



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

Tese de Doutorado

**IMAGEAMENTO DA POROSIDADE ATRAVÉS DE PERFIS
GEOFÍSICOS DE POÇO.**

ANNA ILCÉA FISCHETTI MIRANDA

**BELÉM
2004**

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

**IMAGEAMENTO DA POROSIDADE ATRAVÉS DE PERFIS GEOFÍSICOS DE
POÇO**

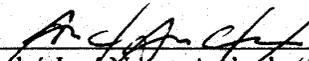
TESE APRESENTADA POR
ANNA ILCÉA FISCHETTI MIRANDA

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

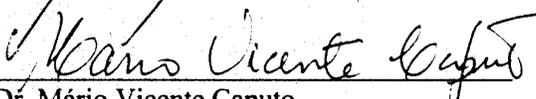
Data de Aprovação: 27/ 01/ 2004

Conceito: EXCELENTE (91 %)

COMITÊ DE TESE:



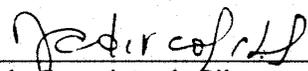
Dr. André José Neves Andrade (Orientador)



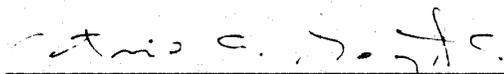
Dr. Mário Vicente Caputo



Dr. Roberto Célio Limão de Oliveira



Dr. Jadir da Conceição da Silva



Dr. Antonio Abel González Carrasquilla

BELÉM

2004

*Ao meu filho, Rafael Fischetti
Miranda, com muito amor e carinho. Que
esta tese sirva como estímulo na sua vida
estudantil.*

AGRADECIMENTOS

Ao CNPq pelo suporte dado através da minha bolsa de doutorado.

Aos meus pais, Giuseppe Fischetti e Maria da Conceição Rocha Fischetti, pelos incentivos e oportunidades que me propiciaram.

Ao meu marido, Luis Marcos Moura Miranda, pela sua paciência, tolerância e apoio nos momentos mais difíceis.

À minha irmã, Anna Carmela Fischetti Ferreira, pela confiança e apoio.

À professora Josefina Irene Pinheiro (*in memoriam*) pela amizade e incentivo.

Às professoras Dra. Brígida Ramati Pereira da Rocha (CT/UFPa) e Dra. Valquíria Macedo Gusmão (CT/UFPa) pelas contribuições nesta tese.

Aos membros da banca de defesa de tese, Prof^o Dr. Mário Vicente Caputo (CG/UFPa), Prof^o Dr. Roberto Célio Limão de Oliveira (CT/UFPa), Prof^o Dr. Jadir da Conceição da Silva (DG/UFRJ) e Prof^o Dr. Antônio Abel Gonzáles Carrasquilla (LENEP/UENF), pelas sugestões feitas à esta tese.

Ao meu orientador, Prof^o Dr. André José Neves Andrade (CG/UFPa), agradeço a oportunidade e confiança em mim depositadas em todos estes anos de trabalho. Muito obrigada.

Sumário

DEDICATÓRIA	i
AGRADECIMENTOS	ii
LISTA DE ILUSTRAÇÕES	iv
RESUMO	1
ABSTRACT	2
1 INTRODUÇÃO	3
2 GRÁFICOS DE POROSIDADE	5
2.1 INTRODUÇÃO.....	5
2.2 PERFIS DE POROSIDADE.....	5
2.2.1 Perfil de Densidade	6
2.2.1.1 Princípio Ferramental.....	6
2.2.2 Perfil Neutrônico	8
2.2.2.1 Princípio Ferramental.....	8
2.2.3 Perfil Sônico	10
2.2.3.1 Princípio Ferramental.....	10
2.3 GRÁFICOS DE POROSIDADE.....	12
2.3.1 Gráfico $\rho_b - \Delta t$	13
2.3.2 Gráfico $\phi_N - \Delta t$	15
2.3.3 Gráfico $\rho_b - \phi_N$	16
3 REDES NEURAIS ARTIFICIAIS	17
3.1 INTRODUÇÃO.....	17
3.2 O NEURÔNIO BIOLÓGICO.....	21
3.3 O NEURÔNIO ARTIFICIAL.....	23
3.4 REDE NEURAL COMPETITIVA.....	25
3.5 REDE NEURAL DE FUNÇÃO DE BASE RADIAL.....	28
4 IMAGEAMENTO DA POROSIDADE	31
4.1 INTRODUÇÃO.....	31
4.2 INTERPRETAÇÃO AUTOMÁTICA DO GRÁFICO DENSIDADE- NEURÔNICO.....	31
4.2.1 Perfil de Porosidade	33
4.3 LINHAS DE CORRELAÇÃO.....	42
4.4 IMAGEAMENTO DA POROSIDADE.....	45
5 CONCLUSÕES	51
REFERÊNCIAS BIBLIOGRÁFICAS	52
APÊNDICE- Porosity images from well logs	58

Lista de Ilustrações

FIGURAS

Figura 2.1	Ferramenta de densidade no interior de um poço. A ferramenta está separada da parede do mesmo pela espessura t_{mc} do reboco (modificada de Ellis, 1987).....	7
Figura 2.2	Representação de uma ferramenta de porosidade neutrônica com dois detetores (modificada de Ellis, 1987).....	9
Figura 2.3	Ferramenta sônica padrão, em atividade, no interior de um poço (modificada de Ellis, 1987).....	11
Figura 2.4	Gráfico densidade-sônico. Variações de porosidade nos três tipos de rochas reservatórios produzem variações no tempo de trânsito da onda compressional e na densidade da formação.....	14
Figura 2.5	Gráfico nêutron-sônico para determinação da porosidade, onde pode-se observar uma melhor distribuição das curvas para a discriminação da litologia.....	15
Figura 2.6	Gráfico densidade-neutrônico para a determinação da litologia e porosidade em litologias simples.....	16
Figura 3.1	Neurônio biológico exemplificado pela célula piramidal, comum no córtex cerebral, mostrando os caminhos do fluxo do sinal (dentritos e axônios), o corpo da célula e, no detalhe, as microcavidades das ligações sinápticas (modificada de Haykin, 2001).....	23
Figura 3.2	Modelo de um neurônio artificial típico, onde identifica-se os seus componentes básicos, em analogia ao neurônio biológico.....	24
Figura 3.3	Transformação afim realizada pela introdução do termo θ_k (potencial limite).....	25
Figura 3.4	Arquitetura de uma rede neural competitiva simples, onde podemos observar a camada com os nós de entrada e a camada competitiva.....	27
Figura 3.5	Arquitetura de uma rede neural com função de base radial, onde podemos observar a camada de entrada, composta por duas unidades sensoriais, a camada oculta, composta por quatro neurônios, e a camada de saída, composta por um neurônio.....	30

Figura 4.1	Localização do Campo de Lagunillas, na Bacia do Lago Maracaibo e, no detalhe, apresenta-se a coluna estratigráfica referente à Formação Lagunillas, caracterizada pela seqüência arenito-folhelho, sendo que os arenitos apresentam diferentes graus de contaminação por argila (modificada de Talukdar & Marcano, 1994).....	32
Figura 4.2	Gráfico $\rho_b - \phi_N$, obtido a partir do Poço A, onde as cruzes representam os pares ordenados de entrada (ρ_b, ϕ_N) e a linha azul representa a linha dos arenitos limpos.....	33
Figura 4.3	Arquitetura da rede neural competitiva para a obtenção do ponto do folhelho. A camada de entrada é composta por duas unidades sensoriais e a camada competitiva é composta por quatro neurônios.....	35
Figura 4.4	Posicionamento, após o treinamento, dos pesos sinápticos dos quatro neurônios da camada competitiva da rede neural, representados por círculos verdes, para o estabelecimento do ponto do folhelho.....	35
Figura 4.5	Gráfico $\rho_b - \phi_N$, obtido a partir do Poço A, o ponto verde representa o ponto do folhelho e a linha verde é a linha representativa dos folhelhos, que passa por este ponto.....	36
Figura 4.6	Arquitetura da rede neural competitiva para a obtenção do zoneamento do perfil. A camada de entrada é composta por duas unidades sensoriais e a camada competitiva é composta por oitenta e dois neurônios competitivos.....	37
Figura 4.7	Perfil de porosidade zoneada para o Poço A. Na primeira faixa temos o perfil de raios gama. Na segunda faixa temos o perfil de porosidade zoneada para o arenito e na terceira faixa temos o perfil de porosidade zoneada para o folhelho...	39
Figura 4.8	Perfil de porosidade zoneada para o Poço B. Na primeira faixa temos o perfil de raios gama. Na segunda faixa temos o perfil de porosidade zoneada para o arenito e na terceira faixa temos o perfil de porosidade zoneada para o folhelho...	40
Figura 4.9	Perfil de porosidade zoneada para o Poço C. Na primeira faixa temos o perfil de raios gama. Na segunda faixa temos o perfil de porosidade zoneada para o arenito e na terceira faixa temos o perfil de porosidade zoneada para o folhelho...	41
Figura 4.10	Arquitetura de rede neural de função de base radial (RBF) para determinação das linhas de correlação.....	42
Figura 4.11	Conjunto de treinamento da rede neural de função de base	

	radial para a determinação das linhas de correlação. Destacado pela linha amarela tracejada, temos o intervalo de treinamento utilizado.....	43
Figura 4.12	Perfis de raio gama natural dos Poços A, B e C mostrando as linhas de correlação estabelecidas para a primeira camada de folhelho, através do processamento da rede neural de função de base radial.....	44
Figura 4.13	Arquitetura de rede neural de função de base radial para a determinação da porosidade ϕ nos perfis interpolados.....	46
Figura 4.14	Visualização do processo de interpolação da porosidade adotado pelo algoritmo interpretativo. Em vermelho têm-se os perfis de porosidade originais. Em azul mostra-se o primeiro perfil de porosidade interpolado.....	47
Figura 4.15	Interpolação de perfis realizada pela rede neural de função de base radial para a determinação do imageamento da porosidade. Os perfis em vermelho são referentes aos Poços A, B e C. Em azul temos os perfis interpolados.....	48
Figura 4.16	Imageamento da porosidade mostrando as suas variações laterais.....	49
Figura 4.17	Imageamento da porosidade. A variação das cores representa a distribuição dos valores da porosidade ao longo da seção.....	50

RESUMO

O imageamento da porosidade é uma representação gráfica da distribuição lateral da porosidade da rocha, estimada a partir de dados de perfis geofísicos de poço. Apresenta-se aqui uma metodologia para produzir esta imagem geológica, totalmente independente da intervenção do intérprete, através de um algoritmo, dito, interpretativo baseado em dois tipos de redes neurais artificiais. A primeira parte do algoritmo baseia-se em uma rede neural com camada competitiva e é construído para realizar uma interpretação automática do clássico gráfico $\rho_b - \phi_N$, produzindo um zoneamento do perfil e a estimativa da porosidade. A segunda parte baseia-se em uma rede neural com função de base radial, projetado para realizar uma integração espacial dos dados, a qual pode ser dividida em duas etapas. A primeira etapa refere-se à correlação de perfis de poço e a segunda à produção de uma estimativa da distribuição lateral da porosidade.

Esta metodologia ajudará o intérprete na definição do modelo geológico do reservatório e, talvez o mais importante, o ajudará a desenvolver de um modo mais eficiente as estratégias para o desenvolvimento dos campos de óleo e gás. Os resultados ou as imagens da porosidade são bastante similares às seções geológicas convencionais, especialmente em um ambiente deposicional simples dominado por clásticos, onde um mapa de cores, escalonado em unidades de porosidade aparente para as argilas e efetiva para os arenitos, mostra a variação da porosidade e a disposição geométrica das camadas geológicas ao longo da seção.

Esta metodologia é aplicada em dados reais da Formação Lagunillas, na Bacia do Lago Maracaibo, Venezuela.

ABSTRACT

Porosity images are graphical representations of the lateral distribution of rock porosity estimated from well log data. We present a methodology to produce this geological image entirely independent of interpreter intervention, with an interpretative algorithm approach, which is based on two types of artificial neural networks. The first is based on neural competitive layer and is constructed to perform an automatic interpretation of the classical $\rho_b - \phi_N$ cross-plot, which produces the log zonation and porosity estimation. The second is a feed-forward neural network with radial basis function designed to perform a spatial data integration, which can be divided in two steps. The first refers to well log correlation and the second produces the estimation of lateral porosity distribution.

This methodology should aid the interpreter in defining the reservoir geological model, and, perhaps more importantly, it should help him to efficiently develop strategies for oil or gas field development. The results or porosity images are very similar to conventional geological cross-sections, especially in a depositional setting dominated by clastics, where a color map scaled in porosity units illustrates the porosity distribution and the geometric disposition of geological layers along the section.

The methodology is applied over actual well log data from the Lagunillas Formation, in the Lake Maracaibo basin, located in western Venezuela.

1 INTRODUÇÃO

Atualmente, muitos estudos têm mostrado a aplicabilidade e eficiência das redes neurais artificiais em resolver um grande número de problemas geofísicos (Andrade & Luthi, 1997; Crocker et al., 1999; Fischetti & Andrade, 1999; Fitzgerald et al., 1999; Ali & Chawathe, 2000; Banchs & Michelena, 2000; Chang et al., 2000; Jamialahmadi & Javadpour, 2000). Um ponto em comum na maioria destes trabalhos é a necessidade da intervenção do intérprete no processamento das redes neurais, apresentando a resposta certa durante a fase de treinamento (Vander Baan & Jutten, 2000).

Neste trabalho introduzimos o conceito de algoritmo interpretativo, o qual deve integrar toda a informação disponível da geologia e geofísica de poço para produzir uma interpretação autônoma e geologicamente plausível destes dados em uma escala regional.

Aplica-se este conceito para um problema geológico de interpretação de perfis de poço. O objetivo é obter o imageamento da porosidade ou uma seção representativa da distribuição lateral da porosidade da rocha em subsuperfície. Este algoritmo interpretativo realiza uma eficiente integração dos dados dos perfis de poço com os procedimentos clássicos da interpretação dos perfis através das redes neurais artificiais.

Convencionalmente, problemas geológicos de interpretação de perfis requerem um alto grau de experiência do intérprete (Luthi, 2001). Todavia, mostra-se que o algoritmo interpretativo pode simular os processos de decisão envolvidos neste tipo de problema, particularmente em um ambiente deposicional dominado por clásticos (arenitos e folhelhos) e onde os processos diagenéticos ainda não tenham produzido grandes diferenças entre as várias partes do campo.

Apresentamos a aplicação da metodologia sobre dados reais da Formação Lagunillas, na Bacia do Lago Maracaibo, Venezuela. A evolução geológica da Bacia do Lago Maracaibo, relevante para o desenvolvimento de sistemas petrolíferos, inclui sedimentação e tectônica e vão do Cretáceo ao Holoceno. A Formação Lagunillas é derivada do inferior e médio Mioceno, consistindo de arenitos, folhelhos e carvão depositados em ambientes que variam de fluviais a deltaicos (Talukdar & Marcano, 1994).

Esta tese está estruturada na seguinte forma:

No Capítulo 2 apresenta-se o embasamento da Geofísica de Poço necessário para a compreensão do trabalho realizado.

No Capítulo 3 apresenta-se um resumo das redes neurais artificiais, enfatizando as redes neurais com camada competitiva e de função de base radial, que foram as utilizadas neste trabalho.

No Capítulo 4 mostra-se a metodologia desenvolvida nesta tese para a obtenção do imageamento da porosidade. Vê-se também o funcionamento de cada parte do algoritmo interpretativo e mostram-se os resultados obtidos em cada etapa do processamento. Mostra-se, ainda, a imagem da porosidade para dados reais de origem venezuelana.

Nas Conclusões destaca-se a adequabilidade, eficiência e ineditismo do método aplicado, apresentando novas idéias que irão refinar a metodologia apresentada.

2 GRÁFICOS DE POROSIDADE

2.1 INTRODUÇÃO

A porosidade é a propriedade petrofísica característica e peculiar das rochas sedimentares tipo reservatório, que expressa a fração do volume total da rocha que pode ser ocupado por um fluido. Assim, a porosidade é a propriedade que qualifica a capacidade armazenadora de um reservatório. A sua determinação, através dos perfis geofísicos, não é uma tarefa fácil e imediata, quando consideram-se as múltiplas possibilidades de composição e arranjo dos grãos nas rochas sedimentares. Normalmente, um único perfil, na maioria das situações, é incapaz de proporcionar uma estimativa confiável da porosidade, em função das diversas formas de interação entre a constituição da rocha e a propriedade física mensurada pelas ferramentas. Assim, é comum a utilização de mais de um perfil para a sua determinação.

A descrição litológica, clássica da geologia, geralmente inclui, em adição ao mineral principal, a indicação da presença de vários outros minerais chamados acessórios; no entanto para o objeto da geofísica de poço bastam os minerais principais componentes das rochas reservatório. Pode-se incluir ainda, a depender do tipo de gráfico de porosidade, rochas como a anidrita, a halita, a gipsita e outras rochas evaporíticas. Para os geólogos, esta lista é bastante limitada, mas é suficiente para a solução do problema geofísico da estimativa da porosidade em uma dada profundidade, cuja matriz seja desconhecida.

Uma das formas eficientes para a determinação conjunta da litologia e da porosidade é a utilização dos, assim chamados, gráficos de porosidade. Em um plano conveniente que possui como eixos dois perfis de porosidade, é lançada a solução da equação de Willye para uma dada litologia (Ellis, 1987). Neste tipo de interpretação, o termo *matriz* é utilizado para designar os principais tipos de rocha reservatório: arenito, calcário e dolomita.

2.2 PERFIS DE POROSIDADE

Nesta seção discutem-se as três ferramentas sensíveis à porosidade. A primeira é a ferramenta de densidade, cujo parâmetro medido é a densidade da formação (ρ_b). Conforme a

porosidade aumenta, a densidade da rocha diminui. A segunda é a ferramenta neutrônica, que é sensível à presença do hidrogênio. O registro da sua medida é a porosidade neutrônica (ϕ_N), associada à porosidade da formação, em função do índice de hidrogênio que reflete a quantidade deste elemento na formação, normalmente presente nos fluidos no espaço poroso. Para finalizar, temos a ferramenta sônica que mede o tempo de trânsito (Δt) da onda compressional, registrado em $\mu s/ft$. Esta medida aumenta de acordo com o aumento da porosidade, em razão da baixa velocidade sônica nos fluidos nos poros.

2.2.1 Perfil de Densidade

O perfil de densidade é o registro contínuo das variações das densidades das rochas atravessadas por um poço. No caso de rochas porosas, a medição realizada pelo perfil inclui tanto a densidade da matriz da rocha, como a do fluido contido no espaço poroso. Sabe-se que a transmissão de raios gama, através da matéria, pode ser relacionada com a densidade eletrônica se a interação predominante for o Efeito Compton. No ambiente do poço, uma medida do transporte dos raios gama pode ser usada para determinar a densidade da rocha próxima à parede do poço. Com alguma informação sobre a composição do material, litologia e fluido, pode-se determinar a porosidade da rocha.

2.2.1.1 Princípio Ferramental

A fonte de raios gama normalmente utilizada é o Césio (Cs^{137}), o qual emite raios gama com uma energia de 662 KeV, bem abaixo do limite para a ocorrência do efeito de Produção de Par. Este isótopo tem uma meia vida de cerca de trinta anos, o que dá uma estabilidade na intensidade do feixe energético, durante um período de tempo considerável. Algumas ferramentas utilizam o Cobalto (Co^{60}), que emite raios gama de diferentes energias: 1332 e 1173 KeV.

O poço é bombardeado por um fluxo de raios gama produzido por uma fonte que se encontra no interior da ferramenta. Um cintilômetro, montado no mesmo corpo ferramental e protegido da radiação direta da fonte, registra o fluxo de raios gama difundido pela formação. O sinal observado é relacionado com a densidade da formação, uma vez que ele é representativo do número de raios gama que foram desviados de sua trajetória original, no interior da formação. Assim, quanto menor for o fluxo de raios gama detectados, maior é o número de elétrons

(densidade eletrônica) responsáveis pela mudança na trajetória dos raios gama pelo Efeito Compton, o que implica em um maior número de átomos por unidade de volume. Infelizmente, a ferramenta de densidade não responde diretamente à densidade da rocha, mas sim ao número de elétrons por unidade de volume da mesma, ou seja, a densidade eletrônica. Então, uma correção é aplicada internamente, calibrando-se a ferramenta para o calcário saturado com água doce, visto através da equação (2.1),

$$\rho_b = 1.0704\rho_e - 0.188, \quad (2.1)$$

a qual produz valores de densidade com precisão de 0.0001 g/cc nas litologias mais comuns.

As ferramentas antigas consistiam de uma fonte de raios gama e um único detector. Entretanto, para eliminar o efeito da lama/reboco sobre as leituras do perfil, as ferramentas modernas (Figura 2.1) incorporaram dois detectores, geralmente ambos de NaI(Tl), que estão colocados em um tubo, que os protege da radiação direta proveniente da fonte. O detector próximo é mais influenciado pelo reboco (ou lama, se estiver em zonas desmoronadas) do que o detector afastado, mais afetado pela formação.

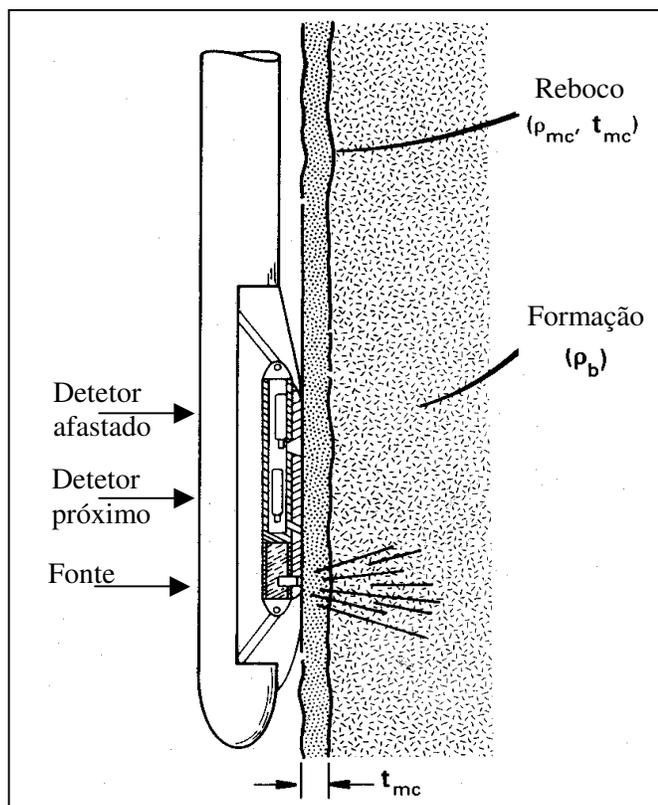


Figura 2.1: Ferramenta de densidade no interior de um poço. A ferramenta está separada da parede do mesmo pela espessura t_{mc} do reboco (modificada de Ellis, 1987).

Com estas duas leituras, em diferentes profundidades de investigação, acrescida da medida da espessura do reboco com a curva do caliper, a ferramenta realiza correções internas, ou compensações no valor da densidade, e apresenta valores de densidade bem mais realistas que as antigas ferramentas de um detetor. A ferramenta é comprimida contra a formação por um braço hidráulico, operado eletricamente na superfície. Este braço dá-nos também uma medida do diâmetro ao longo do poço, em uma direção.

2.2.2 Perfil Neutrônico

A ferramenta de perfilagem neutrônica foi a primeira ferramenta nuclear a ser utilizada para obter-se uma estimativa direta da porosidade da formação. Os nêutrons são partículas destituídas de carga elétrica, com massa quase idêntica à do núcleo de hidrogênio. Sendo partículas neutras, eles podem penetrar profundamente na matéria, atingindo os núcleos dos elementos que compõem a rocha, onde interagem elástica ou inelasticamente com eles.

O princípio ferramental baseia-se no fato que o hidrogênio apresenta uma seção de choque relativamente grande e massa pequena, sendo bastante eficiente no processo de redução da energia dos nêutrons rápidos. Uma medida da distribuição espacial dos nêutrons epitermais, resultantes da interação dos nêutrons com a formação, dá uma noção do conteúdo de hidrogênio presente. Como este hidrogênio (na forma de água ou hidrocarboneto) está no interior do espaço poroso da formação, isto faz com que esta medida esteja diretamente relacionada ao valor da porosidade.

2.2.2.1 Princípio Ferramental

Os nêutrons, cujo conceito foi introduzido, em 1932, por Heisenberg (Ellis, 1987), classificam-se de acordo com seus níveis energéticos (Tabela 1).

Tabela 1: Classificação dos nêutrons de acordo com o nível de energia.

NÊUTRON	ENERGIA (E)
Rápido	$E > 0.1 \text{ MeV}$
Epitermal	$0.1 \text{ MeV} > E > 0.025 \text{ eV}$
Termal	$E < 0.025 \text{ eV}$

As ferramentas neutrônicas modernas, Figura 2.2, são constituídas por uma fonte de nêutrons e dois ou mais detectores. As principais fontes em uso são constituídas por $Ra_{88}^{226} \cdot Be_4^9$, $Pu_{88}^{239} \cdot Be_4^9$ e $Am_{95}^{241} \cdot Be_4^9$, e foram projetadas para a emissão de nêutrons rápidos. A fonte emite nêutrons rápidos, os quais penetram nas camadas adjacentes ao poço. Através das sucessivas e múltiplas colisões elásticas, os nêutrons perdem parte da energia com que foram injetados. Esta perda de energia depende da massa relativa ou seção de choque do núcleo com o qual o nêutron colide. A maior quantidade de perda energética ocorre, justamente, quando os nêutrons se chocam com núcleos de massa praticamente igual à sua, portanto, com o núcleo de hidrogênio.

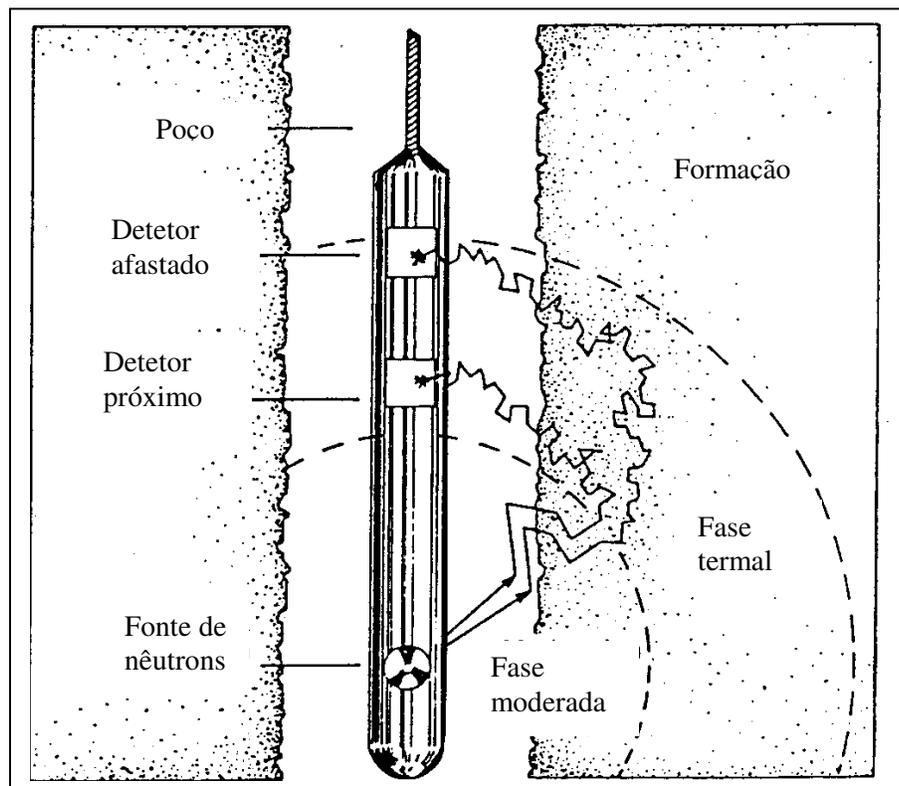


Figura 2.2: Representação de uma ferramenta de porosidade neutrônica com dois detectores (modificada de Ellis, 1987).

A detecção da radioatividade e o conseqüente produto final, o perfil, dependem do tipo de detector utilizado, visto que dependendo do modelo, eles captam nêutrons que variam de termiais a epitermais; lembrando sempre que o amortecimento do nível energético dos nêutrons rápidos,

depende da quantidade de hidrogênio, por unidade de volume, das camadas próximas às paredes do poço. Na interpretação do perfil neutrônico deve-se estar atento para perturbações inerentes ao ambiente da perfilagem, tais como o efeito da argila, matriz e gás sobre a ferramenta.

Em zonas portadoras de gás ou hidrocarbonetos leves (condensados), ocorre a redução da quantidade de átomos de hidrogênio por unidade de volume, produzindo a diminuição do valor da porosidade nessas zonas. Na situação de gás, as ferramentas de densidade e sônico não sofrem influência pela redução da densidade de hidrogênio. Este comportamento propicia a indicação imediata das zonas de gás, a partir do cruzamento da curva de porosidade neutrônica com a curva de porosidade estimada pelos perfis de densidade ou sônico.

2.2.3 Perfil Sônico

A medida da porosidade, através do perfil sônico, ocorre a partir da determinação do tempo gasto pela onda compressional para percorrer um determinado espaço de formação.

A velocidade do som varia segundo o meio em que suas ondas se propagam. Ela é mais rápida nos sólidos que nos líquidos e gases. Logo, o tempo gasto por uma onda sonora nos sólidos, para percorrer uma mesma distância fixa, é bem menor que nos líquidos e gases. A maior vantagem do perfil sônico provém da relação direta que existe entre o tempo de trânsito de uma onda sonora em uma rocha e sua porosidade, pois ao considerar-se duas rochas semelhantes, aquela que tiver maior quantidade de fluidos no seu espaço poroso (maior porosidade), apresentará um tempo de trânsito maior que aquela de menor volume fluido (menor porosidade).

2.2.3.1 Princípio Ferramental

A ferramenta sônica convencional mede o tempo de trânsito das ondas compressionais, na rocha vizinha ao poço, por meio de uma sonda composta por um transmissor e dois receptores (Figura 2.3). O impulso sonoro emitido com uma frequência constante, pelo transmissor, propaga-se nas camadas até vir a ativar sucessivamente dois receptores localizados, a distâncias fixas e pré-determinadas, na sonda de perfilagem.

Mede-se, portanto, não o tempo gasto pelo som para atingir ambos receptores, mas sim o tempo gasto no percurso entre os mesmos. Em outras palavras, mede-se uma diferença de tempo de propagação (tempo de trânsito), que é expressa em microssegundos por pé de formação ($\mu s / ft$).

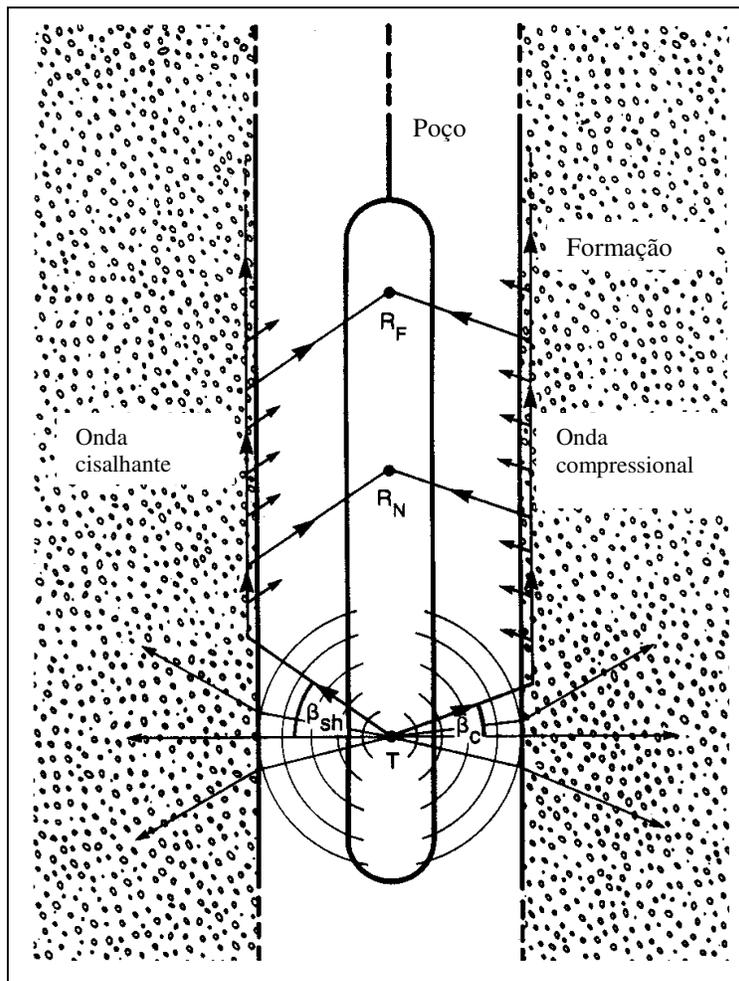


Figura 2.3: Ferramenta sônica padrão, em atividade, no interior de um poço (modificada de Ellis, 1987).

Os transmissores e os receptores consistem de transdutores feitos de cristais, cerâmicas ou bobinas magnéticas, que possuem a função de produzir uma deformação mecânica em resposta a um sinal elétrico (transmissor) ou produzir um sinal elétrico quando ele se deforma (receptor).

2.3 GRÁFICOS DE POROSIDADE

As medidas realizadas pelas ferramentas neutrônica, de densidade e sônica não dependem exclusivamente da porosidade, mas da litologia da formação, do fluido nos poros e, em alguns casos, da geometria da estrutura porosa e da granulometria. Quando se conhece a litologia, representada pelos parâmetros da matriz (ϕ_{Nm} , ρ_{bm} e Δt_m), pode-se obter o valor correto da porosidade com a utilização dessas medidas, no caso de formações limpas e saturadas com água.

Nas situações mais comuns, o cálculo da porosidade torna-se mais complexo quando não se conhece a litologia, que normalmente constitui-se por dois ou mais minerais em proporções também desconhecidas, e o fluido nos poros apresenta parâmetros muito distintos dos da água.

A fim de determinar-se a porosidade, necessita-se de mais dados do que aqueles produzidos por uma única ferramenta, uma vez que as medições realizadas pelas ferramentas de porosidade são sensibilizadas diferentemente pela litologia, pelo tipo de fluido e geometria da estrutura porosa. Pode-se utilizar combinações destas ferramentas com o propósito de se determinar a matriz e uma melhor estimativa da porosidade.

Uma forma adequada de se representar a associação de medidas, ocorre através dos chamados gráficos de porosidade, que mostram como várias combinações de medidas são sensibilizadas pela litologia e pela porosidade. Além disso, proporcionam uma melhor percepção visual das diversas combinações de minerais que formam a rocha que está sendo investigada.

A sensibilidade dos perfis de porosidade, em relação à matriz e à porosidade das rochas, é expressa através da equação (2.2), na qual a propriedade física registrada pela ferramenta (P) é representada por uma combinação linear destas mesmas propriedades, medidas isoladamente na matriz (P_m) e no fluido contido no espaço poroso (P_f), ponderadas pela porosidade (ϕ). Assim, podemos escrever,

$$P = \phi P_f + (1 - \phi) P_m . \quad (2.2)$$

A solução simultânea para a determinação da matriz e da porosidade, requer a utilização das medidas realizadas por, pelo menos, duas ferramentas, na forma de um sistema linear com duas equações e duas incógnitas, ou seja,

$$\begin{cases} P_1 = \phi P_{1f} + (1 - \phi) P_{1m} \\ P_2 = \phi P_{2f} + (1 - \phi) P_{2m} \end{cases} \quad (2.3)$$

A solução do sistema de equações (2.3) é obtida separadamente para cada uma das litologias características das rochas reservatório, na forma $P_1=f(P_2)$, onde f representa uma função linear. A obtenção de cada reta dá-se pela substituição, no sistema (2.3), dos valores característicos da matriz (Tabela 2) e da água, com a subsequente eliminação da porosidade. A representação gráfica desta solução é vista nos chamados gráficos de porosidade, onde cada reta é escalonada em valores de porosidade, possibilitando assim uma avaliação conjunta da litologia e da porosidade para um par ordenado das medidas provindas de dois perfis de porosidade, a uma mesma profundidade.

Tabela 2: Propriedades físicas da matriz.

MATRIZ	$\Delta t_m (\mu s / ft)$	$\rho_{bm} (g / cm^3)$	$\phi_{Nm} (\%)$
Quartzo	55.5	2.65	-0.02
Calcita	47.5	2.71	0
Dolomita	43.5	2.86	0.04

2.3.1 Gráfico $\rho_b - \Delta t$

É o gráfico que mostra a resposta da associação entre as ferramentas de densidade e sônica para as litologias mais comuns, considerando água doce nos poros, como mostrado pelo sistema de equações (2.4),

$$\begin{cases} \rho_b = \phi\rho_{bw} + (1-\phi)\rho_{bm} \\ \Delta t = \phi\Delta t_w + (1-\phi)\Delta t_m \end{cases}, \quad (2.4)$$

na qual ρ_b representa a densidade da rocha lida no perfil, ϕ é a porosidade, ρ_{bw} é a densidade da água, ρ_{bm} é a densidade da matriz, Δt é o tempo de trânsito lido no perfil, Δt_w é o tempo de trânsito na água e Δt_m é o tempo de trânsito na matriz. A solução deste sistema de equações é mostrada na Figura 2.4, para cada uma das três litologias que compõem as rochas reservatórios.

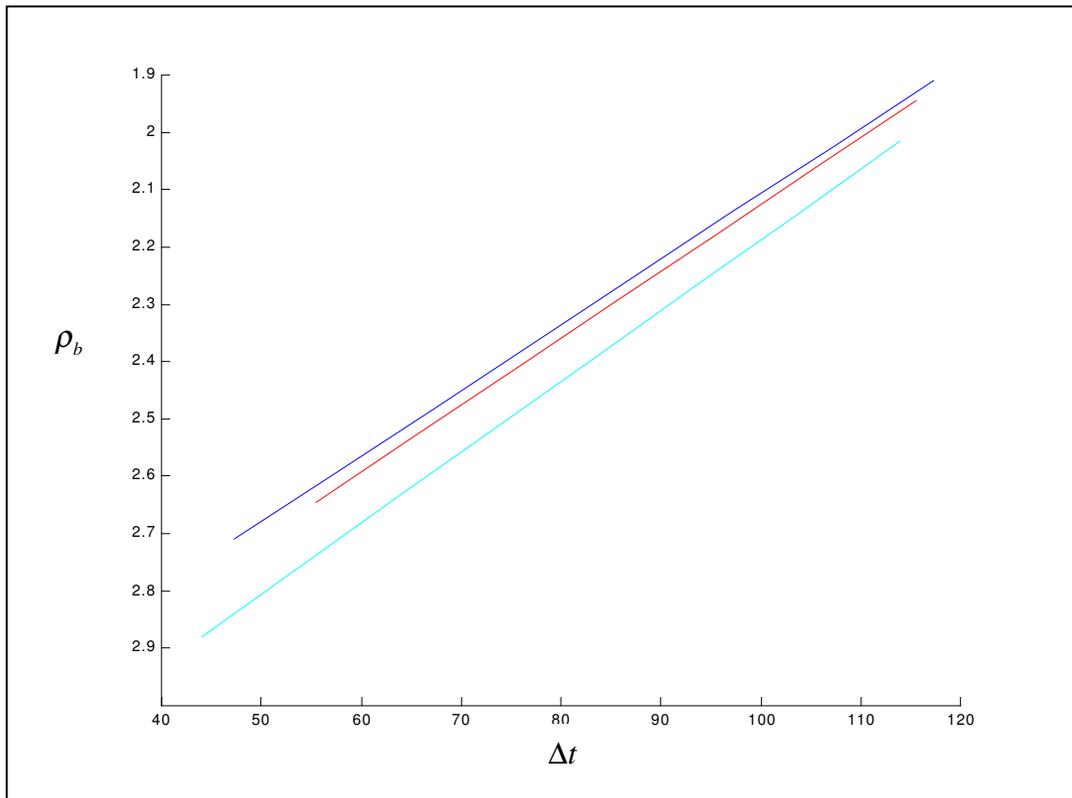


Figura 2.4: Gráfico densidade-sônico. Variações de porosidade nos três tipos de rochas reservatórios, produzem variações no tempo de trânsito da onda compressional e na densidade da formação. A reta azul representa o calcário, a vermelha representa o arenito e a verde representa a dolomita.

2.3.2 Gráfico $\phi_N - \Delta t$

Este gráfico é a representação da solução do sistema de equações (2.5), utilizando os perfis neutrônico (ϕ_N) e sônico (Δt), para cada uma das litologias mais comuns nas rochas sedimentares.

$$\begin{cases} \phi_N = \phi \phi_{Nw} + (1 - \phi) \phi_{Nm} \\ \Delta t = \phi \Delta t_w + (1 - \phi) \Delta t_m \end{cases} \quad (2.5)$$

Na equação (2.5), ϕ_N representa o valor da porosidade neutrônica lido no perfil, ϕ é a porosidade, ϕ_{Nw} é a porosidade neutrônica na água, ϕ_{Nm} é a porosidade neutrônica na matriz rochosa, Δt é o tempo de trânsito lido no perfil, Δt_w é o tempo de trânsito na água e Δt_m é o tempo de trânsito na matriz. Devido ao efeito da matriz, percebido pela ferramenta neutrônica, as três curvas possuem agora uma maior separação entre elas, como mostra a Figura 2.5.

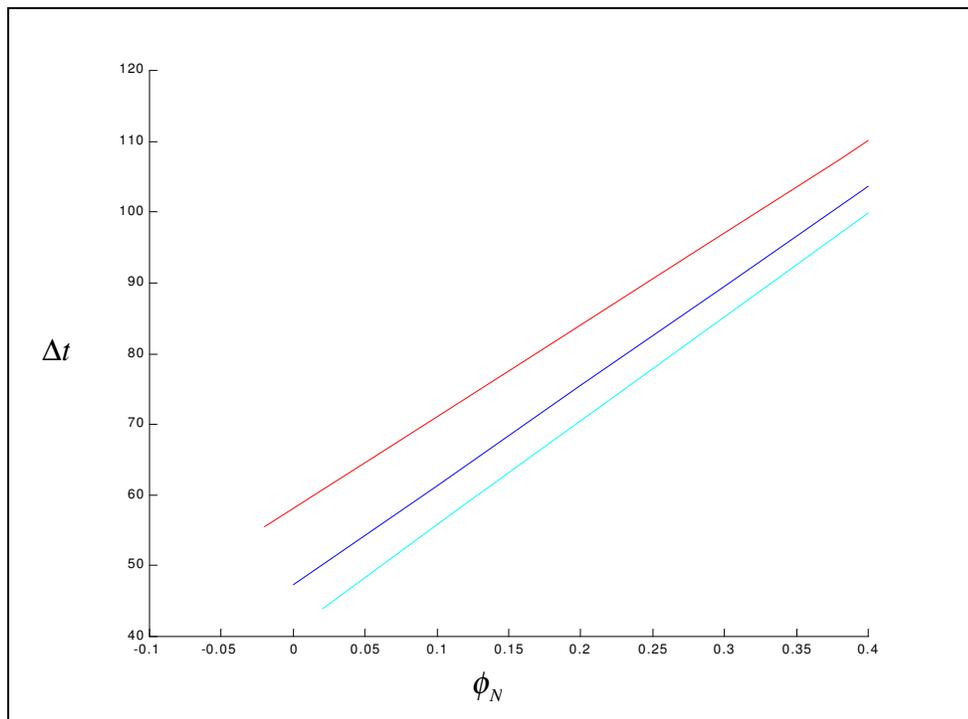


Figura 2.5: Gráfico neutrônico-sônico para determinação da porosidade, onde pode-se observar uma melhor distribuição das curvas para a discriminação da litologia. A reta vermelha representa o arenito, a azul representa o calcário e a verde representa a dolomita.

2.3.3 Gráfico $\rho_b - \phi_N$

O gráfico $\rho_b - \phi_N$ (densidade-neutrônico), Figura 2.6, é o gráfico padrão para a interpretação de misturas binárias. Neste caso, a densidade da rocha é expressa como uma função da porosidade aparente do calcário. Este gráfico é a representação da solução do sistema de equações 2.6.

$$\begin{cases} \rho_b = \phi \rho_{bw} + (1 - \phi) \rho_{bm} \\ \phi_N = \phi \phi_{Nw} + (1 - \phi) \phi_{Nm} \end{cases} \quad (2.6)$$

No sistema (2.6), ρ_b representa a densidade da rocha lida no perfil, ϕ é a porosidade, ρ_{bw} é a densidade da água, ρ_{bm} é a densidade da matriz, ϕ_N é o valor da porosidade neutrônica lido no perfil, ϕ_{Nw} é a porosidade neutrônica na água e ϕ_{Nm} é a porosidade neutrônica na matriz rochosa.

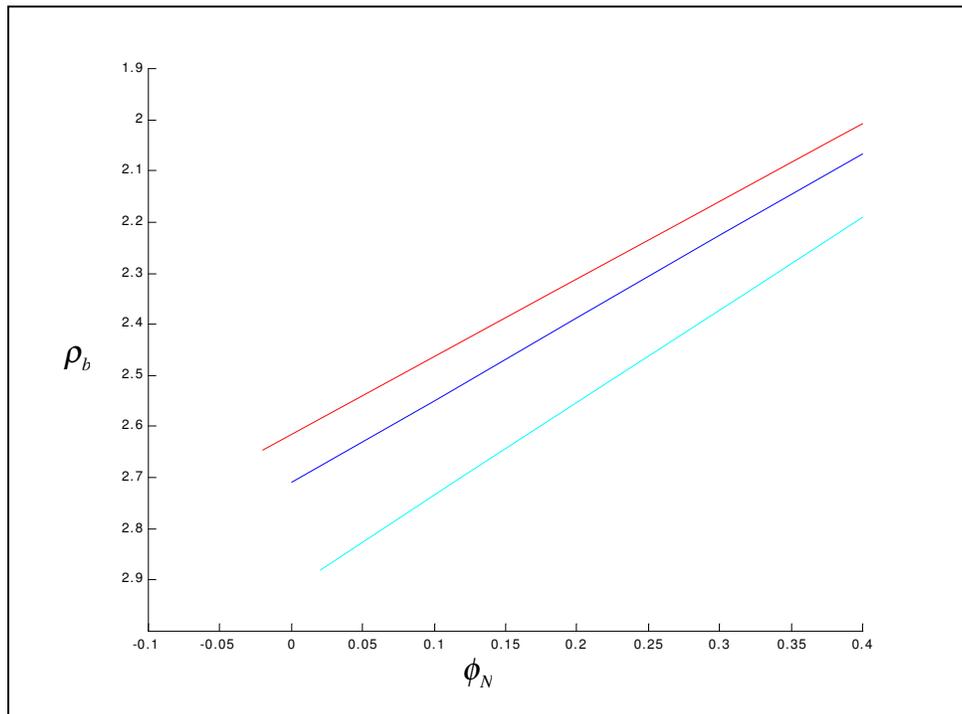


Figura 2.6: Gráfico densidade-neutrônico para a determinação da litologia e porosidade em litologias simples. A reta vermelha representa o arenito, a azul representa o calcário e a verde a dolomita.

3 REDES NEURAIS ARTIFICIAIS

3.1 INTRODUÇÃO

Por várias décadas a ciência tem alcançado um considerável progresso no desenvolvimento de máquinas ditas “inteligentes”. Essas máquinas seriam destinadas a executar tarefas com a habilidade de poder aperfeiçoar, no tempo, as suas próprias operações. Entre as tecnologias empregadas para alcançar esse objetivo pode-se citar a matemática biofísica, a cibernética, a automática, a biocibernética, a teoria geral de sistemas, os sistemas auto-organizativos, a inteligência artificial, a ciência cognitiva e os sistemas neurais artificiais, também conhecidos por redes neurais artificiais.

A criação de algoritmos para os sistemas neurais é motivada pelo reconhecimento de que o cérebro humano trabalha de forma inteiramente diferente que os computadores digitais convencionais, operando sob algoritmos seqüenciais (Haykin, 2001). Assim, a idéia fundamental das redes neurais artificiais é a de simular, por meio de algoritmos, o comportamento do cérebro humano, quando este trabalha na solução de problemas triviais, mas que apresentam um tratamento bastante complexo e oneroso nos computadores convencionais.

A história das redes neurais artificiais tem como marco inicial o ano de 1943, quando Warren Mcculloch, um neurofisiologista, e Walter Pitts, um matemático de apenas 18 anos de idade, escreveram um artigo intitulado “*about how neurons might work*” (Mcculloch & Pitts, 1943). Eles modelaram uma rede neural simples com circuitos elétricos. Dessa forma, eles conseguiram montar o primeiro modelamento matemático de uma rede neural, que era capaz de processar dados, mas não era capaz de aprender com estes dados.

Seis anos depois, em 1949, uma outra grande contribuição foi dada para o crescimento das redes neurais artificiais por Donald Hebb, quando tornou público o livro denominado “*The organization of behavior*” (Hebb, 1949), onde o mesmo propôs um esquema de aprendizagem para atualização das conexões entre neurônios, resultando na elaboração da regra que hoje é conhecida como “regra de aprendizagem de Hebb”.

Na década de cinquenta, com os aperfeiçoamentos em “hardware” e “software”, os computadores de segunda geração foram construídos e deu-se também nessa época a primeira construção física de uma rede neural artificial, por Edmonds e Minsky (Minsky, 1954). Ainda nessa década, McClelland defende a idéia de que a representação do conhecimento no cérebro

faz-se de maneira distribuída (McClelland, 1986). Deste modo, a responsabilidade de armazenar um determinado conceito não fica a cargo de uma única unidade, mas sim de um grupo de unidades (neurônios).

Pesquisadores do laboratório de pesquisa da IBM conduziram uma simulação em “software” de um modelo de rede neural baseado no trabalho de Hebb, em 1950. A primeira tentativa falhou, mas com a colaboração de Hebb e outros, adaptações foram feitas com sucesso.

Nos anos seguintes, John Von Neumann escrevendo material para seu livro “*The Computer and the Brain*” (Von Neumann, 1958), faz sugestões de imitar-se as funções de um simples neurônio, usando relés de telégrafo e válvulas eletrônicas. Frank Rosenblatt (Rosenblatt, 1958) apresenta o “*Perceptron*”, um modelo de rede neural que prometeu bastante, na medida em que era capaz de aprender padrões e generalizar a partir dos padrões aprendidos, pela modificação dos pesos das conexões. Esta idéia foi uma das maiores contribuições à teoria de redes neurais artificiais, servindo como base para os algoritmos de aprendizagem que hoje são estudados.

Em 1959, Bernard Widrow e Marcian Hoff (Stanford) desenvolveram os modelos de rede ADALINE e MADALINE (Multiple ADaptive LINear Elements) (Widrow & Hoff, 1960). Esta foi a primeira rede neural no mundo aplicada à um problema real: filtros adaptativos para eliminar ecos (ruídos) sobre os sinais telefônicos. Eles introduziram uma nova regra de aprendizagem chamada “*Widrow-Hoff learning rule*” (Widrow & Hoff, 1966). Essa regra minimizava o somatório dos quadrados dos erros, durante o treinamento envolvendo classificação de padrões. Mais tarde a ADALINE foi usada com sucesso para o processamento adaptativo de sinais (Widrow et al., 1963; Widrow et al., 1973; Widrow et al., 1975; Widrow & Stearns, 1985), sistemas de controle (Widrow & Smith, 1964; Widrow, 1988), e sistemas adaptativos de antena (Widrow et al., 1967).

Steinbuch, em 1961, foi um dos primeiros pesquisadores a desenvolver o método da codificação da informação em um sistema neural artificial. O método foi aplicado a problemas, tais como: reconhecimento de caracteres altamente distorcidos escritos à mão, diagnósticos de falhas mecânicas e etc. (Steinbuch & Piske, 1963; Steinbuch & Zendej, 1963).

Apesar dos vários sucessos obtidos e entusiasmo dos pesquisadores no início e meados da década de 60, houve um esfriamento à corrida das redes neurais artificiais. Com a publicação do livro “*Perceptrons*”, por Minsky & Papert (Minsky & Papert, 1969), aumentaram-se as dúvidas

a respeito do potencial das redes neurais. Nesta obra, os autores provam, formalmente, a incapacidade dos perceptrons de aprenderem funções como, por exemplo, um simples XOR. Mostram também a existência de máximos e mínimos locais que poderiam ser encontrados durante o processo de aprendizagem e que certamente conduziriam à um processo de aprendizagem insatisfatório.

Mesmo com o ritmo desacelerado das pesquisas em redes neurais artificiais, a área de inteligência artificial continuou sendo alvo dos pesquisadores. Um dos maiores pesquisadores e que mais influenciou nas pesquisas de redes neurais artificiais, da década de 60 até os dias atuais, é Stephen Grossberg (Boston University). Em 1964, Stephen Grossberg estudou exhaustivamente os processos psicológicos (mente), biológicos (cérebro) e fenômenos do processamento da informação humana, unindo-os dentro de uma teoria unificada (Grossberg, 1964). Ele divulgou vários estudos sobre o paradigma das redes neurais artificiais, analisando formalmente aspectos do modelo de aprendizagem por competição (Grossberg, 1970; 1972; 1973; 1978 e 1987), teoria da ressonância adaptativa (Grossberg, 1976), implementação binária (Carpenter & Grossberg, 1986; 1987) e implementação analógica (Carpenter & Grossberg, 1987).

Com o passar dos anos muitos outros pesquisadores continuavam a trabalhar na teoria de sistemas neurais artificiais. Shun-Ichi Amari é um desses pesquisadores. Ele realizou estudos sobre a aprendizagem competitiva em redes e da teoria matemática das redes neurais (Amari, 1977; 1983). Kumihiko Fukushima também contribui para o avanço tecnológico das redes neurais artificiais. Em seu mais notável trabalho desenvolveu uma classe de redes neurais chamada de “*neocognitron*” (Fukushima et al., 1983), aplicada ao reconhecimento de padrões visuais.

A partir da década de 70, Tuevo Kohonen realizou pesquisas em memória associativa (Kohonen, 1984). Paralelamente outros pesquisadores como Anderson (Anderson et al., 1977) e Steinbuch também o fizeram. Nesta mesma década Rumelhart & McClelland combinando seus esforços, inspirados pelo sistema de reconhecimento de voz “*HEARSAY*” da Universidade de Stanford, começaram seus trabalhos investigando as redes neurais artificiais pela formulação de um modelo semi-paralelo do processo mental. Posteriormente, Rumelhart & McClelland (1986) estenderam suas pesquisas para outras arquiteturas de redes neurais artificiais. Usaram o Processamento Paralelo e Distribuído (PDP) para descreverem seus trabalhos. Eles formaram um grupo de pesquisadores dedicados a estudar a estrutura mental da cognição. Os esforços do grupo

de pesquisa PDP removeram a maior barreira existente para o treinamento de redes, através da introdução de novos conceitos e regras de aprendizagem.

A partir da década de 80 as redes neurais artificiais já mostravam grande parte do seu potencial. Em 1982, o interesse em redes neurais artificiais uma vez amadurecido, foi renovado. E vários eventos convergiram para fazer desta o pivô central do ano. Partiu-se então, decisivamente, para a área da aplicação prática. Robert Hecht-Nielsen, fundador de um programa de pesquisas sobre neurocomputação, construiu dois neurocomputadores dedicados ao paradigma das redes neurais artificiais, contribuindo de forma significativa em vários aspectos: engenharia, pesquisas, instrução e comercialização. Como instrutor, foi um dos primeiros a oferecer um curso que apresentava o teorema que prevê a convergência do algoritmo “*backpropagation*” para uma larga faixa de mapeamento e como empresário, formou sua própria companhia dedicada a por em prática aplicações reais de Sistemas Neurais Artificiais (Hecht-Nielsen, 1987).

A partir de então, vários programas de redes neurais artificiais foram desenvolvidos. John Hopfield apresentou seu artigo sobre redes neurais artificiais à Academia Nacional de Ciências dos Estados Unidos, mostrando que as redes neurais podiam encontrar mínimos de energia e, com isso, dar soluções a complicados problemas de otimização. A partir da análise global feita por Hopfield, criou-se um grande interesse em aplicações ao paradigma das redes neurais artificiais. A lista das aplicações que podem ser resolvidas pelo uso das redes neurais artificiais cresceu a partir da resolução de pequenos problemas para grandes aplicações práticas.

A história das redes neurais artificiais embora tenha tido os seus momentos de crédito e descrédito, prevaleceu a perseverança dos pesquisadores em busca de conhecimentos, indo cada vez mais longe. Podemos dizer que esta história está apenas em seu primeiro estágio de desenvolvimento. “Conhecer suficientemente bem a inteligência e ser capaz de construir o seu modelo de trabalho, é certamente o mais excitante problema de desafio da raça humana” (McCordock, 1979).

3.2 O NEURÔNIO BIOLÓGICO

O neurônio biológico é a unidade fundamental constituinte do cérebro humano. Tipicamente, um neurônio biológico é mais lento que um “chip” de silício; no primeiro, os eventos ocorrem na ordem de 10^{-3} s, enquanto que no segundo são da ordem de 10^{-9} s (Sheperd & Koch, 1990). O cérebro contorna a aparente lentidão dos seus neurônios através da sua disposição espacial extremamente eficiente, a qual é baseada na sua intensa interconexão (Sheperd & Koch, 1990).

Para o estudo das redes neurais artificiais, as principais características morfológicas do neurônio biológico são o núcleo ou soma e os caminhos do fluxo dos sinais nervosos. Um típico neurônio pode ser exemplificado pela célula piramidal, comum no córtex cerebral, como mostrada na Figura 3.1, onde o corpo principal da célula, o núcleo, é o único responsável pelo processamento dos estímulos nervosos, de natureza eletroquímica, que chegam até ele. O soma é composto por uma simples unidade processadora, a qual recebe e combina sinais oriundos de muitos outros neurônios e os repassa a outros neurônios.

Esta classe de células possui dois tipos de caminhos para o fluxo da informação ou sinais nervosos, a saber:

- Dendritos
- Axônios

Os dendritos são os vários caminhos de entrada de informação ou estímulo e o axônio é o único caminho de saída percorrido pelo sinal. O axônio conecta-se aos dendritos de outros neurônios através de ligações chamadas sinapses, como destacado na Figura 3.1. A quantidade de informação transferida entre os neurônios depende unicamente da força desta ligação e, é exatamente a força da ligação sináptica que é modificada quando o cérebro aprende alguma nova informação oriunda do ambiente externo.

A operação normal das sinapses ocorre por meio de dois processos:

- Pré-sináptico
- Pós-sináptico

No primeiro, o impulso elétrico transforma-se em impulso químico, enquanto que no pós-sináptico, o impulso químico transforma-se em impulso elétrico.

De um modo simplificado, o neurônio recebe os estímulos de seu mundo exterior através de seus dendritos. A comunicação de um neurônio com o mundo externo depende da função do neurônio dentro do circuito neural. Se o neurônio estiver no nível de entrada, ou seja, for uma unidade que recebe os estímulos do mundo exterior, como por exemplo os neurônios da retina, no circuito da visão, a comunicação, pelo lado da entrada de estímulos (dendritos), é feita através de sua sensibilidade ao mundo exterior. Nesse caso, os neurônios que recebem os estímulos no nível de entrada, são algumas vezes denominados de ‘sensores nervosos’.

A comunicação interna entre neurônios é realizada através de *sinapses*, as quais são aberturas microscópicas, que relacionam dois neurônios. O impulso move-se do primeiro neurônio, que inicia um impulso no segundo e assim sucessivamente. Estes impulsos propagam-se somente em uma única direção, variando na razão de 10 à 120 metros por segundo. A seqüência é a seguinte: o fim de uma fibra nervosa (axônio) é estimulado até o limiar ou acima de sua sensibilidade; iniciam-se as trocas químicas e elétricas, que são os impulsos. O impulso, então, estende ao fim da fibra nervosa e pode induzir um impulso em outra célula nervosa, eventualmente resultando na ativação ou inibição fisiológica desse neurônio, a depender de seu nível particular de ativação.

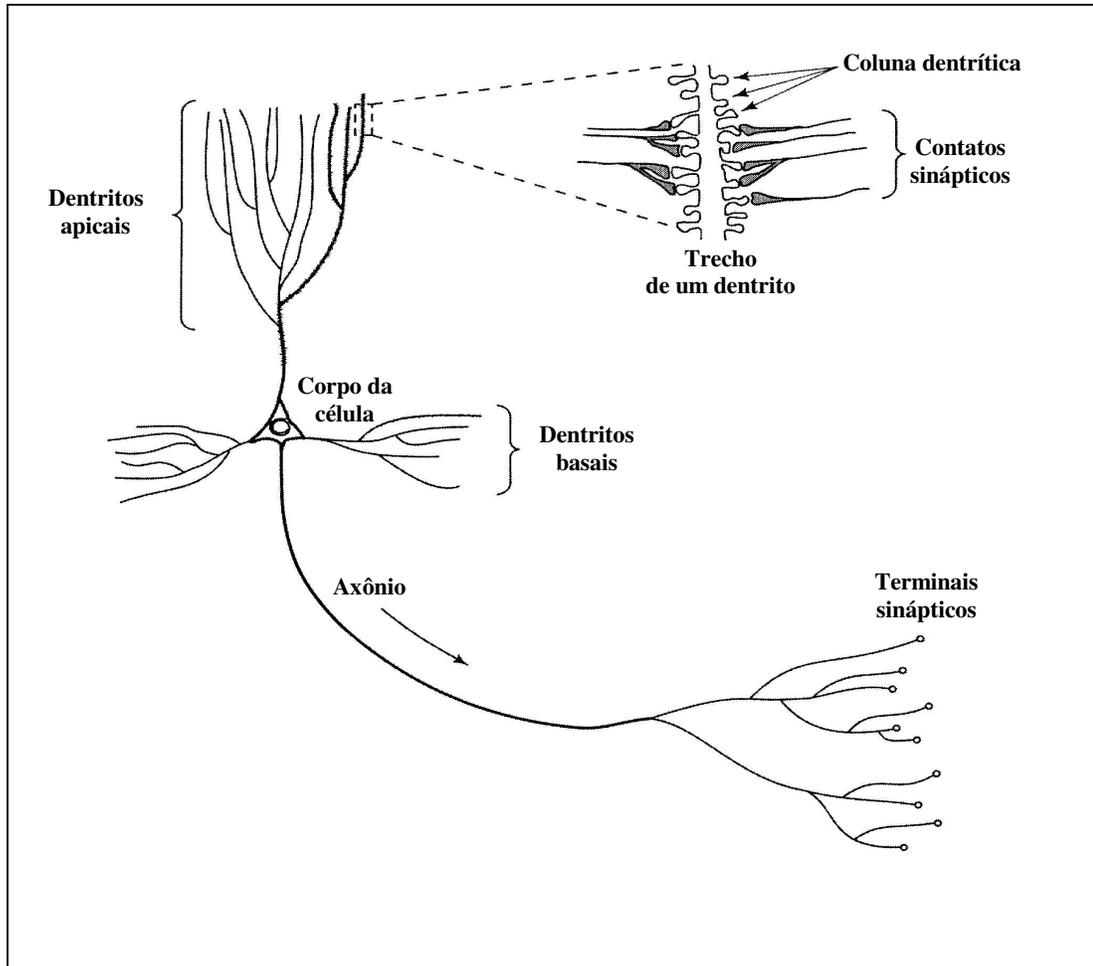


Figura 3.1: Neurônio biológico exemplificado pela célula piramidal, comum no córtex cerebral, mostrando os caminhos do fluxo do sinal (dendritos e axônio), o corpo da célula e, no detalhe, as microcavidades das ligações sinápticas (modificada de Haykin, 2001).

3.3 O NEURÔNIO ARTIFICIAL

O neurônio artificial é a unidade processadora fundamental para a computação das redes neurais artificiais. A Figura 3.2 mostra um modelo de um neurônio artificial típico, onde identificam-se os seus três componentes básicos:

1. Dendritos, representados pelo vetor de entrada. As sinapses, formadas por um especificado conjunto de valores (pesos). A existência de uma conexão entre dois neurônios quaisquer i e j é caracterizada por um peso w_{ij} , onde os subíndices i e j representam o ponto de chegada e o ponto de partida, respectivamente, de um sinal que percorre a rede. Podemos distinguir dois tipos de sinapses:

- a) Sinapse excitatória, onde $w_{ij} > 0$
- b) Sinapse inibitória, onde $w_{ij} < 0$

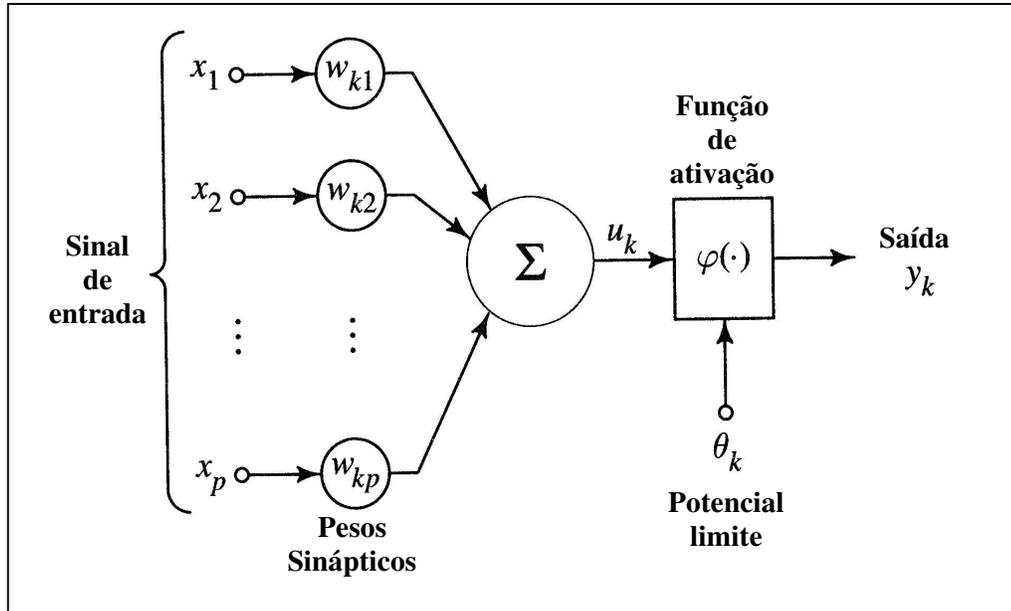


Figura 3.2: Modelo de um neurônio artificial típico, onde identificam-se os seus componentes básicos, em analogia ao neurônio biológico.

2. Núcleo, constituído por dois elementos:

2.1. O somador, que produz uma combinação linear entre os sinais de entrada e os pesos sinápticos.

2.2. A função de ativação, responsável pela limitação da amplitude do sinal de saída do neurônio. A amplitude está comumente no intervalo fechado de $[0,1]$ ou $[-1,1]$.

3. Axônio, representado pelo sinal de saída y_k .

O modelo do neurônio artificial, inclui também um parâmetro externo θ_i , o qual é um valor limite ou valor limiar (“treshold”), 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

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

$$y_k = \varphi (u_k - \theta_k) \quad (3.2)$$

onde, de acordo com a Figura 3.2, x_1, x_2, \dots, x_N são os sinais de entrada 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 . Na equação 3.2, φ representa a função de ativação responsável pela forma de quantização do sinal de saída (y_k), em um intervalo fechado pré-determinado. A utilização de um valor limite, θ_k , possui o efeito de aplicar uma transformação afim (Figura 3.3) sobre u_k , como mostra a equação (3.3), para o nível de atividade P_k .

$$P_k = u_k - \theta_k \quad (3.3)$$

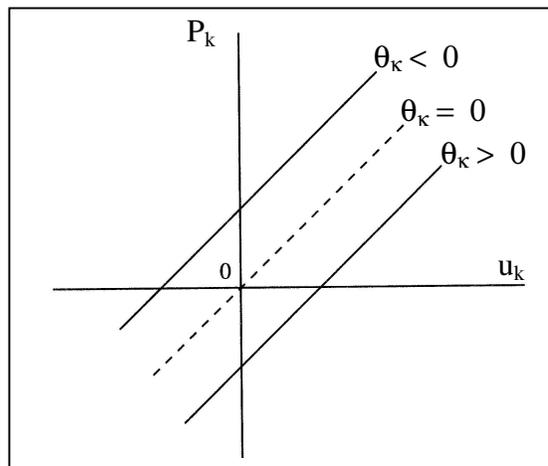


Figura 3.3: Transformação afim realizada pela introdução do termo θ_k (potencial limite).

3.4 REDE NEURAL COMPETITIVA

Na aprendizagem competitiva, como o nome implica, os neurônios da rede neural competem entre si para que apenas um deles esteja ativo. Neste tipo de rede, somente um único neurônio de saída está ativo em um determinado instante. É essa característica que torna a aprendizagem competitiva muito adequada para descobrir características estatisticamente relevantes, que podem ser utilizadas para classificar um conjunto de padrões de entrada. Existem três elementos básicos na regra de aprendizagem competitiva (Rumelhart & Zisper, 1985):

- Um conjunto de neurônios que são todos iguais entre si, exceto por alguns pesos sinápticos distribuídos aleatoriamente, e que por isso respondem diferentemente a um dado conjunto de padrões de entrada.
- Um limite imposto sobre a “força” de cada neurônio.
- Um mecanismo que permite que todos os neurônios compitam pelo direito de responder a um dado subconjunto de entradas, de forma que somente um neurônio, ou somente um neurônio por grupo particular, esteja ativo (i.e. “ligado”) em um determinado instante. O neurônio que vence a competição é denominado de neurônio vencedor.

Correspondentemente, os neurônios individuais da rede aprendem a se especializar em agrupamentos de padrões similares; fazendo isso, eles se tornam detetores de características para classes diferentes de padrões de entrada.

Na forma mais simples de aprendizagem competitiva, Figura 3.4, a rede neural tem uma única camada de neurônios competitivos, estando cada neurônio totalmente conectado aos nós de entrada e aos outros neurônios da camada por meio dos pesos sinápticos, que serão modificados no processo de treinamento da rede.

Na aprendizagem competitiva, os neurônios competitivos competem entre si por cada dado de entrada, para produzir um neurônio vencedor que carregará o sinal de saída. A cada instante de tempo, somente um neurônio competitivo está ativo (Haykin, 2001). Assume-se o sinal de saída, para o neurônio vencedor, como sendo 1 (um) e o sinal de saída de todos os outros neurônios competitivos sendo 0 (zero). A aprendizagem competitiva mais comum utiliza as regras de Kohonen (Kohonen, 1989), onde o neurônio competitivo que mais se assemelha ao vetor de entrada ganha a competição, e tem seus pesos sinápticos movidos para próximo do vetor de entrada. Então, cada neurônio competitivo tem seus pesos sinápticos migrando, progressivamente, para próximo do grupo dos vetores de entrada. Após algumas iterações a rede se estabiliza, tendo cada neurônio no centro da nuvem que ele representa. Se um neurônio qualquer não responde à um particular vetor de entrada, nenhuma aprendizagem irá acontecer ou, então, seus pesos sinápticos não serão alterados.

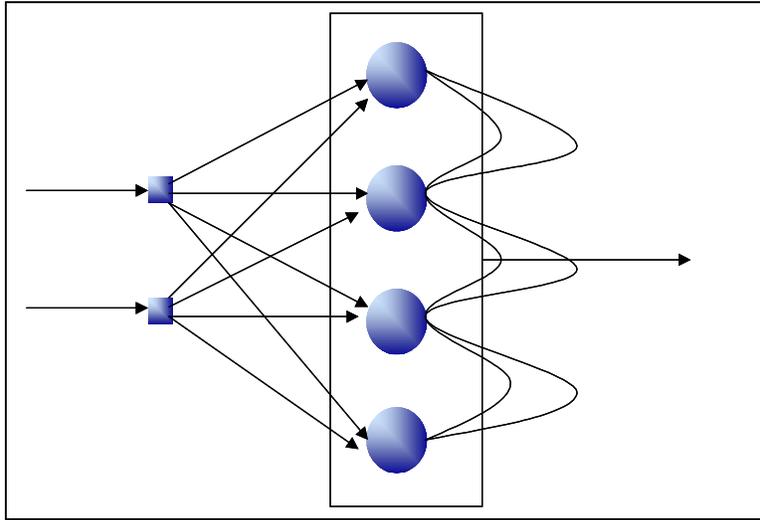


Figura 3.4: Arquitetura de uma rede neural competitiva simples, onde podemos observar a camada com os nós de entrada e a camada competitiva.

Para um neurônio k ser o neurônio vencedor, seu potencial de ativação u_k para um padrão de entrada especificado \mathbf{x} , deve ser o maior entre todos os neurônios da rede. O sinal de saída y_k do neurônio vencedor k é colocado em 1 (um); os sinais de saída de todos os neurônios que perdem a competição são colocados em 0 (zero). Com isso podemos escrever

$$y_k = \begin{cases} 1, & \text{se } u_k > u_j, \text{ para todos } j, j \neq k \\ 0, & \text{caso oposto} \end{cases} \quad (3.4)$$

onde o potencial de ativação u_k representa a ação combinada de todas as entradas diretas e realimentadas do neurônio k .

Considere que w_{kj} represente o peso sináptico conectando o nó de entrada j ao neurônio k . Suponha que a cada neurônio seja alocada uma quantidade fixa de peso sináptico (i.e., todos os pesos sinápticos são positivos), que é distribuída entre seus nós de entrada, ou seja,

$$\sum_j w_{kj} = 1, \text{ para todo } k. \quad (3.5)$$

Um neurônio, então, aprende ao deslocar pesos sinápticos de seus nós de entrada inativos para os seus nós ativos. Se um neurônio não responde a um padrão de entrada particular, então não ocorrerá aprendizado naquele neurônio. Se um neurônio particular vencer a competição, então cada nó de entrada deste neurônio libera uma certa proporção de seu peso sináptico e este peso liberado será, então, distribuído uniformemente entre os nós de entrada ativos. De acordo

com a regra de aprendizagem competitiva padrão, a variação Δw_{kj} aplicada ao peso sináptico w_{kj} é definida por

$$\Delta w_{kj} = \begin{cases} \eta(x_j - w_{kj}), & \text{se o neurônio } k \text{ vencer} \\ 0 & , \text{ se o neurônio } k \text{ perder} \end{cases} \quad (3.6)$$

onde η é o parâmetro taxa de aprendizagem. Esta regra tem o efeito global de mover o vetor de peso sináptico w_k do neurônio vencedor k em direção ao padrão de entrada x .

A análise dos dados realizada por este tipo de rede neural é comumente chamada de esquema descobridor de características, o qual realiza a separação em nuvens ou quantização do espaço de entrada (Saggaf & Nebrija, 2000) e pode ser utilizada para detectar padrões estatisticamente significantes no espaço de entrada e classificá-los (Haykin, 2001).

3.5 REDE NEURAL DE FUNÇÃO DE BASE RADIAL

Neste item, tomamos um enfoque totalmente diferente ao ver o projeto de uma rede neural como um problema de ajuste de curva (aproximação). De acordo com este ponto de vista, aprender é equivalente a encontrar uma superfície, em um espaço multidimensional, que forneça o melhor ajuste para os dados de treinamento, com o critério de “melhor ajuste” sendo medido em um sentido estatístico.

No contexto de uma rede neural, as unidades ocultas oferecem um conjunto de “funções” que constituem uma “base” arbitrária para os padrões (vetores) de entrada, quando eles são expandidos sobre o espaço oculto: estas funções são chamadas de *funções de base radial*.

A construção de uma rede neural de função de base radial (RBF), em sua forma mais básica, envolve três camadas com papéis totalmente diferentes (Figura 3.5). A camada de entrada é constituída por unidades sensoriais que conectam a rede ao seu ambiente. A segunda camada, a única camada oculta da rede, aplica uma transformação não-linear do espaço de entrada para o espaço oculto; na maioria das aplicações o espaço oculto é de alta dimensionalidade. A camada de saída é linear, fornecendo a resposta da rede ao padrão (sinal) de ativação aplicado à camada de entrada. Uma justificativa matemática para a estratégia de uma transformação não-linear seguida de uma transformação linear remonta a um artigo original de Cover, em 1965 (Haykin, 2001). De acordo com este artigo, um problema de classificação de padrões disposto em um espaço de alta dimensionalidade tem maior probabilidade de ser linearmente separável do que em

um espaço de baixa dimensionalidade, daí a razão de freqüentemente se fazer com que a dimensão do espaço oculto em uma rede RBF seja alta. Um outro ponto importante, é o fato de que a dimensão do espaço oculto está relacionada à capacidade da rede de realizar um mapeamento entrada-saída suave (Mhaskar, 1996; Niyogi & Girosi, 1996); quanto mais alta for a dimensão do espaço oculto, mais precisa será a aproximação.

As funções transferência ou funções de base radial, na camada oculta da rede, são similares à função Gaussiana multivariada

$$\varphi_j(x) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right), \quad (3.7)$$

onde j refere-se ao j -ésimo neurônio oculto, $\|x - c_j\|^2$ é a distância Euclidiana entre o vetor de entrada (x) e o centro da função de base radial (c_j) e σ_j é a sua largura.

A camada de saída é linear, dando as respostas da rede aos padrões de ativação aplicados na camada de entrada. A operação realizada na camada de saída é dada por

$$y_k(x) = \sum_{j=1}^N w_{kj} \varphi_j(x), \quad (3.8)$$

onde y_k é o k -ésimo neurônio de saída para o vetor de entrada x , w_{kj} é o peso sináptico entre o k -ésimo neurônio de saída e o j -ésimo neurônio oculto. Neste trabalho, limitaremos nossas considerações às funções Gaussianas com largura constante, as quais são as mesmas para todos os neurônios da camada oculta. O ajuste dos pesos sinápticos, na equação (3.8), é realizado através da solução dos mínimos quadrados, após a seleção dos centros e largura das funções de base radial, a partir das amostras do treinamento.

As redes neurais de função de base radial possuem as mesmas propriedades da rede neural que utiliza o algoritmo de retro-propagação do erro, tais como generalização e robustez. Elas, no entanto, têm a vantagem de possuir uma aprendizagem rápida e habilidade para detectar padrões complexos durante a estimação (Devaraj et al., 2002).

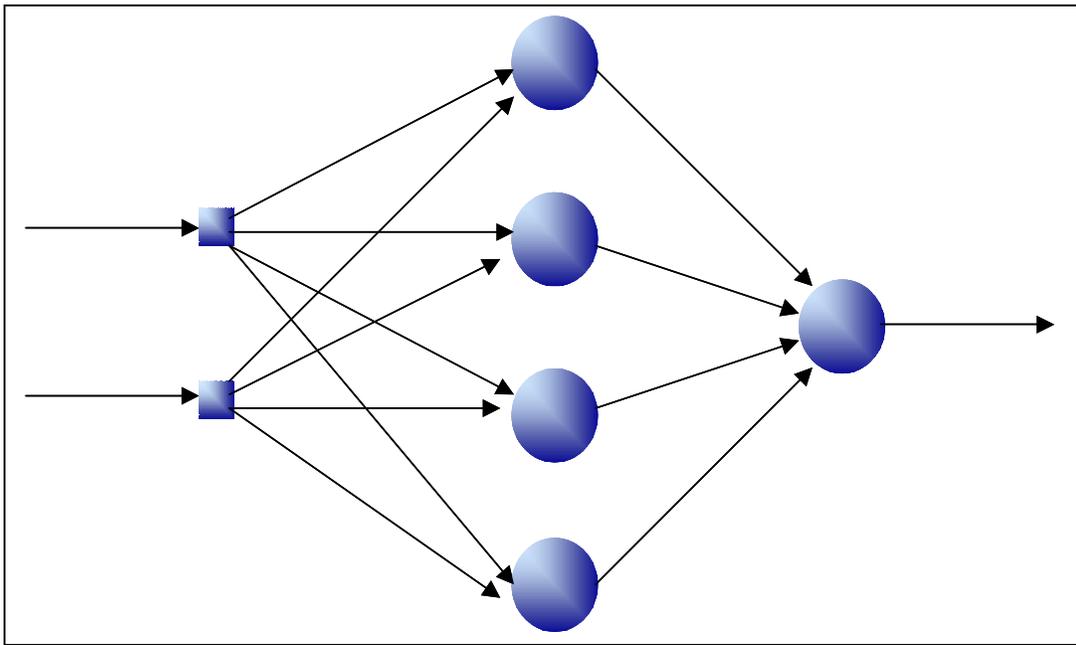


Figura 3.5: Arquitetura de uma rede neural com função de base radial, onde podemos observar a camada de entrada, composta por duas unidades sensoriais, a camada oculta, composta por quatro neurônios, e a camada de saída, composta por um neurônio .

4 IMAGEAMENTO DA POROSIDADE

4.1 INTRODUÇÃO

Para obtermos o imageamento da porosidade, construímos um algoritmo interpretativo composto por três processos sequenciais envolvendo as redes neurais artificiais. O primeiro processo toma como entrada os perfis de porosidade neutrônica e densidade para produzir o *perfil de porosidade*. Este perfil processado, obtido em um poço de referência, irá ditar a construção do conjunto de treinamento necessário no segundo processo. Este processo recebe como entrada um conjunto de perfis de poço convencionais (raio gama, densidade, porosidade neutrônica e volume de argila) e o perfil de porosidade para a obtenção das linhas de correlação ou as linhas que irão mostrar a estratigrafia do reservatório. Finalmente, o último processo utiliza toda a informação gerada nos processos anteriores para produzir o imageamento da porosidade ao longo da seção.

Esta metodologia é aplicada em três poços perfilados na formação Lagunillas, na bacia do Lago Maracaibo, Venezuela. Os poços são mencionados como Poço A, Poço B e Poço C. As profundidades absolutas e distâncias horizontais relativas não são indicadas nas figuras, mas o deslocamento horizontal relativo entre estes poços e a posição, em profundidade, de cada intervalo perfilado são mantidos. Na Figura 4.1 mostra-se a localização do Campo de Lagunillas, na bacia do Lago Maracaibo e, no detalhe, apresenta-se a coluna estratigráfica referente à Formação Lagunillas, caracterizada pela seqüência arenito-folhelho, sendo que os arenitos apresentam diferentes graus de contaminação por argila.

4.2 INTERPRETAÇÃO AUTOMÁTICA DO GRÁFICO DENSIDADE-NEUTRÔNICO

Apresentamos neste tópico o perfil de porosidade, que é a primeira parte do processo para a determinação do imageamento da porosidade, obtido através da interpretação automática do gráfico densidade-neutrônico ($\rho_b - \phi_N$). Construímos um algoritmo interpretativo, baseado na arquitetura das redes neurais competitivas, cujas entradas são compostas pelos perfis de densidade e neutrônico e a saída é o perfil de porosidade, que nos dá, concomitantemente, a litologia e a porosidade de cada trecho do perfil.

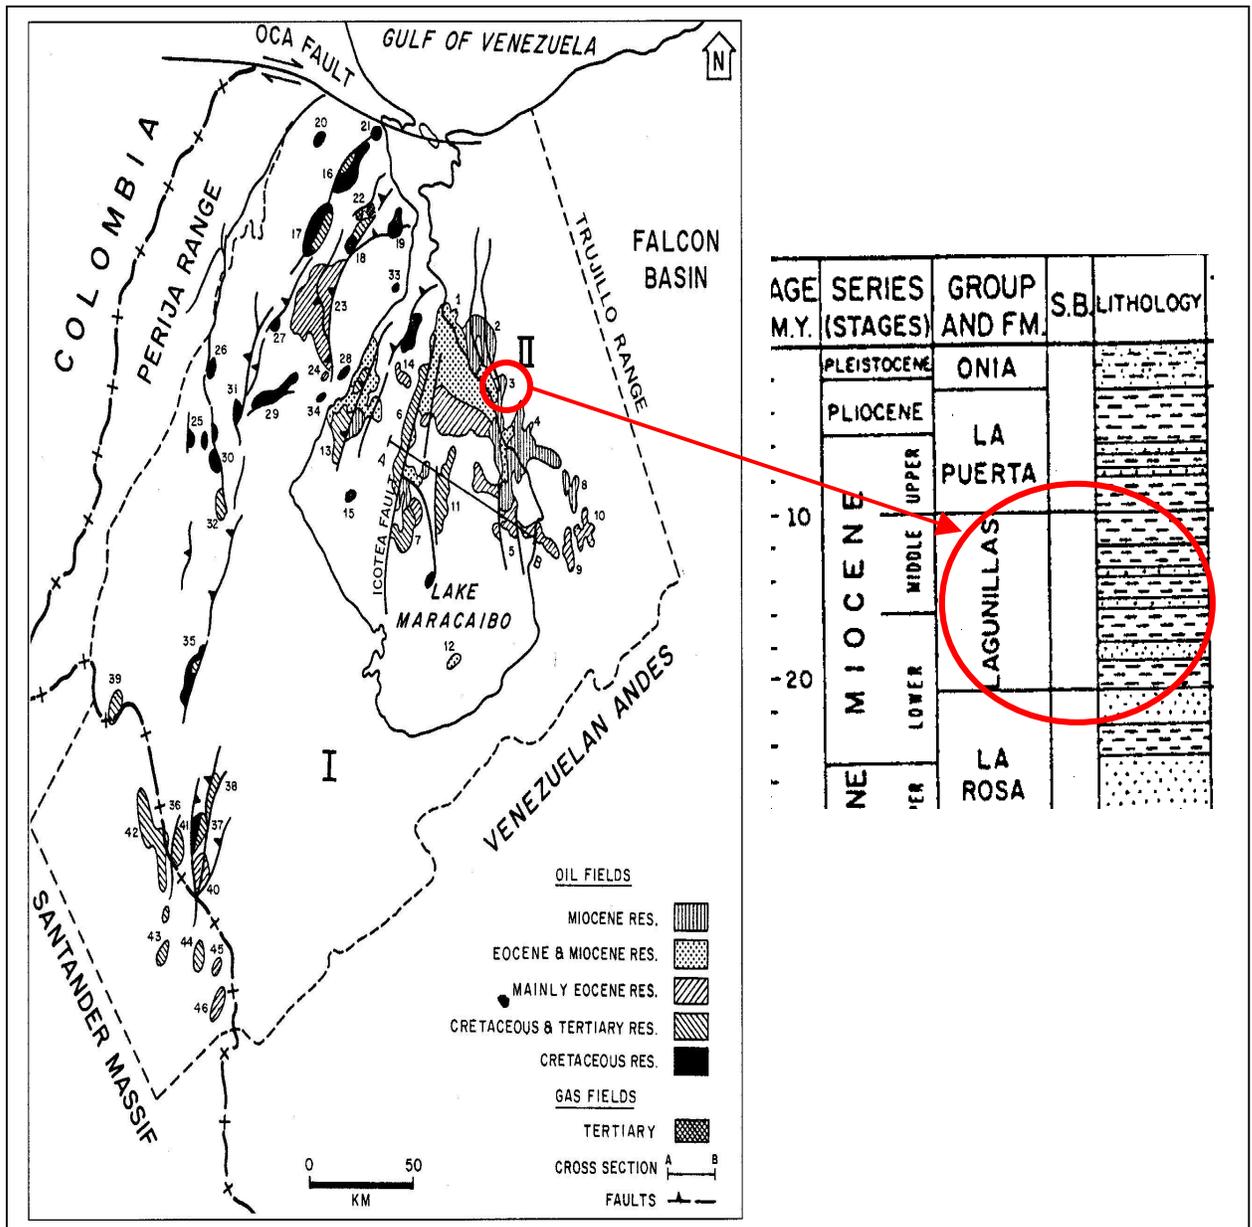


Figura 4.1: Localização do Campo de Lagunillas, na Bacia do Lago Maracaibo e, no detalhe, apresenta-se a coluna estratigráfica referente à Formação Lagunillas, caracterizada pela seqüência arenito-folhelho, sendo que os arenitos apresentam diferentes graus de contaminação por argila (modificada de Talukdar & Marcano, 1994).

4.2.1 Perfil de porosidade

O perfil de porosidade é composto por uma curva escalonada em unidades de porosidade, para cada litologia atravessada pelo poço. Construímos um algoritmo interpretativo, baseado na arquitetura das redes neurais competitivas, para a obtenção do perfil de porosidade. Este algoritmo interpretativo simula a interpretação do gráfico $\rho_b - \phi_N$, o qual recebe como entrada o perfil de porosidade neutrônica (ϕ_N) e o perfil de densidade (ρ_b).

Assumimos que o perfil de porosidade neutrônica está calibrado para arenito. Logo, a linha dos arenitos limpos, no gráfico $\rho_b - \phi_N$, obtido a partir do Poço A, é representada por uma linha reta, com 45° de inclinação, onde cada ponto caracterizado por um par-ordenado (ρ_b, ϕ_N) , representa um valor de porosidade para as amostras de arenito limpo (Figura 4.2).

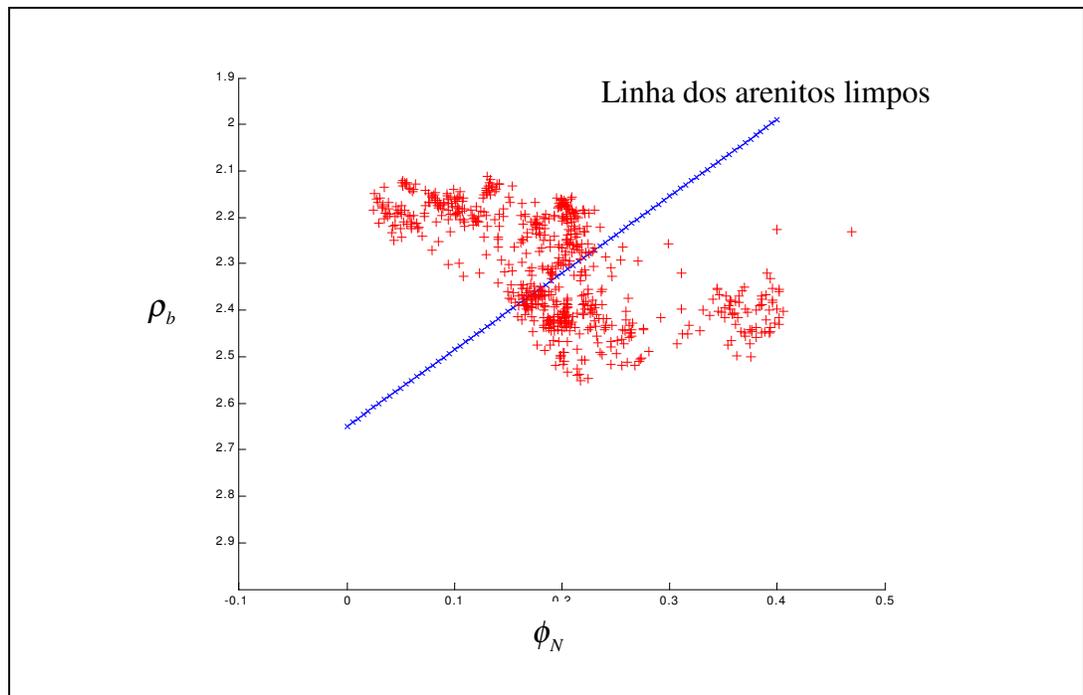


Figura 4.2: Gráfico $\rho_b - \phi_N$, obtido a partir do Poço A, onde as cruces representam os pares ordenados de entrada (ρ_b, ϕ_N) e a linha azul representa a linha dos arenitos limpos.

Cada ponto em profundidade, em cada perfil de entrada, representa um par-ordenado (ρ_b, ϕ_N) , ou um ponto no plano $\rho_b - \phi_N$. Se plotarmos estes pontos a partir de um intervalo de

profundidade selecionado, veremos que eles estão arranjados em agrupamentos. A partir do critério interpretativo do gráfico $\rho_b - \phi_N$ e considerando o modelo deposicional arenito-folhelho, podemos identificar dois importantes agrupamentos no plano $\rho_b - \phi_N$. As amostras de arenito limpo estão localizadas ao redor da linha dos arenitos limpos – os pontos do arenito. Os pontos do arenito podem mostrar uma dispersão ao redor da linha dos arenitos limpos por causa da presença de argila ou hidrocarboneto no espaço poroso, ou efeito da matriz – presença de alguma quantidade de feldspato, por exemplo. Um outro importante agrupamento está localizado distante da linha dos arenitos limpos, no canto inferior direito – são os pontos do folhelho, os quais representam os pontos de entrada, cuja matriz é dominada por folhelho.

Nosso primeiro interesse é construir uma rede neural competitiva para realizar o zoneamento do perfil, ou separar os pontos de matriz dominados por arenitos daqueles dominados pelo folhelho. Em outras palavras, queremos identificar o agrupamento, no plano $\rho_b - \phi_N$, correspondente ao folhelho.

A partir do conhecimento da posição da linha dos arenitos limpos e da localização relativa do agrupamento do folhelho, construímos uma rede neural competitiva com dois neurônios na camada de entrada; cada um recebe, como entrada, o perfil de densidade e o perfil de porosidade neutrônica para cada ponto em profundidade (Figura 4.3). Para este trabalho utilizamos quatro neurônios na camada competitiva, representando o arenito limpo (neurônio 1), o arenito sujo (neurônio 2), o arenito portador de hidrocarboneto (neurônio 3) e o folhelho (neurônio 4). O processo de treinamento inicia-se com os pesos sinápticos de todos os neurônios próximos do centro do plano $\rho_b - \phi_N$ e termina quando estes pesos estabilizam-se, próximos do centro de cada agrupamento (Figura 4.4). Naturalmente, em virtude do espalhamento dos pontos do arenito, e para evitar uma interpretação errônea dos pontos do arenito sujo com os pontos do folhelho, utilizamos mais neurônios para caracterizar o agrupamento do arenito.

Após o treinamento da rede competitiva, retemos os pesos sinápticos do neurônio que se estabiliza mais longe da linha dos arenitos limpos, em direção ao folhelho – o neurônio do folhelho. Os pesos sinápticos deste neurônio representam um ponto característico no plano $\rho_b - \phi_N$, o ponto do folhelho, que é utilizado para corrigir a porosidade do arenito em relação ao conteúdo de argila (Ellis, 1987) e este ponto tem uma função importante no zoneamento do perfil,

onde assumimos que este particular neurônio identifica, corretamente, o agrupamento do folhelho.

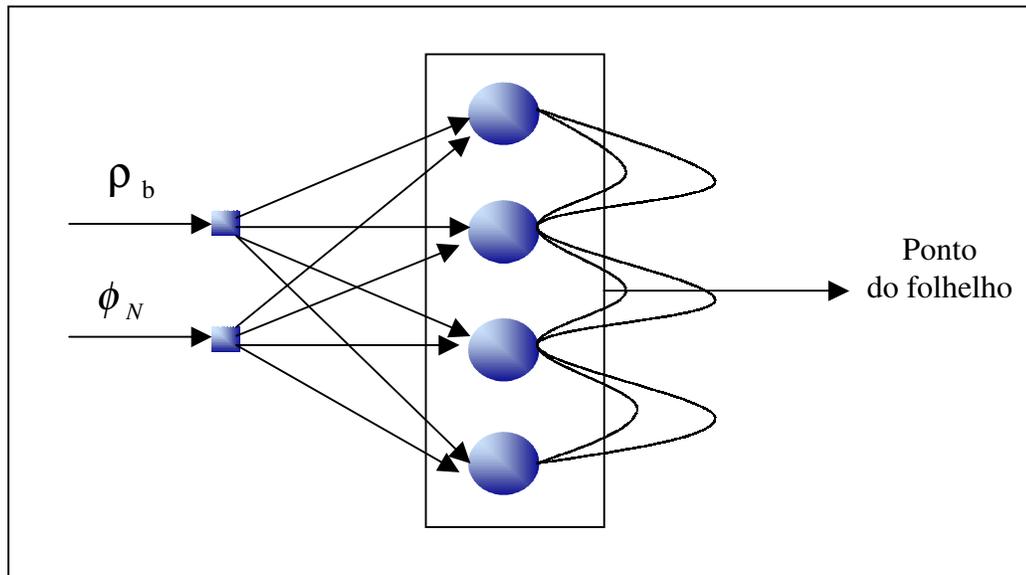


Figura 4.3: Arquitetura da rede neural competitiva para a obtenção do ponto do folhelho. A camada de entrada é composta por duas unidades sensoriais e a camada competitiva é composta por quatro neurônios competitivos.

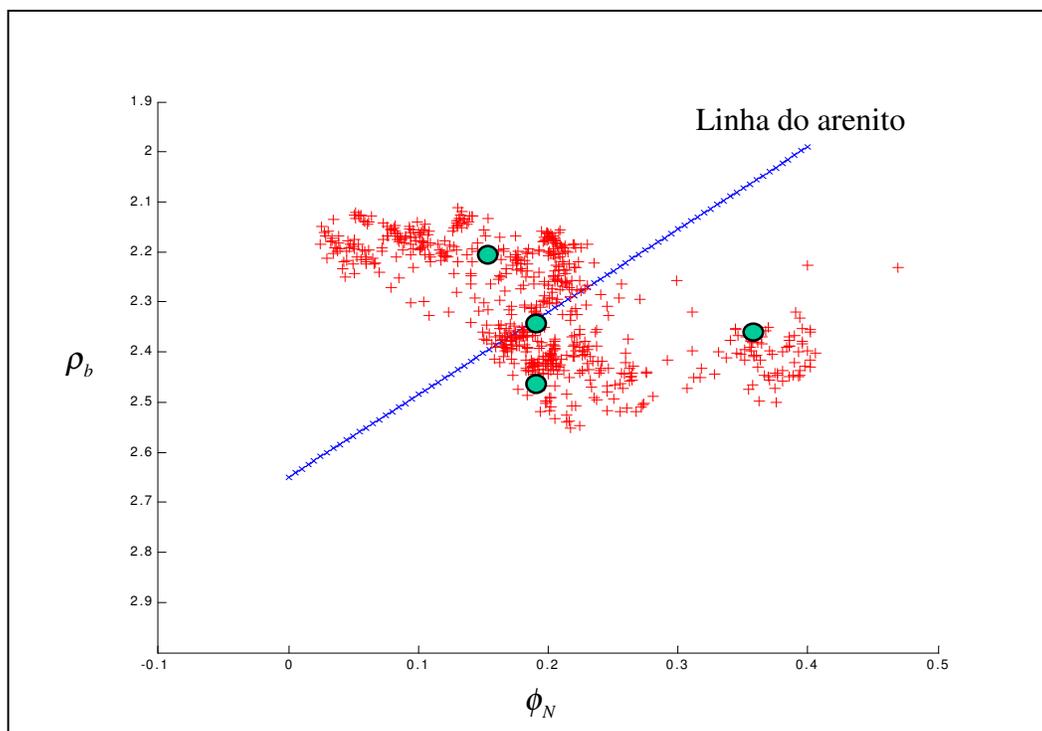


Figura 4.4: Posicionamento, após o treinamento, dos pesos sinápticos dos quatro neurônios da camada competitiva da rede neural, representados por círculos verdes, para o estabelecimento do ponto do folhelho.

Agora somos capazes de produzir o zoneamento e estimar as porosidades de um determinado intervalo do perfil. Para isso, introduzimos o conceito de linha do folhelho e damos uma interpretação geológica ao processamento da rede neural competitiva. Definimos a linha do folhelho, no gráfico $\rho_b - \phi_N$, como uma linha paralela à linha dos arenitos limpos que passa pelo ponto do folhelho, identificado anteriormente (Figura 4.5). A próxima etapa é a associação de um valor de porosidade a cada neurônio da camada competitiva. Isto significa que assumimos uma conveniente escala de porosidade e associamos cada par ordenado (ϕ_N, ρ_b) , de cada ponto da linha dos arenitos limpos e da linha dos folhelhos, como os pesos sinápticos que conectam cada neurônio da camada competitiva com os neurônios da camada de entrada. Assim, o número de neurônios na camada competitiva reflete a precisão na estimativa da porosidade (Figura 4.6).

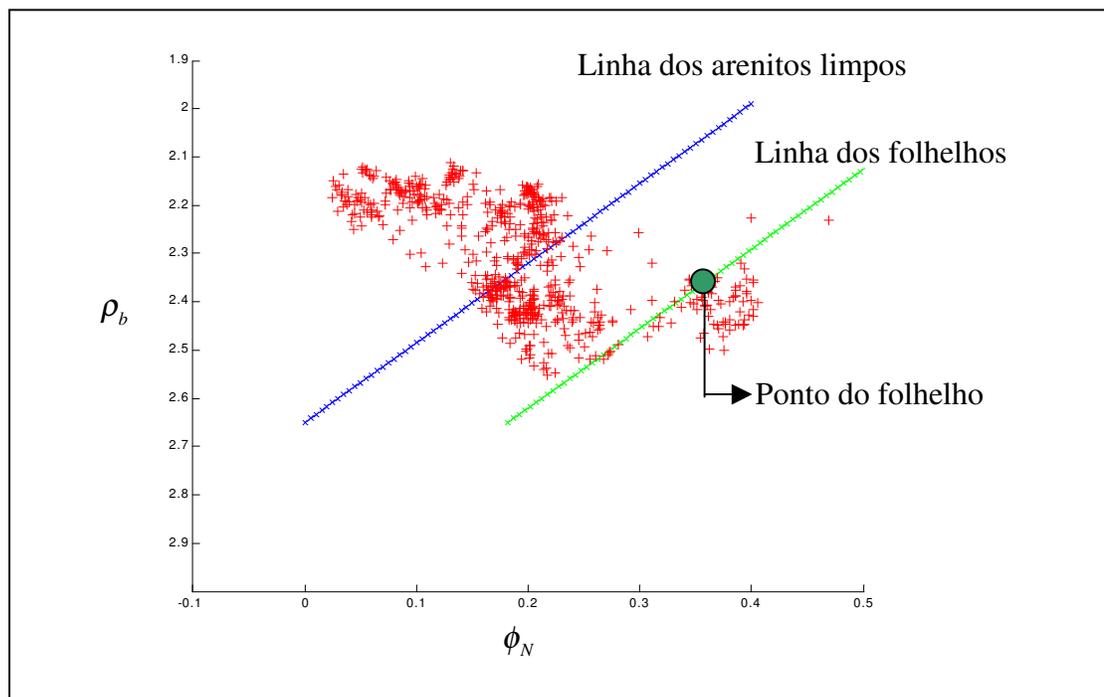


Figura 4.5: Gráfico $\rho_b - \phi_N$, obtido a partir do Poço A, o ponto verde representa o ponto do folhelho e a linha verde é a linha representativa dos folhelhos, que passa por este ponto.

Nesta aproximação, estimamos a porosidade com uma precisão de 0.01 unidades de porosidade (PU) e assumimos para os arenitos e folhelhos um intervalos de porosidade variando de 0 a 40 PU.

Para mostrar a construção e comportamento desta camada competitiva, consideremos, por exemplo, uma camada competitiva composta por 82 neurônios. Neste caso, a estimativa da porosidade tem uma precisão de 1 PU. Os neurônios estão ordenados em ordem crescente. Os primeiros 41 neurônios representam os pontos da linha dos arenitos limpos e os 41 neurônios restantes representam os pontos da linha dos folhelhos. Se o neurônio ordenado pelo número 20 ganha a competição para um particular dado de entrada, isto significa que este dado é proveniente do arenito e tem uma porosidade total igual a 19 PU. Para os folhelhos tomamos o mesmo mecanismo. Por exemplo, se o neurônio 65 ganha a competição, a sua porosidade é de 23 PU. Através desta analogia, podemos observar que a operação da rede neural é bastante simples. Cada par de dados de entrada força a competição entre todos os neurônios. O neurônio vencedor é aquele que tem os seus pesos sinápticos mais próximos do vetor de entrada. A posição do neurônio vencedor, na camada competitiva, dá-nos a litologia e o valor da porosidade do ponto, em profundidade, representado pelo par ordenado de entrada.

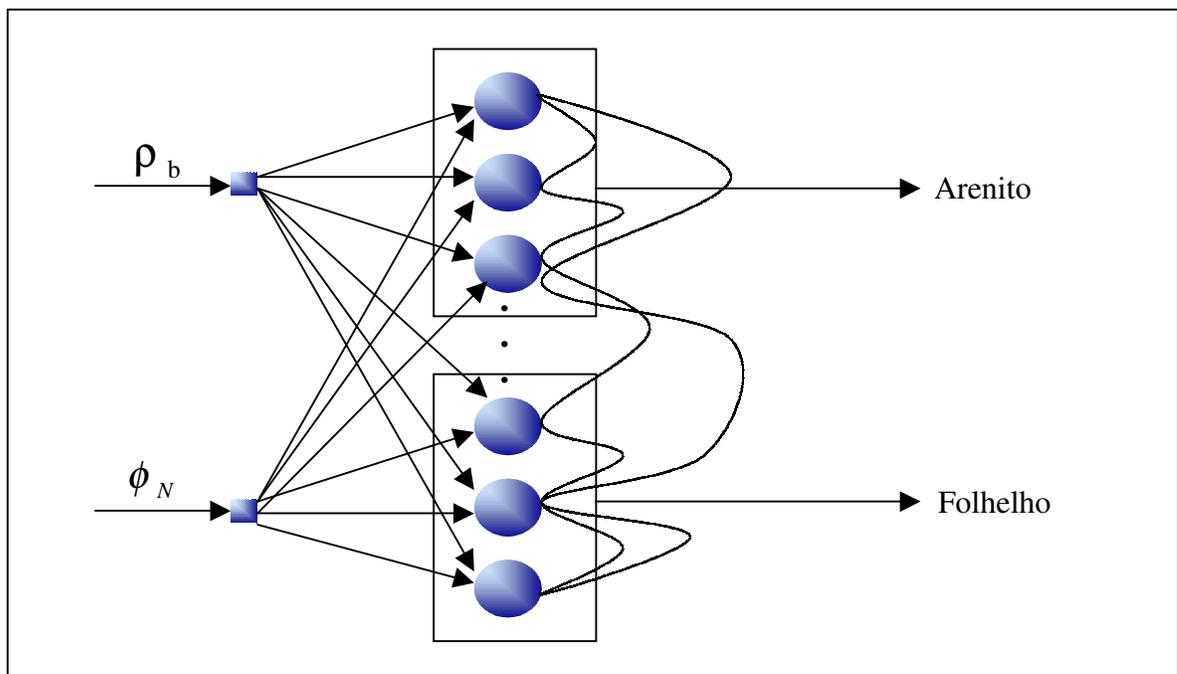


Figura 4.6: Arquitetura da rede neural competitiva para a obtenção do zoneamento do perfil. A camada de entrada é composta por duas unidades sensoriais e a camada competitiva é composta por oitenta e dois neurônios competitivos.

Como resultados das operações envolvidas neste algoritmo interpretativo, plotamos os valores da porosidade associados ao arenito, na segunda faixa, e os valores associados ao folhelho, na terceira faixa. Na primeira faixa temos o perfil de raios gama, que mostra a validade dos resultados obtidos nos perfis de porosidade (Figuras 4.7, 4.8 e 4.9). Assim, construímos o perfil de porosidade, escalonado em porosidade total. As descontinuidades, em ambas as faixas, marcam os limites verticais das camadas.

Para refinar o cálculo da porosidade, temos que corrigir a porosidade dos arenitos em relação ao volume de argila (Ellis, 1987). Primeiro, calculamos a porosidade devido ao densidade através da equação

$$\phi_D = \frac{\rho_{bM} - \rho_b}{\rho_{bM} - \rho_{bF}}, \quad (4.1)$$

onde ϕ_D é a porosidade calculada a partir do perfil de densidade, ρ_{bM} é a densidade da matriz (2.65, para o arenito), ρ_{bF} é a densidade do fluido (1.1, para água salgada) e ρ_b é a densidade medida no perfil. Então, corrigimos os valores de porosidade, no perfil de porosidade do arenito, através da equação (Crain, 1986)

$$\phi = \frac{\phi_D \phi_{N_{SH}} - \phi_N \phi_{D_{SH}}}{\phi_{N_{SH}} - \phi_{D_{SH}}}, \quad (4.2)$$

onde ϕ é a porosidade efetiva e $\phi_{N_{SH}}$, $\phi_{D_{SH}}$ são os pesos sinápticos do neurônio do folhelho.

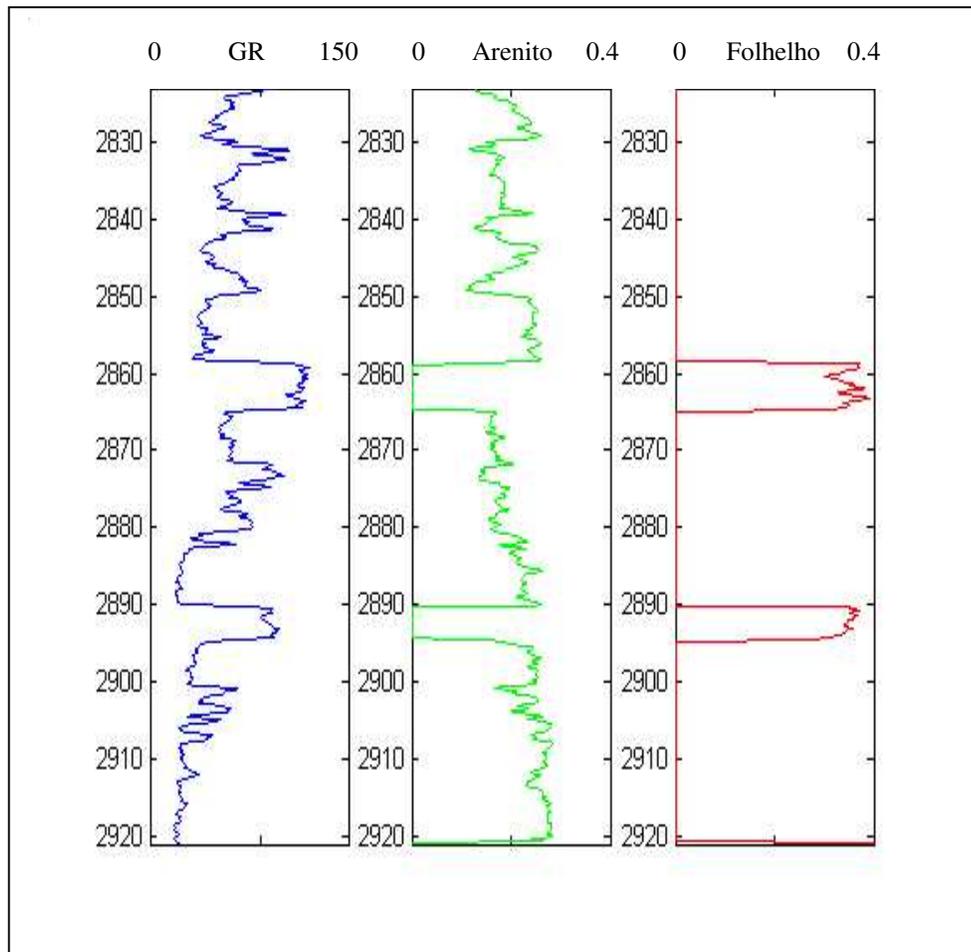


Figura 4.7: Perfil de porosidade para o Poço A. Na primeira faixa temos o perfil de raios gama. Na segunda faixa temos o perfil de porosidade para o arenito e na terceira faixa temos o perfil de porosidade para o folhelho.

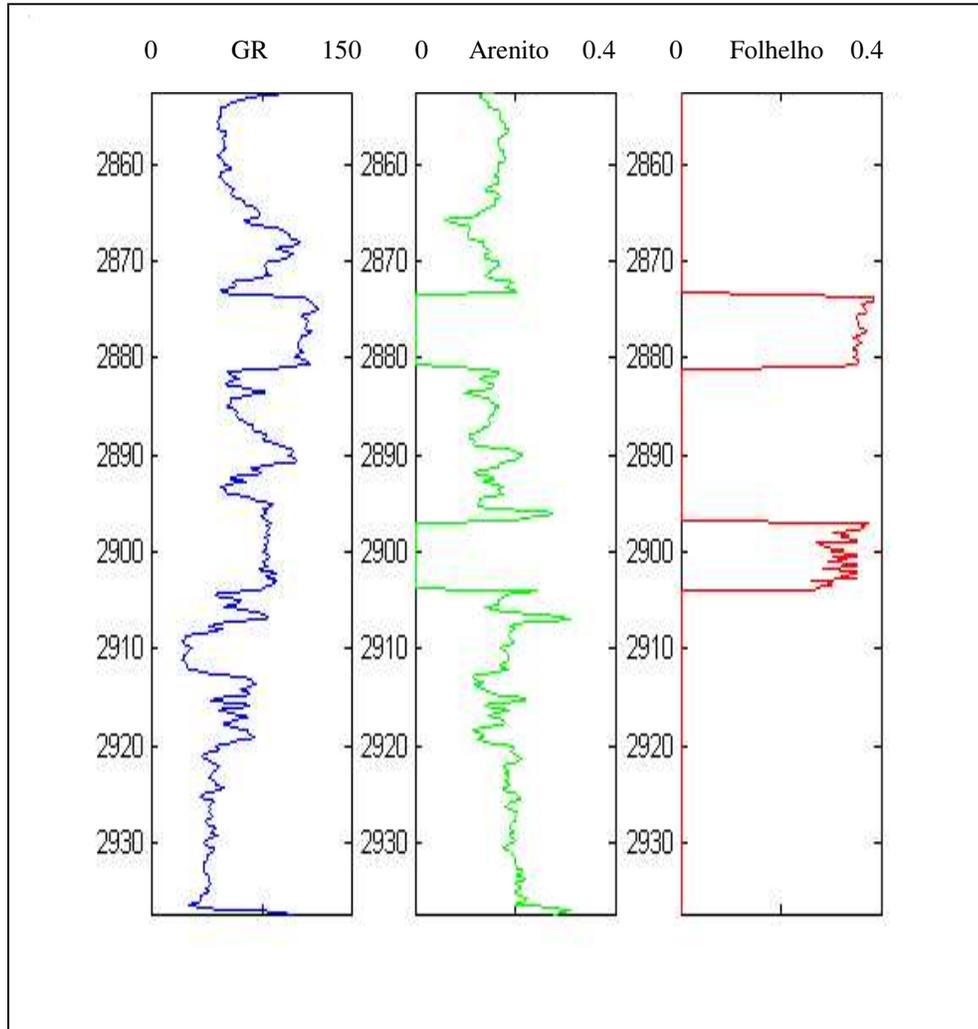


Figura 4.8: Perfil de porosidade para o Poço B. Na primeira faixa temos o perfil de raios gama. Na segunda faixa temos o perfil de porosidade para o arenito e na terceira faixa temos o perfil de porosidade para o folhelho.

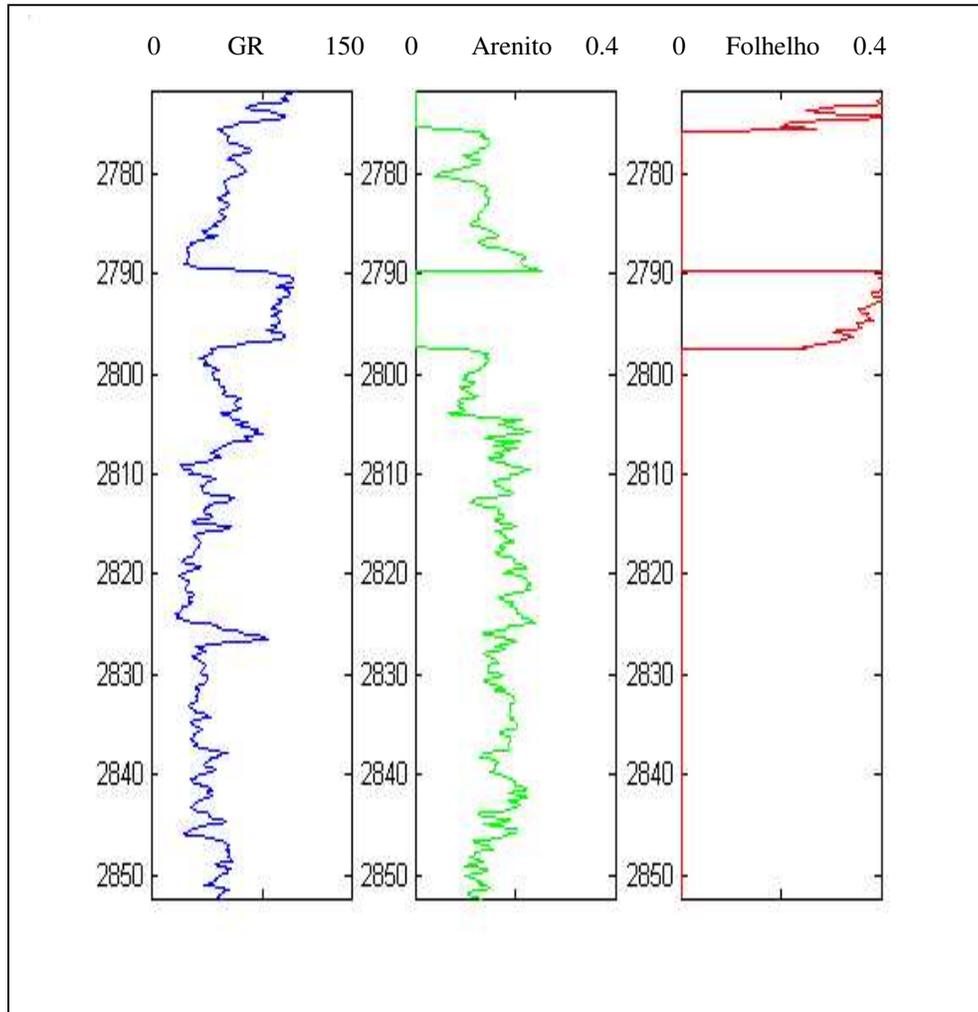


Figura 4.9: Perfil de porosidade para o Poço C. Na primeira faixa temos o perfil de raios gama. Na segunda faixa temos o perfil de porosidade para o arenito e na terceira faixa temos o perfil de porosidade para o folhelho.

4.3 LINHAS DE CORRELAÇÃO

As linhas de correlação conectam os pontos, em profundidade, associados ao topo e base de uma mesma camada, atravessada por diferentes poços. Assumimos que um par de linhas de correlação identifica o topo e base de uma camada geológica.

Apresentamos um algoritmo interpretativo que realiza a correlação de perfis de poço. Este algoritmo tem como núcleo uma rede neural de função de base radial, que possui como entrada quatro perfis de poço convencionais (raio gama, densidade, porosidade neutrônica e volume de argila) e o perfil de porosidade. Geralmente, para fazer-se a correlação de poços, necessita-se da ajuda de um datum de correlação que deve representar um evento regional, que pode ser identificado nos perfis de todos os poços. Utilizamos como dados de correlação as camadas de folhelho, identificadas nos perfis de porosidade (ϕ).

A arquitetura da rede neural é composta por cinco neurônios de entrada, que recebem um valor lido no perfil, para cada profundidade, a cada instante de tempo; e por uma camada de saída, que possui um neurônio, cuja resposta é 1 (um) para uma correlação verdadeira e 0 (zero), para uma correlação falsa. Utilizamos uma rotina que adiciona um neurônio à camada oculta, a cada iteração, até que o erro estipulado entre a saída da rede e a saída desejada esteja dentro do intervalo pré-definido (Figura 4.10).

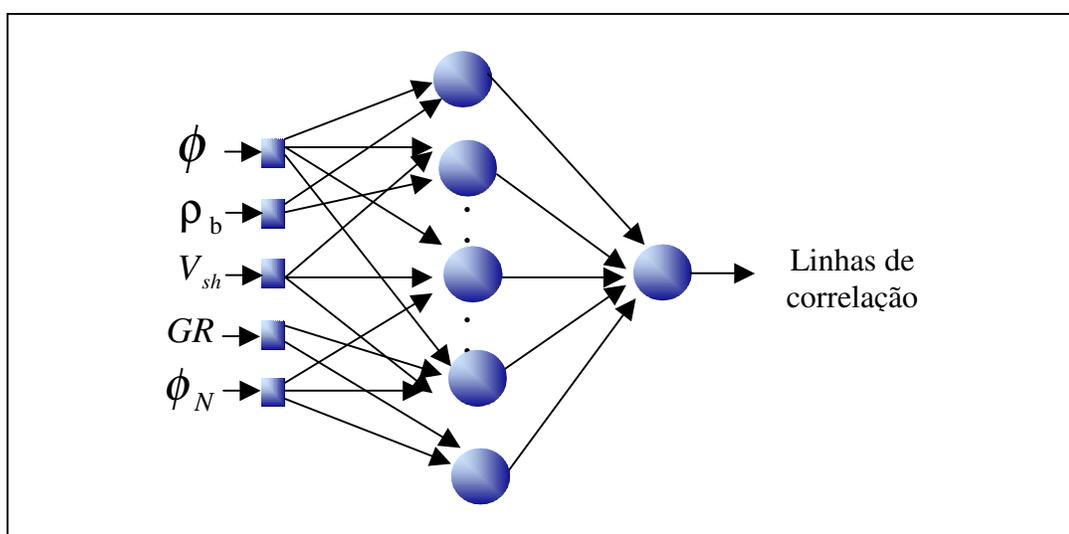


Figura 4.10: Arquitetura de rede neural de função de base radial (RBF) para a determinação das linhas de correlação.

Cinco colunas compõem a matriz de entrada, onde cada coluna representa um perfil de entrada com N amostras tomadas em uma janela de profundidade, na vizinhança de cada camada de folhelho, no perfil de porosidade do folhelho. A matriz de respostas desejadas é igualmente construída com cinco colunas. Cada coluna é formada de tal maneira que onde o perfil de porosidade do folhelho for diferente de zero, seu valor é igual a 1 (um) e zero para o caso contrário, com um número N de amostras. O trabalho realizado na fase de treinamento corresponde ao mapeamento de cada intervalo não nulo, do perfil de porosidade do folhelho, para a unidade, em todos os perfis de entrada, como mostrado na Figura 4.11. Isto significa que é necessário fazer um treinamento isolado para cada camada de folhelho.

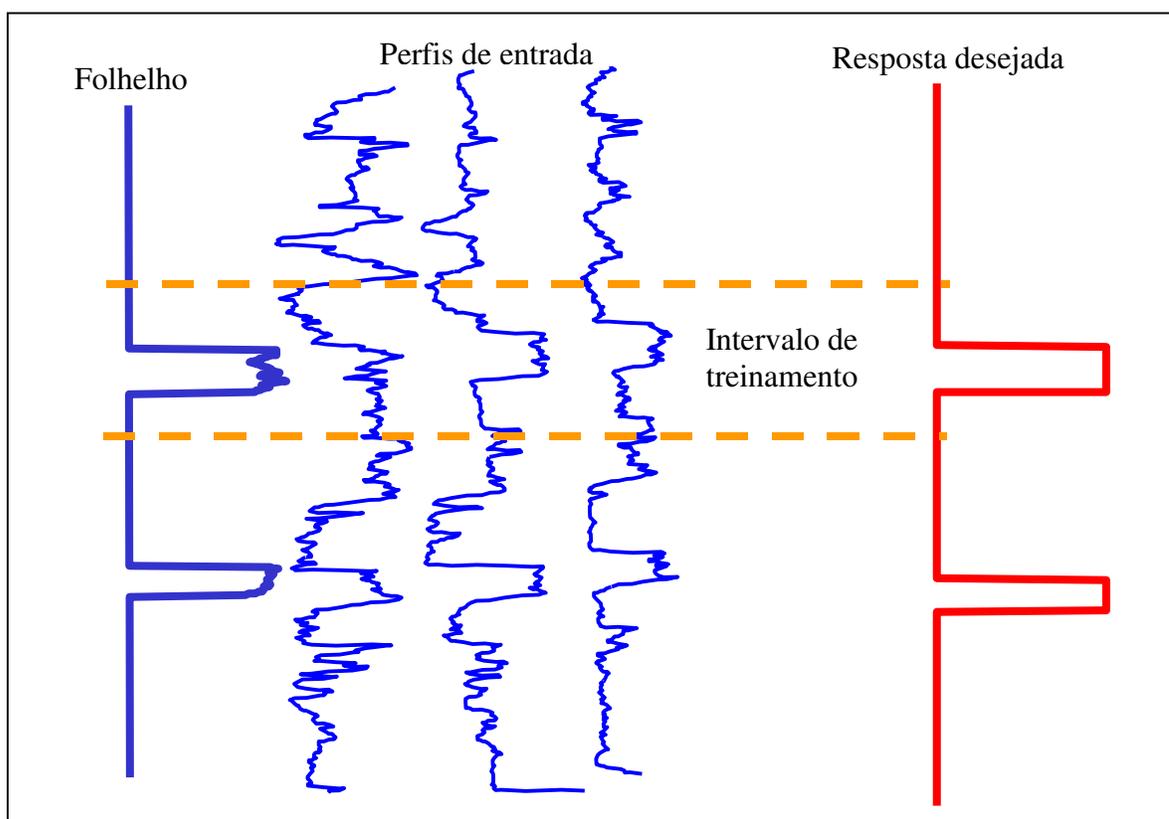


Figura 4.11: Conjunto de treinamento da rede neural de função de base radial para a determinação das linhas de correlação. Destacado pelas linhas amarelas tracejadas, tem-se o intervalo de treinamento utilizado.

Trabalhamos com dois poços na fase de operação – o poço de referência e o poço de teste. Este processo pode ser interpretado como a busca das camadas de folhelho no poço teste, assim

como aconteceu no poço de referência. Na prática, isto é um trabalho mais delicado realizado pela rede neural.

A generalização das redes neurais pode produzir mais que uma resposta, mas para cenários geológicos simples podemos evitar isto utilizando duas regras. A primeira é a posição relativa da camada de folhelho em cada poço, onde assume-se a ausência de falhas e/ou planos de descontinuidade. A segunda regra toma uma aproximação estatística. A saída atual da rede é um vetor que contém valores próximos de zero, para a ausência de correlação, e valores próximos de 1 (um), quando uma correlação é estabelecida. Tomamos um valor mediano. Se o valor médio é próximo da unidade, então existe equivalência lateral entre as camadas de folhelho. Este critério é bom o suficiente para evitar ambigüidades na correlação das camadas de folhelho ou o cruzamento destas, assegurando que camadas com diferentes espessuras sejam corretamente correlacionadas (Figura 4.12). O processo continua para as outras camadas de folhelho no poço teste.

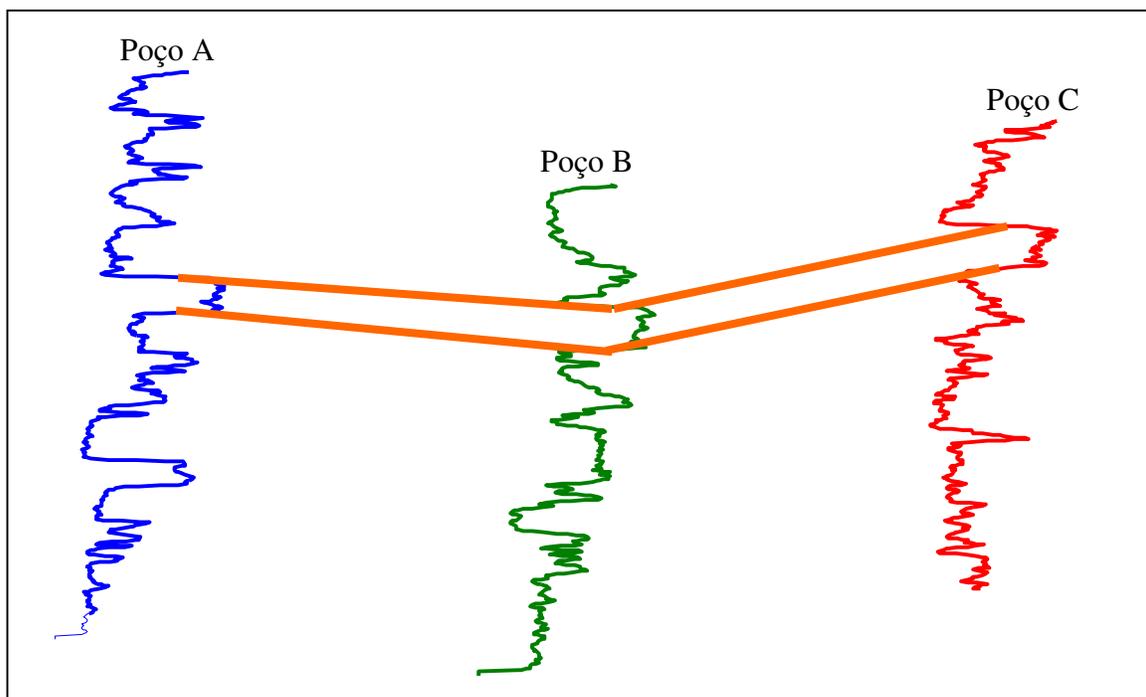


Figura 4.12: Perfis de raios gama naturais dos Poços A, B e C mostrando as linhas de correlação estabelecidas para a primeira camada de folhelho, através do processamento da rede neural de função de base radial.

A definição de linhas de correlação para os folhelhos pode estabelecer um plano deposicional horizontal antigo, modificado por eventos tectônicos posteriores. Deste modo, se trabalharmos em ambientes geológicos simples, as linhas de correlação podem muito bem representar a equivalência litoestratigráfica entre as mesmas camadas atravessadas por diferentes poços, em campos de óleo ou gás.

Tabela 3: Validação das profundidades, em metros, para o topo e a base da camada de folhelho determinada pelo algoritmo interpretativo, por comparação com os resultados de Luthi et al. (1995) e por um geólogo da empresa Maraven S.A., proprietária dos dados.

Poço		Geólogo	Luthi et al. (1995)	Algoritmo interpretativo
A	TOPO	2858.7	2858.4	2858.6
	BASE	2864.5	2864.4	2864.7
B	TOPO	2873.9	2873.5	2873.4
	BASE	2881.2	2880.9	2880.9
C	TOPO	2789.6	2789.6	2789.8
	BASE	2797.1	2796.8	2797.4

4.4 IMAGEAMENTO DA POROSIDADE

O imageamento da porosidade é a representação gráfica da distribuição lateral da porosidade estimada a partir de dados de perfis de poço. Esta imagem, obtida em ambientes deposicionais dominados por clásticos e caracterizados por uma seqüência, com alternância em profundidade, de arenitos e folhelhos, em muito se assemelha à seção geológica convencional. Em que pese a escala de cores adotada ser representativa da porosidade, a particular escolha da utilização dos valores de porosidade aparente, para representar os folhelhos, e os valores de porosidade efetiva, para os arenitos, permite-nos deduzir a litologia e a geometria das camadas. A

interpretação deste tipo de imagem tem aplicações imediatas na geologia do petróleo, possibilitando uma boa aproximação da seção geológica em campos novos e, bem como, no desenvolvimento de reservatórios, possibilitando melhores indicações de novas perfurações em função das variações laterais da porosidade efetiva pela contaminação de seus poros pela argila.

Neste tópico utiliza-se toda a informação produzida nos tópicos anteriores, a partir da construção de um algoritmo interpretativo que possui como núcleo uma rede neural de função de base radial.

A arquitetura base da rede neural de função de base radial é composta por uma camada de entrada, que recebe os valores da porosidade, tomadas em uma mesma profundidade, para o poço de referência (ϕ_1) e para um poço de teste (ϕ_2). A camada de saída da rede é composta por um neurônio, cuja resposta será o valor da porosidade (ϕ) nesta profundidade, para o perfil interpolado resultante. Para este processamento utilizamos quatro neurônios de base radial na camada oculta, conforme ilustrado na Figura 4.13.

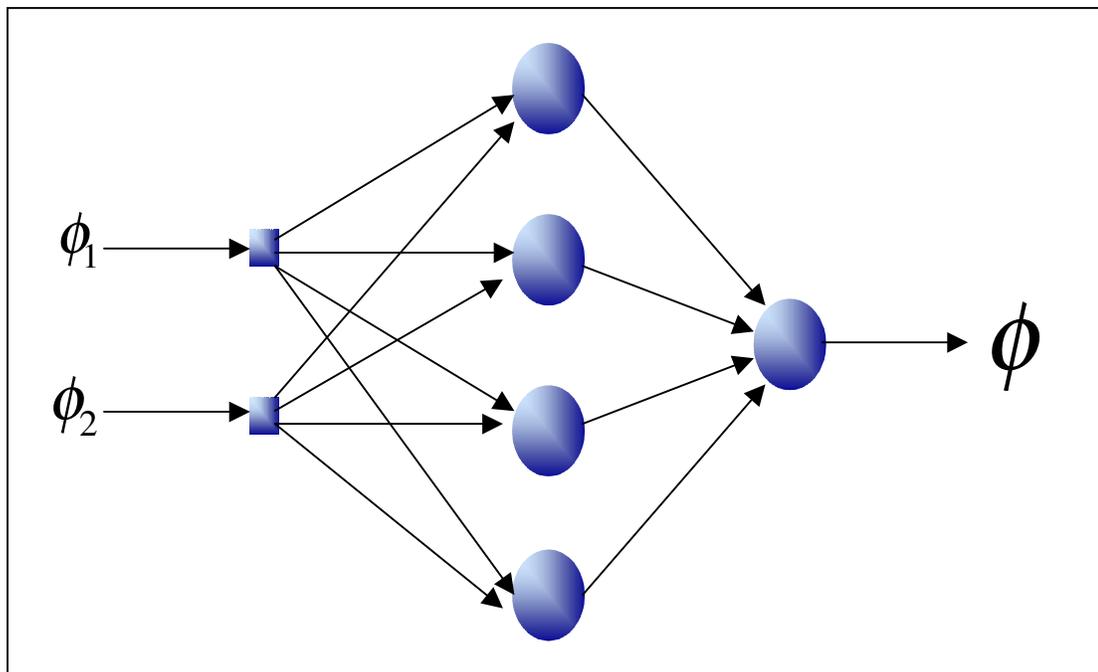


Figura 4.13: Arquitetura de rede neural de função de base radial para a determinação da porosidade ϕ nos perfis interpolados.

Agora, exploramos a capacidade de interpolação da rede neural. Este mapeamento é guiado pela direção estabelecida pelas linhas de correlação, que ligam todos os poços envolvidos no processo, possibilitando que as interpolações ocorram entre valores da mesma litologia e geologicamente relacionados.

Para um melhor entendimento das entradas e saída da rede neural de função de base radial para a determinação do perfil de porosidade interpolado (Figura 4.13), assume-se como entradas, para cada profundidade, os pares de porosidade dos Poços A e B, em vermelho, obtendo-se, na posição intermediária entre estes poços, o perfil interpolado em azul (Figura 4.14).

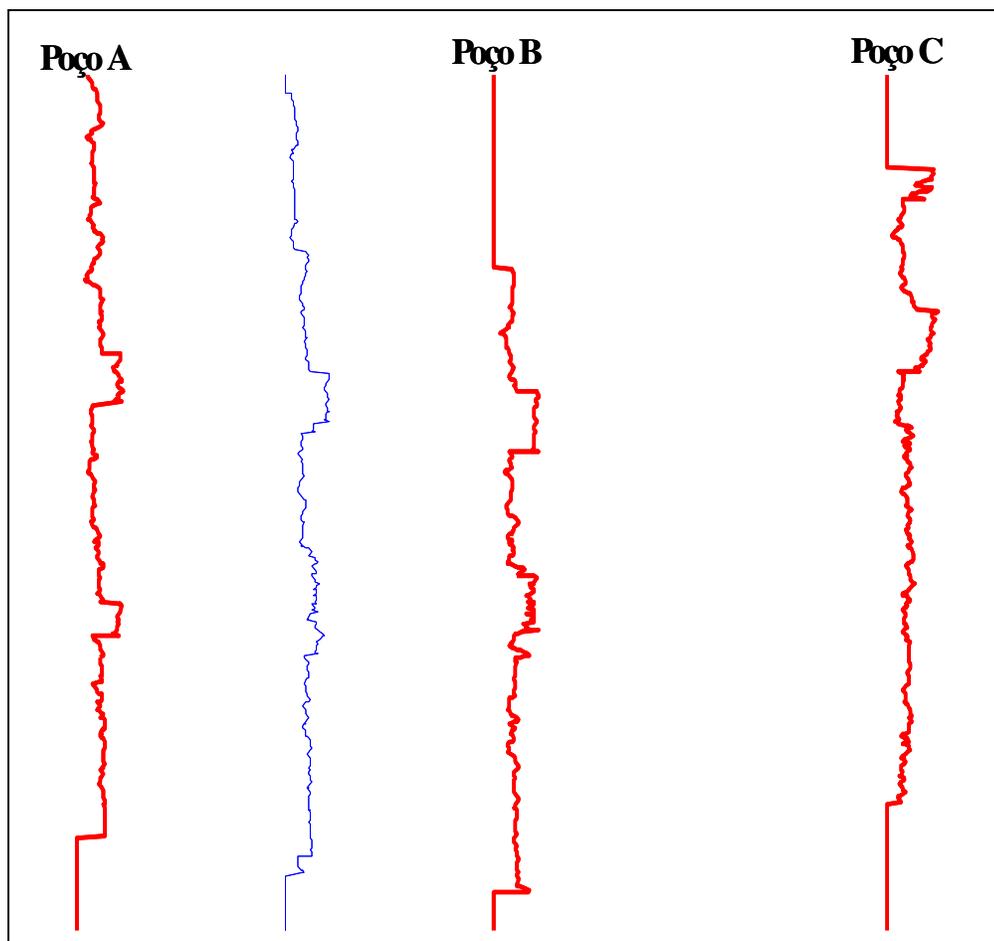


Figura 4.14: Visualização do processo de interpolação da porosidade adotado pelo algoritmo interpretativo. Em vermelho têm-se os perfis de porosidade originais. Em azul mostra-se o primeiro perfil de porosidade interpolado.

A rede trabalha como se nós colocássemos um número de poços hipotéticos entre cada dois poços reais (Figura 4.15), permitindo assim a estimativa da distribuição da porosidade e apresentar o resultado como uma seção, mostrando o comportamento geométrico das camadas.

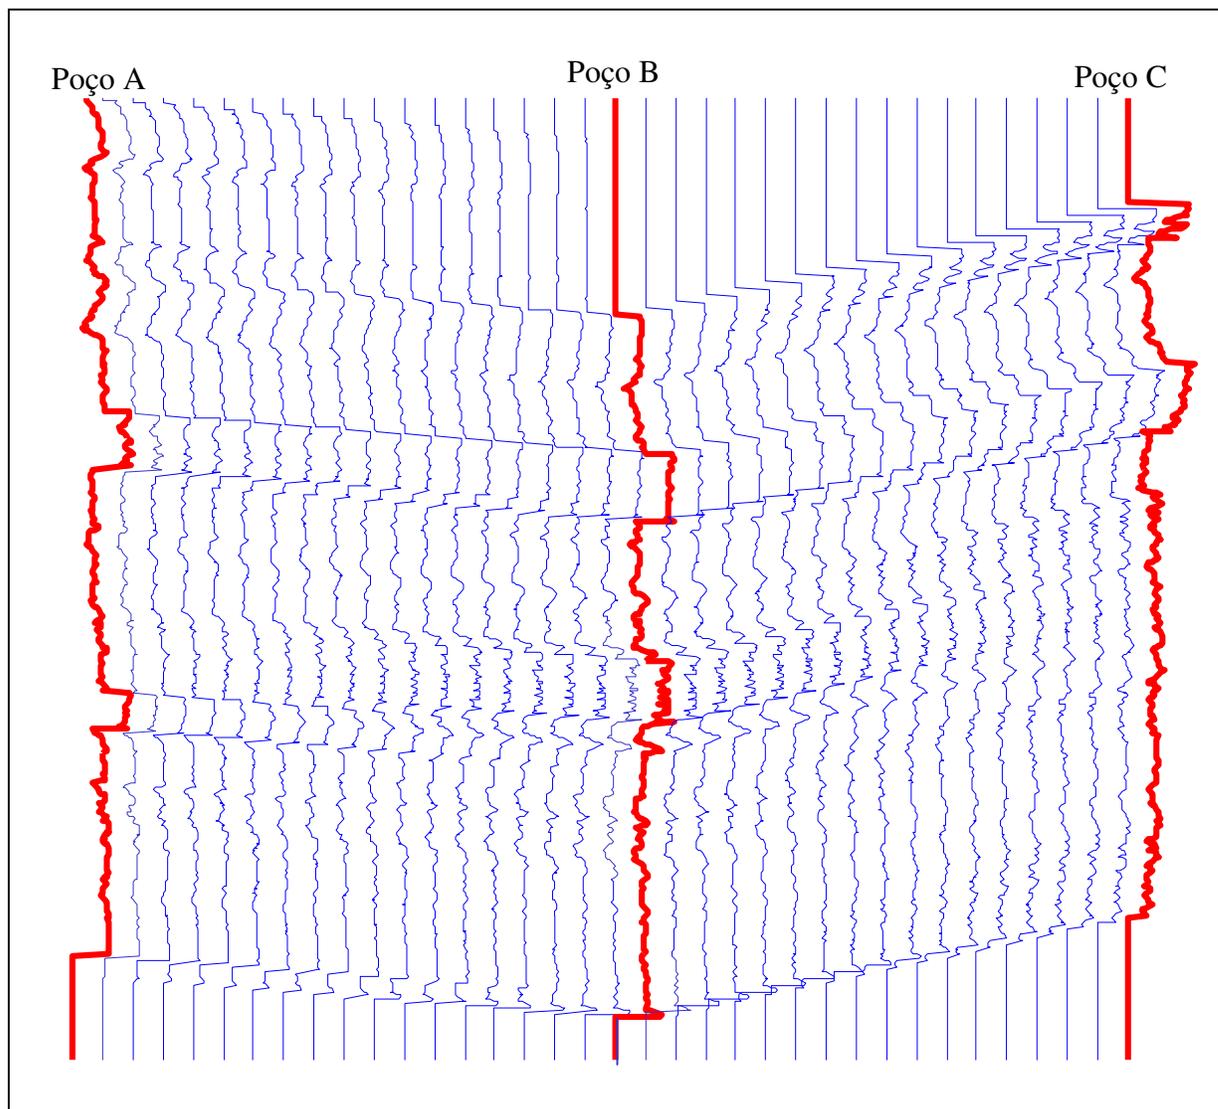


Figura 4.15: Interpolação dos perfis de porosidade realizado pelo algoritmo interpretativo para a determinação do imageamento da porosidade. Os perfis em vermelho são referentes aos Poços A, B e C. Em azul temos os perfis interpolados.

Após a finalização do processamento da rede neural temos uma matriz – a matriz de porosidade, onde as colunas representam as posições dos poços e as linhas representam as profundidades. Cada elemento desta matriz representa um valor de porosidade. Adicionam-se

zeros nas posições onde não existem valores de porosidade, ou seja, nos limites verticais de cada trecho de perfil. A matriz de porosidade é, então, convertida para o conjunto de matrizes RGB, gerando uma imagem colorida, ou para uma outra matriz em nível de cinza, através dos métodos convencionais do processamento de imagens, para, finalmente, apresentar a imagem da porosidade (Figura 4.16). A variação das cores representa a distribuição dos valores de porosidade ao longo da seção. A cor preta indica valores de porosidade iguais a zero ou os limites verticais da seção. A cor laranja claro indica altos valores de porosidade que estão associados à porosidade aparente das argilas. Deste modo, conceituamos a escala de porosidade com os altos valores associados às cores claras e os baixos valores, associados às cores escuras.

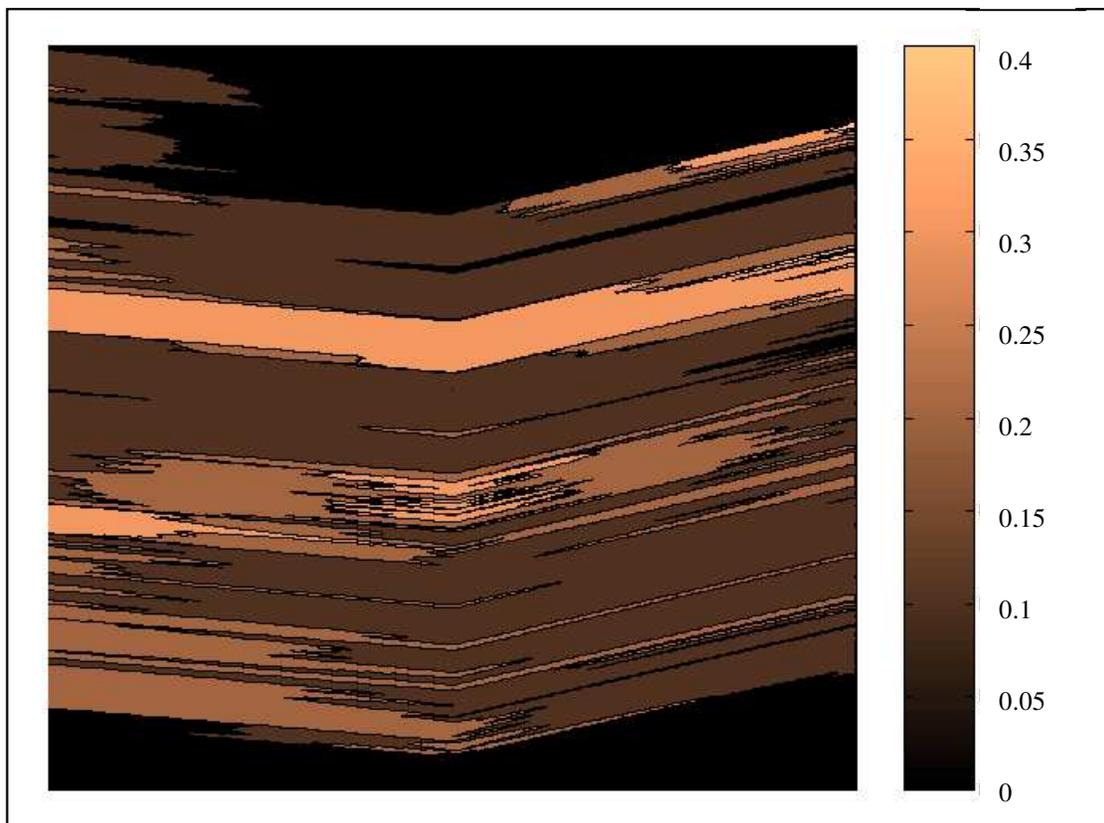


Figura 4.16: Imagem da porosidade mostrando as suas variações laterais.

Na Figura 4.16, mostra-se ainda a escala de porosidade adotada. Assim, podemos interpretar a cor marrom, próxima ao meio da seção, como sendo representativa de um arenito sujo, o qual perde o seu conteúdo de argila em direção às bordas da seção.

A Figura 4.17 mostra a mesma imagem da porosidade que a Figura 4.16, apenas com um maior nível de detalhe possibilitando-nos produzir algumas interpretações de caráter geológico, como:

1. Na base da seção temos um corpo arenoso que mostra o decréscimo nos valores da porosidade da esquerda para a direita da seção.
2. Pela verificação visual da Figura 4.15 poderia-se imaginar que a camada de folhelho mais profunda, no Poço A, tivesse alguma correlação com a segunda camada no Poço B. Vê-se na Figura 4.17, que essas camadas não se correlacionam.
3. A mesma situação aplica-se ao pico de folhelho visto, na Figura 4.15, no Poço C.

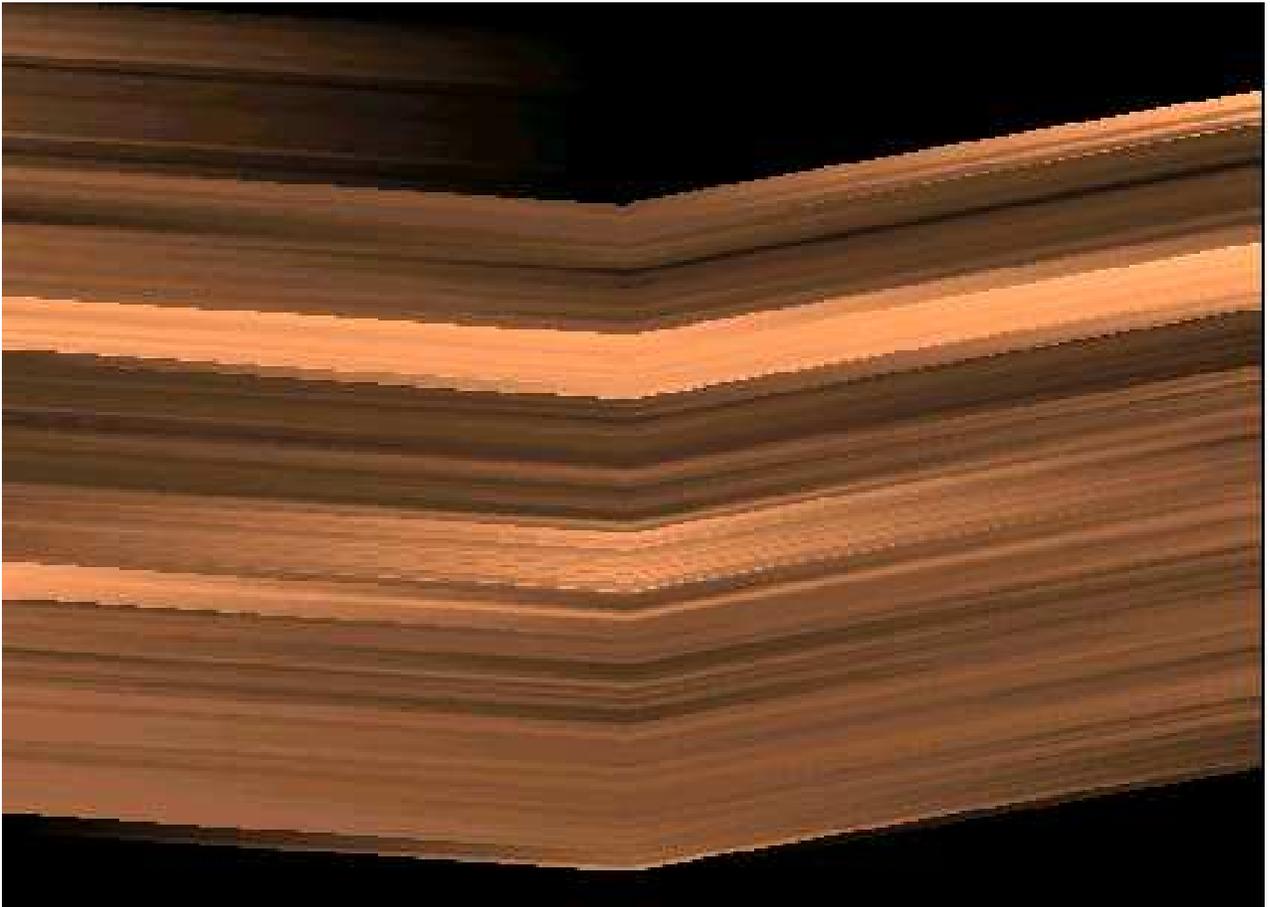


Figura 4.17: Imageamento da porosidade. A variação das cores representa a distribuição dos valores de porosidade ao longo da seção.

5 CONCLUSÕES

Apresentou-se, nesta tese, um novo conceito para a interpretação integrada dos perfis geofísicos de poço, voltada à caracterização de reservatórios, na forma do assim chamado algoritmo interpretativo. A intenção aqui não foi esgotar todas as possibilidades da sua aplicação na melhoria do conhecimento geológico de subsuperfície, através da utilização dos perfis geofísicos de poço, mas sim apresentar tão somente um exemplo de sua aplicação para o caso da determinação da variação lateral da porosidade e, particularmente, para os cenários geológicos dominados por clásticos. Mostrou-se, ainda, a possibilidade da identificação litológica e o mapeamento geométrico das camadas.

O algoritmo interpretativo possui como núcleo uma ou mais redes neurais artificiais, que operam seqüencialmente na extração de informação dos dados de poço, associadas aos algoritmos seqüenciais da computação científica convencional. Com o objetivo de simular os processos de decisão envolvidos na interpretação, foi produzida uma ferramenta para a redução do volume de dados a serem processados e criada uma memória interativa da interpretação dos reservatórios de hidrocarboneto. O algoritmo interpretativo pode guardar a interpretação da porosidade realizada e integrá-la a um novo conjunto de dados de um modo bastante eficiente. Permite, ainda, o estabelecimento de novas seções de porosidade, melhorando a construção de um modelo do reservatório de uma maneira prática e com um alto grau de automação.

A metodologia apresentada nesta tese pode ser expandida para incluir outros perfis de entrada, mais sofisticados e geologicamente mais relevantes, tais como o perfil de imageamento ultrassônico ou elétrico de poço, os perfis de ressonância magnética nuclear e os perfis geoquímicos. Pode também ser estendido para incluir outros parâmetros geológicos de saída, tais como permeabilidade, saturação de fluidos, mineralogia, acamamento ou cronoestratigrafia das camadas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALI, M. & CHAWATHE, A. 2000. Using artificial intelligence to predict permeability from petrographic data. *Computers and Geosciences*, **26**: 915-925.
- AMARI, S. 1977. Neural theory of association and concept-formation. *Biological Cybernetics*, **26**: 175-185.
- AMARI, S. 1983. Field theory of self-organizing neural nets. *IEEE Transactions on Systems, Man and Cybernetics* SMC, **13**: 741-748.
- ANDERSON, J.A.; SILVERSTEIN, J.W.; RITE, S.; JONES, R.S. 1977. Distinctive features, categorical perception and probability learning: Some applications of a neural model. *Psych. Ver.*, **84**: 413-451.
- ANDRADE, A.J.N. & LUTHI, S. M. 1997. *Correlação estratigráfica de perfis de poço através de rede neuronal direta multicamadas*. In: CONGRESSO INTERNACIONAL DA SOCIEDADE BRASILEIRA DE GEOFÍSICA, 5., São Paulo. *Anais...* São Paulo. V.1, p.369-372.
- BANCHS, R. & MICHELENA, R. 2000. Well log estimates and confidence intervals by using artificial neural networks. In: ANNUAL MEETING SOCIETY OF EXPLORATION GEOPHYSICISTS. 1 CD-ROM.
- BRYANT, I. D.; BAYGÜN, B.; HERRON, M. M.; MATTESON, A.; RAMAMOORTHY, R.; STEWART, L.; TARIQ, S. M.; COLL, C.; CORDOVA, P.; VILLARROEL, H.G.; HERNÁNDEZ, L.; JIMENEZ, Z.; LEÓN, K.; RONDÓN, L. 1998. Integration of old and new measurements to optimize redevelopment of the Lower Lagunillas Reservoir of Bloque IV, Lake Maracaibo, Venezuela. *SPE Reservoir Evaluation & Engineering*, June.
- CARPENTER, G. & GROSSBERG, S. 1986. Adaptive resonance theory: stable self-organization of neural recognition codes in response to arbitrary lists of input patterns. In: ANNUAL CONFERENCE OF THE COGNITIVE SCIENCE SOCIETY, 8. p.45-62.

- CARPENTER, G. & GROSSBERG, S. 1987. Invariant pattern recognition and recall by an attentive self-organizing ART architecture in a nonstationary world. In: *IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS*, 1. *Proceedings*. V.2, p. 737-746.
- CHANG, H.C.; CHEN, H.C.; DURRANS, S.R.; KOPASKA-MERKEL, D.C. 2000. Lithofacies identification using multiple adaptive resonance theory neural networks and group decision expert system. *Computer and Geosciences*, **26**, (5):591-601.
- CRAIN, E. R. 1986 *The log analysis handbook*. Tulsa, PennWell Books.
- CROCKER, H.; FUNG, C.C.; WONG, K.W. 1999. The stag oil field formation evaluation: a neural network approach. *Australian Petroleum Production and Exploration Association Journal*, **38**: 451-459.
- DEVARAJ, D.; YEGNANARAYANA, B.; RAMAR, K. 2002. Radial basis function networks for fast contingency ranking. *Electrical Power and Energy Systems*, **24**: 387-395.
- ELLIS, D. V. 1987. *Well logging for earth scientists*. USA, Elsevier.
- FISCHETTI, A.I. & ANDRADE, A.J.N. 1999. Automatic lithologies identification from well logs. In: CONGRESSO INTERNACIONAL DA SOCIEDADE BRASILEIRA DE GEOFÍSICA. 6. CD-ROM.
- FITZGERALD, E.M.; BEAN, C.J.; REILLY, R. 1999. Fracture-frequency prediction from borehole wireline logs using artificial neural networks. *Geophysical Prospecting*, 1031-1044.
- FUKUSHIMA, K.; MIYAKE, S.; ITO, T. 1983. Neocognitron: a neural network model for a mechanism of visual pattern recognition. *IEEE Transactions on Systems, Man and Cybernetics SMC*, **13**: 826-834.
- GALLANT, A.R. & WHITE, H. 1988. There exist a neural network that does not make avoidbale mistakes. In: *IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS*, 1., San Diego. p.657-664.

- GROSSBERG, S. 1964. *The theory of embedding fields with applications to psychology and neurophysiology*. Rockefeller Institute of Medical Research.
- GROSSBERG, S. 1970. Neural pattern discrimination. *Journal of Theoretical Biology*, **27**: 291-337.
- GROSSBERG, S. 1972. Neural expectation: cerebellar and retinal analogues of cells fired by unlearnable and learnable pattern classes. *Kybernetik*, **10**: 49-57.
- GROSSBERG, S. 1973. Contour enhancement, short-term-memory, and constancies in reverberating network. *Studies in Applied Mathematics*, **52**: 217-257.
- GROSSBERG, S. 1976. Adaptive pattern classification and universal recording: II. Feedback, expectation, olfaction, illusions. *Biological Cybernetics*, **23**: 187-202.
- GROSSBERG, S. 1978. Competition, decision and consensus. *Journal of Analytic Applications*, **66**: 470-493.
- GROSSBERG, S. 1987. Competitive learning: from interactive activation to adaptive resonance. *Cognitive Science*, **11**: 23-63.
- HAYKIN, S. 2001. *Redes neurais: princípios e práticas*. São Paulo, Bookman.
- HEBB, D.O. 1949. *The organization of behavior: a neuropsychological theory*. New York, Wiley.
- HECHT-NIELSEN, R. 1987. Kolmogorov's mapping neural network existence theorem. In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1. V. 3, p. 11-14.
- JAMIALAHMADI, M. & JAVADPOUR, F.G., 2000. Relationship of permeability, porosity and depth using an artificial neural network. *Journal of Petroleum Science and Engineering*, **26**: 235-239.
- KOHONEN, T. 1984. *Self-organization and associative memory*. Berlin, Springer-Verlag

- KOHONEN, T. 1989. *Self-organization and associative memory*. Berlin, Springer-Verlag.
- LUTHI, S. 2001. *Geological well logs: their use in reservoir modeling*. Springer.
- LUTHI, S.; BRYANT, I.; VILLAROEL, H. 1995. Well log correlation using backpropagation neural networks. In: CONGRESSO INTERNACIONAL DA SOCIEDADE BRASILEIRA DE GEOFÍSICA, 4. V. 2, p.733-736.
- McCLELLAND, J. 1986. *The appeal of parallel distributed processing*.
- McCORDOCK, P. 1979. *Machine who thinks*. W. H. Freeman and Company. p. 113.
- McCULLOH, W.S. & PITTS, W. 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, **5**: 115-133.
- MHASKAR, H.N. 1996. Neural networks for optimal approximation of smooth and analytic functions. *Neural Computation*, **8**: 1731-1742.
- MINSKY, M.L. 1954. *Theory of neural-analog reinforcement systems and its application to the brain-model problem*. New Jersey, Princeton University. (Ph.D. Thesis).
- MINSKY, M.L. & PAPERT, S.A. 1969. *Perceptrons*. Cambridge, MA: MIT Press.
- NIYOGI, P. & GIROSI, F. 1996. On the relationship between generalization error, hipótesis complexity, and sample complexity for radial basis functions. *Neural Computation*, **8**: 819-842.
- ROSENBLATT, F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, **65**: 386-408.
- ROSENBLATT, F. 1962. *Principles of neurodynamics*. Spartan Books.

- RUMELHART, D.E. & MCCLELLAND, J.L. 1986. *Parallel distributed processing: explorations in the microstructure of cognition*, 1. Cambridge, MA: MIT Press.
- RUMELHART, D.E. & ZISPER, D. 1985. Feature discovery by competitive learning. *Cognitive Science*, **9**: 75-112.
- RUMELHART, D.E.; HINTON, G.E.; WILLIAM, R.J. 1986, Learning internal representation by error propagation. *Parallel distributed processing: explorations in the microstructure of cognition*, **1**: 318-362.
- SAGGAF, M.M. & NEBRIJA, E. M. 2000. Estimation of lithologies and depositional facies from wire-line logs. *AAPG Bulletin*, **84** (10).
- SHEPERD, G.M. & KOCH, C. 1990. Introduction to synaptic circuits. In *THE SYNAPTIC organization of the brain*. New York, Oxford University Press. p.3-31.
- STEINBUCH, K. & PISKE, U.A.W. 1963. Learning matrices and their applications. *IEEE Transactions on Electronic Computers*, **12**: 846-862.
- STEINBUCH, K. & ZENDEH, F. 1963. Self-connecting translator circuits. *Information Processing*, 359-365.
- TALUKDAR, S. C. & MARCANO, F. 1994. Petroleum systems of the Maracaibo basin, Venezuela. The petroleum system: from source to trap. *AAPG Memoir* **60**.
- VANDER BAAN, M. & JUTTEN, C. 2000. Neural networks in geophysical applications. *Geophysics*, **65** (4): 1032-1047.
- VON NEWMANN, J. 1958. *The computer and the brain*. Yale University Press.
- WIDROW, B. 1988. The original adaptive neural network broom balancer. In: *INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS*. p.351-357.

- WIDROW, B. & HOFF, M.E. 1960. Adaptive switching circuits. *IRE WESCON Convention Record*, 96-104.
- WIDROW, B. & HOFF, M.E. 1966. *Adaptive swiching circuits*. IRE WESCOM Convention Record.
- WIDROW, B. & SMITH, F. 1964, Pattern-recognizing control system. *Computer and Information Sciences*, 288-317.
- WIDROW, B. & STEARNS, S.D. 1985. *Adaptive signal processing*. Englewood Cliffs, Prentice-Hall.
- WIDROW, B.; GLOVER, J.R.; McCOOL, J.M.; KAUNITZ, J.; WILLIAMS, C.S.; HEARN, R.H.; ZEIDLER, J.R.; DONG, J.; GOODLIN, R.C. 1975. Adaptive noise cancelling: principles and applications. *Proceedings of the IEEE*, **63**: 1692-1716.
- WIDROW, B.; GRONER, G.; HU, M.; SMITH, F.; SPECHT, D.; TALBERT, L. 1963. *Pratical applications for adaptive data-processing system*. WESCON Convention Record, Section 11.4.
- WIDROW, B.; GUPTA, N.K.; MAITRA, S. 1973. Punish/reward: Learning with a critic in adaptive treshold systems. *IEEE Transactions on Systems, Man and Cybernetics* SMC-3, 455-465.
- WIDROW, B.; MANTEY, P.; GRIFFITHS, L. 1967. Adaptive antenna systems. *IEEE Transactions on Systems, Man and Cybernetics*, **55**: 2143-2159.