra a viabilidade da automatização de algumas das atividades cotidianas do intérprete de perfis.

O zoneamento do perfil e o cálculo de porosidade efetiva realizados de forma automática e apresentados na forma do perfil de porosidade zoneada é claramente um auxílio para o intérprete e não um substituto, visto que é do julgamento do intérprete a aplicação da metodologia apresentada.

Em termos computacionais para obtenção da porosidade efetiva o perfil de porosidade zoneada possui precisão equivalente ao perfil de porosidade convencional, mas apresenta um tempo de máquina inferior.

Quanto ao zoneamento obtido por RNA, pode-se constatar que possui grande fidelidade aos perfis geológicos, o que pode ser observado relacionando as colunas (D) e (E) das Figuras 5.1a, 5.2a, 5.3a, 5.4a, 5.5a e 5.6a. Porém, alguma discrepância é notada nos contatos entre camadas. Essa variação de posicionamento das interfaces, entre os dois métodos, é devido à mudança gradativa de litologia que geralmente ocorre em bacias sedimentares (devido a seus processos deposicionais gradativos). Desta forma, este contato litológico não ocorre de forma pontual e sim em um intervalo de profundidade, enquanto que o zoneamento apresentado nesta dissertação é determinado de forma discretizada.

Esses resultados foram obtidos para seções geológicas específicas de intercalações de arenito com folhelho, porém, estima-se que possam ser estendidas para outras litologias características das bacias sedimentares, como por exemplo, o calcário e a dolomita; pois não foram identificadas limitações no método apresentado nesta dissertação, a nenhum tipo específico de litologia.

Os resultados obtidos pela aplicação desse procedimento a dados reais são bastantes animadores e apontam no sentido de uma maior investigação quanto a utilização da técnica a outros parâmetros petrofísicos, e até mesmo a outras ferramentas de perfilagem.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AMBROS-INGERSON, J.; GRANGER R.; LYNCH G., 1990. *Simulation of paleo-cortex performs hierarchical clustering. Science* **247**: 1344-1348.
- BRYANT, I. D., 1989 – *Sedimentology of the Lower Lagunillas Reservior, Pilot Area, Bloque IV, Lake Maracaibo, Venezuela.*
- CHURCHLAND, P. S., 1986 – *Neurophilosophy: Toward a Unified Science of the Mind/Brain.* Cambridge, MA: MIT Press.
- CHURCHLAND, P. S. & SEJNOWSKI, T. J. 1992 – *The Computation Brain.* Cambridge, MA: MIT Press.
- CRAIN, E. R. 1986 – *The Log Analysis Handbook* – Oklahoma, Penn Well Publishing Company.
- DOVETON, J. D., 1986 – *Log Analysis of subsurface Geology: Concepts and Computer Methods.* Kansas, USA. 273 p.
- DURBIN, R.; MIALI C.; MITCHISON G., (eds), 1989 – *The Computing Neuron.* Reading, MA: Addison-Wesley.
- ELLIS, D. V., 1987 – *Well Logging for Earth Scientists* – New York, Elsevier Science Publishing Co., Inc.. 532 p.
- FUKUSHIMA, K., 1975 – *Cognitron: A Self-organizaion Multilayered Network. Biological Cybernetics* **20**: 121-136.
- GROSSBERG, S., 1972 – *Neural expectation: Cerebellar and retinal analogs of cells fired by learnable or unlearned pattern classes. Kybernetik* **10**: 49-57.

- GROSSBERG, S., 1976a – *Adaptive pattern classification and universal recording: I. Parallel development and coding of neural detectors. Biological Cybernetics* **23**: 121-134.
- GROSSBERG, S., 1976b - “Adaptive pattern classification and universal recording: II. Feedback, expectation, olfaction, illusions.” *Biological Cybernetics* **23**: 187-202
- GROSSBERG, S., 1982 – *Studies of the Mind and Brain*, Dordrecht, Holland: Reidel Press, 1982.
- HAYKIN, S., 1991 – *Adaptive Filter Theory*. 2. ed. Englewood Cliffs, NJ: Prentice-Hall.
- HAYKIN, S. 1994 – *Neural Networks - Comprehensive Foundation*. New York, Macmillan College Publishing Company.
- HEBB, D. O., 1949 – *The Organization of Behavior: A Neuropsychological Theory*. New York: Wiley.
- HECHT-NIELSEN, R., 1988 – *Neurocomputing*. Reading, MA: Addison-Wesley.
- HERTZ, J.; KROGH A.; PALMER R. G., 1991 – *Introduction to the Theory of Neural Computation*. Reading, MA: Addison-Wesley.
- KOHONEN, T., 1988 – *Self-Organization and Associative Memory*. 3. ed. New York: Springer-Verlag.
- LEVINE, M., 1985 – *Man and Machine Vision*. New York: McGraw-Hill.
- MARR, D., 1982 – *Vision*. New York: Freeman.
- MCCORMACK, M.D.; ZAUCHA, D.E.; DUSHEK, D.W., 1993. First-break refraction event picking and seismic data trace editing using neural networks. *Geophysics*, **58**: 67-78.

NERY, G. G., 1989 – *Perfilagem em poço Aberto*. Curso de Engenharia do Petróleo. CEN-NOR.  
231 p.

RUMELHART, D. E. & ZIPSER D., 1985 – *Feature discovery by competitive learning*.  
*Cognitive Science* **9**: 75-112.

*SCHLUMBERGER LOG INTERPRETATION CHARTS* 1985 - Schlumberger, New York.

von der MALSBERG, C., 1973 – *Self-organization of orientation sensitive cells in the striate cortex*. *Kybernetik* **14**: 85-100.

WIDROW, B. & STEARNS, S. D., 1985 – *Adaptive Signal Processing*. Englewood Cliffs, NJ:  
Prentice-Hall.

WILLSHAW, D. J. & C. von der MALSBERG, 1976 – *How patterned neural connections can be set up by self-organization*. *Proceedings of the Royal Society of London, Series B* **194**:  
431-445.