



**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE GEOCIÊNCIAS
FACULDADE DE GEOFÍSICA**

DAIVISON NYVOU CALADO DE BRITO

**DETERMINAÇÃO DA POROSIDADE – INTEGRAÇÃO DO
TESTEMUNHO E DO PERFIL DE DENSIDADE ATRAVÉS DA
REDE NEURAL BACKPROPAGATION**

BELÉM

2008



**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE GEOCIÊNCIAS
FACULDADE DE GEOFÍSICA**

DAIVISON NYVOU CALADO DE BRITO

**DETERMINAÇÃO DA POROSIDADE – INTEGRAÇÃO DO
TESTEMUNHO E DO PERFIL DE DENSIDADE ATRAVÉS DA
REDE NEURAL BACKPROPAGATION**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Geofísica do Instituto de
Geociências da Universidade Federal do Pará -
UFPA, em cumprimento às exigências para
obtenção de Bacharel em Geofísica.
Orientador: André José Neves Andrade

BELÉM

2008

Dados Internacionais de Catalogação-na-Publicação (CIP)
Biblioteca Geól. Rdº Montenegro G. de Montalvão

B862d Brito, Daivison Nyvou Calado de
Determinação da porosidade - Integração do testemunho e do perfil de densidade através da rede neural backpropagation / Daivison Nyvou Calado de Brito. – 2009
49 f.: il.

Trabalho de Conclusão de Curso (Graduação em Geofísica) – Universidade Federal do Pará, Instituto de Geociências, Faculdade de Geofísica, Belém, Segundo Semestre de 2008.

Orientador, André José Neves Andrade.

1. Geofísica de poço. 2. Porosidade. 3. Redes Neurais Artificiais. I. Universidade Federal do Pará. II. Andrade, André José Neves, Orient. III. Título.

CDD 20º ed.: 622.15

DAIVISON NYVOU CALADO DE BRITO

**DETERMINAÇÃO DA POROSIDADE – INTEGRAÇÃO DO
TESTEMUNHO E DO PERFIL DE DENSIDADE ATRAVÉS DA
REDE NEURAL BACKPROPAGATION**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Geofísica do Instituto de
Geociências da Universidade Federal do Pará -
UFPA, em cumprimento às exigências para
obtenção de Bacharel em Geofísica.

Data de Aprovação: ____ / ____ / ____

Conceito:

Banca Examinadora

André José Neves Andrade – Orientador
Doutor em Geofísica
Universidade Federal do Pará

José Geraldo das Virgins Alves – Membro
Mestre em Geofísica e diretor do centro de Geociência.
Universidade Federal do Pará

José Gouvêa Luiz – Membro
Doutor em Geofísica
Universidade Federal do Pará

Dedico este trabalho a Jeová meu Deus e pai, a minha esposa Crístieli da Silva Calado de Brito, aos meus pais carnis, Jesuíno Silva de Brito e Maria Antonia Calado de Brito, a minha avó, Maria Madalena Rodrigues Calado, aos meus irmãos Douglas Glesias Calado de Brito e Danielle Cristina Calado de Brito.

AGRADECIMENTOS

Agradeço em primeiro lugar, a Jeová Deus pelo dom dado da vida.

Ao meu Professor e orientador André Andrade pelos ensinamentos, pelas orientações, e pelos incentivos que foram muito importantes e que sem dúvida estão contribuindo para a aprendizagem na Geofísica de poço e para o desenvolvimento desse trabalho de conclusão de curso.

A minha amiga Dielle Franco pela ajuda que prestou com respeito ao entendimento do programa Matlab, utilizando rede neural backpropagation e ao meu amigo Wildney Vieira pela ajuda que prestou referente às dúvidas no funcionamento do programa.

Aos meus amigos, colegas de curso e principalmente aos meus familiares que me deram muita força e encorajamento. São a esses que dedico esse trabalho de conclusão de curso.

RESUMO

A porosidade é uma das mais importantes propriedades petrofísicas para a qualificação dos reservatórios de óleo e gás. Para estimar a porosidade nas rochas reservatórios são utilizadas duas fontes de dados, que são os testemunhos e os perfis geofísicos. A análise do testemunho que é realizada em laboratório fornece a medida direta da porosidade, enquanto que os perfis apresentam informações indiretas sobre a porosidade, mas contínuas ao longo da profundidade do poço. A porosidade e sua relação com o perfil de densidade é muito conhecida na geofísica de poço. Porém, a falta de conhecimento sobre a densidade da matriz da rocha reservatório e sobre a densidade do fluido são os principais problemas para o cálculo da porosidade. Este trabalho tem por objetivo realizar a integração ou mapeamento dos dados do perfil de densidade com os resultados da análise dos testemunhos, que produzem valores diretos da porosidade através de uma interpolação não-linear utilizando como metodologia a técnica de redes neurais treinadas com o algoritmo de backpropagation. A obtenção da porosidade com a rede neural artificial possibilita um menor custo para a aquisição dessa importante informação petrofísica, permitindo ao intérprete de perfis de poço optar ou não pela exploração de uma unidade estudada com uma visão mais completa. A aplicabilidade dessa metodologia é verificada com a utilização do perfil de densidade e valores de porosidade produzidos pela análise de testemunho para um poço perfurado no Campo de Namorado da Bacia de Campos, Brasil. Para os experimentos aqui realizados, essa metodologia exibiu estimativas de porosidade semelhantes aos valores produzidos na análise de testemunho.

Palavras Chave: Geofísica de Poço. Porosidade. Redes Neurais Artificiais.

ABSTRACT

Porosity is an important petrophysical property of reservoir rocks to qualify oil and gas accumulations. Porosity can be estimated from two sources, core analysis and wireline logs. The core analysis is performed in the laboratory and provides a discrete direct measurement, while the processing and interpretation of wireline logs give an indirect porosity information, but continuous along the borehole depth. From wireline logs, porosity may be calculated using the density log. However, lack of matrix density of the reservoir may produce unrealistic porosity values. This work aims to make the integration of core analysis and density log using a backpropagation artificial neural network to map density values in porosity values from core analysis. The porosity calculation using this artificial neural network, which has as input the density log allows a lower cost process to acquire this important petrophysical information. The applicability of this methodology is verified using porosity values from conventional core analysis from one borehole drilled in Namorado oil field, Basin of Campos, Brazil. For the case appraised here, the artificial neural network exhibits compatible results.

Keywords: Wireline logging. Intelligent algorithms. Artificial neural networks.

LISTA DE FIGURAS

Figura 1 – A porosidade primária do tipo intergranular.....	14
Figura 2 – A porosidade secundária do tipo fratura.....	15
Figura 3 – A porosidade secundária do tipo cárstica.....	15
Figura 4 – Porosímetro por expansão de gás.....	19
Figura 5 – Esquema do porosímetro a ar.....	20
Figura 6 – O porosímetro por injeção de mercúrio.....	21
Figura 7 – Software tratando os dados obtidos no porosímetro de mercúrio.....	22
Figura 8 – Ferramenta de densidade.....	25
Figura 9 – Arquitetura neural é tipicamente organizada em camadas.....	29
Figura 10 – Neurônio artificial.....	30
Figura 11 – Função degrau simples (treshold function).....	31
Figura 12 – Função rampa (piecewise-linear function).....	32
Figura 13 – Função logística (logistic function), mostrando, em função do parâmetro γ, a variação da transição entre os dois estados (0 e 1).....	33
Figura 14 – Esquema de Treinamento Backpropagation.....	35
Figura 15 – Interpolação não-linear dos dados de treinamento.....	39
Figura 16 – Arquitetura da rede artificial com três camadas: camada de entrada, camada intermediária e a camada de saída.....	40
Figura 17 – (A): Perfil de densidade. (B): Perfil de porosidade.....	42
Figura 18 – Resultado do treinamento: Os asteriscos azuis mostram a operação da rede sobre o conjunto de treinamento. Resultado da operação: Os círculos em vermelho representam os valores da porosidade estimados pela rede.....	44

Figura 19 – Gráfico de erros.....	45
Figura 20 – Resultado da aplicação da rede neural. (A) Perfil de densidade. (B) Perfil de porosidade direta em azul. O perfil de porosidade estimado pela rede neural é apresentado pela linha em vermelho.....	46

LISTA DE TABELA

Tabela 1 – Densidade de rochas compiladas de Luiz e Silva (1995).....	27
--	-----------

SUMÁRIO

1	INTRODUÇÃO.....	13
2	POROSIDADE.....	14
3	MEDIDAS DIRETAS.....	17
3.1	MEDIDA DIRETA DA POROSIDADE.....	17
4	MEDIDAS INDIRETAS.....	23
4.1	PERFIL DE DENSIDADE.....	23
5	REDE NEURAL ARTIFICIAL.....	28
5.1	NEURÔNIO ARTIFICIAL.....	29
5.2	FUNÇÕES DE ATIVAÇÃO.....	31
5.3	PROCESSOS DE APRENDIZADO.....	34
5.4	ALGORITMOS DE APRENDIZAGEM BACKPROPAGATION.....	35
6	TEOREMAS DE APROXIMAÇÕES DE FUNÇÕES.....	37
7	METODOLOGIA.....	39
7.1	ARQUITETURA DA REDE NEURAL.....	40
7.2	DADOS UTILIZADOS.....	41
8	RESULTADOS.....	43
9	CONCLUSÃO.....	47
	REFERÊNCIAS.....	49

1 – INTRODUÇÃO

A qualificação dos reservatórios de hidrocarbonetos é uma das atividades mais importantes da avaliação de formação. Uma das propriedades que dominam este procedimento é a porosidade. O conhecimento dessa propriedade, a partir das informações dos testemunhos e dos perfis geofísicos de poço, orienta os geofísicos e os engenheiros de reservatórios no projeto de exploração e no desenvolvimento dos campos petrolíferos.

Nos poços são obtidos os testemunhos por meio das ferramentas de perfuração. As medidas diretas da porosidade são realizadas em laboratório, diretamente sobre estas amostras. No entanto, nem toda perfuração de poço é conduzida com a coleta de testemunhos; em alguns campos petrolíferos tais testemunhos são impossíveis de serem obtidos devido à baixa cimentação da rocha. No caso geral, é necessária a testemunhagem de pelo menos alguns dos poços de uma bacia, devido à valiosa importância das informações produzidas pela análise de testemunhos.

As medidas indiretas são realizadas por meio dos perfis geofísicos de poço e dentre as diversas aplicações desses perfis, uma delas é a determinação das significativas propriedades petrofísicas dos reservatórios para a quantificação do conteúdo de hidrocarbonetos.

Este trabalho apresenta um mapeamento ou interpolação não-linear, integrando os dados do perfil de densidade e as medidas diretas da porosidade produzidas pela análise de testemunho; para tanto apresenta-se uma arquitetura de rede neural, do tipo backpropagation, visando a estimativas mais realistas da porosidade.

2 – POROSIDADE

A porosidade é a propriedade petrofísica que expressa a capacidade de armazenamento de fluidos nos poros de uma rocha reservatório. Ela representa o volume de fluido que a unidade de volume de uma rocha pode armazenar em seus poros (GOMES, 2002).

A porosidade é definida como a razão entre o volume do poro (V_p) e o volume total da rocha (V_t). O volume total da rocha é constituído pela soma do volume do poro e o volume da matriz (fase sólida da rocha).

$$\phi = \frac{V_p}{V_t} \quad (1)$$

$$V_t = V_p + V_m \quad (2)$$

A porosidade pode ser classificada como:

- *Porosidade primária ou deposicional*: é aquela adquirida pela rocha durante a deposição ou bioconstrução, ou seja, é originada na formação das rochas e é caracterizada pelos espaços aleatórios entre os grãos agrupados das rochas (porosidade intergranular), como no caso dos arenitos ou dos carbonatos (SUGUIO, 1973), como mostra a Figura 1.




Figura 1 – Porosidade primária do tipo intergranular.

- *Porosidade secundária ou pós-deposicional*: é adquirida após a diagênese das rochas reservatórios. Nesse período, essas rochas são submetidas a esforços mecânicos, podendo resultar no aparecimento de fraturas ou falhas (porosidade de fraturas), fraturas essas que podem aparecer em arenitos, folhelho e carbonato, como mostra a Figura 2.




Figura 2 – Porosidade secundária do tipo fratura.

Pode ocorrer, ainda, em rochas solúveis, como os calcários, aonde o material vai se dissolvendo devido ao ataque de fluidos de formação (porosidade de condutos ou cárstica), como mostra a Figura 3.




Figura 3 – Porosidade secundária do tipo cárstica.

Para a engenharia do petróleo, existem dois tipos de porosidade, a porosidade

absoluta e a efetiva. Existe uma grande diferença entre a porosidade absoluta ou total, que é o volume total de espaços porosos das rochas; e a porosidade efetiva, que leva em conta somente os espaços porosos que estão interconectados (GRATON; FRASER, 1935). Para engenharia do petróleo essa diferença é muito importante, pois a porosidade efetiva tem relação com uma possível recuperação do petróleo, por isso ela é comercialmente mais importante, do que a porosidade total que nos dá somente o resultado encontrado na perfilagem de poço.

A porosidade medida nos testemunhos é a porosidade efetiva, enquanto a porosidade calculada a partir do perfil de densidade é a porosidade absoluta.

3 - MEDIDAS DIRETAS

As medidas diretas são realizadas em laboratório diretamente sobre os testemunhos retirados dos poços. São retirados *plugs* do testemunho, que devem ser grandes o suficiente para conter uma significativa representação da estrutura dos poros de cada unidade litológica ou camada reservatório. De um ponto de vista prático, o plugue de menor tamanho deve ser de pelo menos uma ordem de grandeza superior ao maior diâmetro dos poros. A forma convencional do plugue é a de um cilindro com 2,5 *cm* de diâmetro e 5 *cm*, que normalmente, satisfaz a este requisito para as rochas clásticas.

Apesar das características ambientais serem razoavelmente restabelecidas nos laboratórios, alguns erros sistemáticos das medidas diretas ocorrem, em consequência dos danos produzidos ao testemunho pelo mecanismo de obtenção durante a operação da testemunhagem, pela manipulação, transporte, armazenamento e preparação ou limpezas das amostras laboratoriais. O procedimento correto indica que as medidas diretas deveriam ser realizadas sob as mesmas características de pressão e temperatura de subsuperfície. Isto pode às vezes ser demasiadamente difícil, caro, ou até mesmo, perda de tempo, pois frequentemente tais informações são indisponíveis e as medidas são executadas nas condições ambientes.

3.1 – MEDIDAS DIRETAS DA POROSIDADE

As medidas diretas da porosidade são realizadas, normalmente, em ambiente com baixos níveis de tensões. As variações nos valores de porosidade são dadas, geralmente, como

função da compressibilidade (C_p) das rochas reservatório (NERY, 2004) definida pela equação 3.

$$C_p = \frac{1}{V_p} \frac{dV_p}{dp} \quad (3)$$

Na equação 3, V_p é o volume do poro e o $\frac{dV_p}{dp}$ é a variação do volume do poro devido a mudança na pressão do fluido. A compressibilidade do volume do poro varia com o tipo de fluido, por exemplo, hidrocarbonetos.

Em geral, a compressibilidade é a redução dos espaços internos das rochas, que ocorre desde a sedimentação até a formação da rocha, ou seja, é um processo diagenético. No ambiente natural, os grãos vão se depositando numa bacia sedimentar, de forma que passam a surgir várias camadas sobrejacentes no decorrer do tempo. Os espaços existentes entre os grãos são preenchidos por água e o peso das camadas sobrejacentes faz com que ocorra uma compressão, fazendo uma redução daqueles espaços e expulsando as águas existentes automaticamente, se ela não tiver para onde ir, a compressão para devido a água ser incompressível. Quando se tira a rocha e leva para o laboratório, a rocha se expande de modo que para deixar a rocha sob compressibilidade igual no ambiente natural é preciso fazer uma nova compressão, para se ter o valor exato da porosidade daquela rocha.

Para que ocorra a determinação da porosidade nos laboratórios são utilizados vários métodos. Inicialmente a determinação da porosidade é feita macroscopicamente ou microscopicamente por meio de estimativa visual ou por comparação. Mas, para obtermos medidas mais precisas é necessário usar um equipamento chamado porosímetro, que foi feito para medir ou determinar com grande rigor as dimensões ou tamanhos dos poros existentes e as distribuições dos tamanhos dos poros em materiais, ou seja, o volume dos poros.

O porosímetro pode ser classificado como:

- Porosímetro por expansão de gás

- Porosímetro a ar
- Porosímetro por injeção de gás

No porosímetro por expansão de gás, a determinação da porosidade é feita por uma injeção de gás Hélio nos poros da rocha, pois injetando esse gás ele exclui o ar existente e se expandirá em aproximadamente 0,5%. Equipamento esse mostrado na Figura 4.



Figura 4: Porosímetro por expansão de gás.

O porosímetro a ar, baseado na Lei de Boyle, determina as porosidades dos testemunhos, como mostrado na Figura 5. Neste porosímetro, a pressão inicial (P_1 , mostrada no manômetro 1, é medida quando a válvula 1 está fechada, esta pressão é equivalente ao volume de ar que está distribuído na célula. Depois que a válvula 1 é aberta a pressão diminui, e o manômetro 1 indica uma pressão final (P_2) menor do que P_1 , neste caso o volume engloba todo o sistema, ou seja, a célula e o testemunho. Antes de iniciar a medida da porosidade do testemunho deve ser feito o vácuo durante o tempo necessário para retirar todo o ar existente

dentro dos poros da rocha.

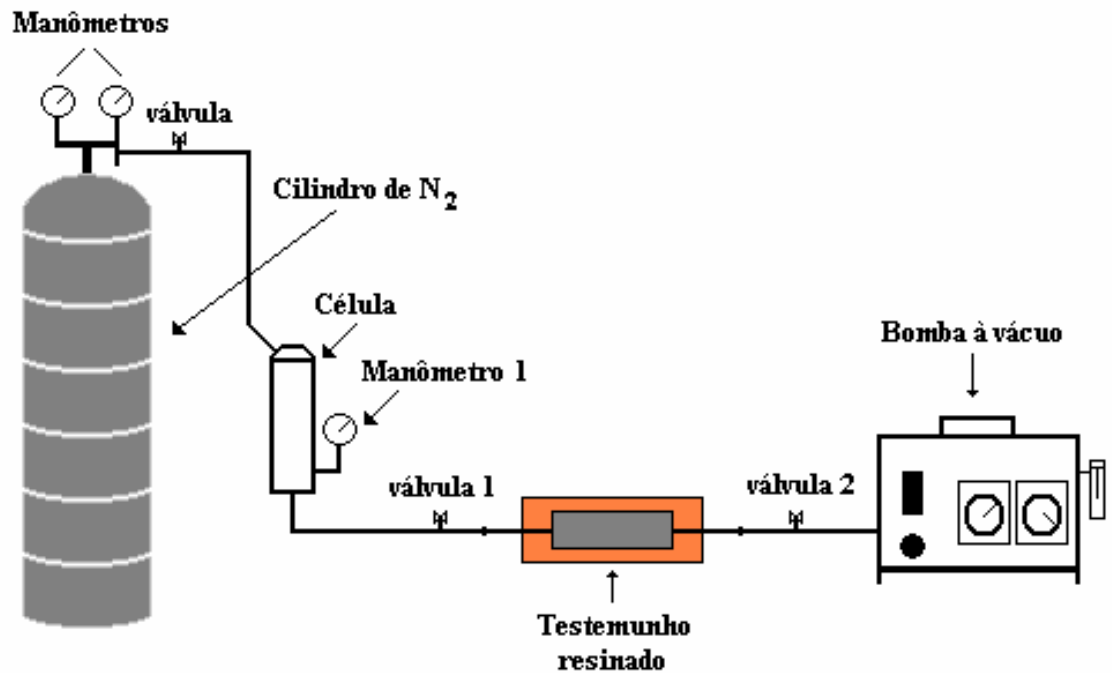


Figura 5 – Esquema do porosímetro a ar.

O porosímetro por injeção de mercúrio foi proposto por Washburn (1921), que sugeriu ser possível se obter a distribuição de diâmetros de poros a partir dos dados pressão-volume durante a penetração de um material poroso pelo mercúrio, desde então vem se desenvolvendo. Na Figura 6, podemos visualizar o porosímetro por injeção de mercúrio.



Figura 6 – O porosímetro por injeção de mercúrio.

Essa técnica se baseia no fato de que o mercúrio se comporta como um fluido não-molhante em relação à maior parte das substâncias. Por consequência, não penetra espontaneamente em pequenos furos ou fissuras destes materiais a menos que se aplique uma pressão sobre ele.

Se uma amostra de um sólido poroso é encerrada num recipiente dotado de um capilar, sendo feito o vácuo sobre a mesma e sendo preenchido o recipiente e o capilar com mercúrio, ao se aumentar a pressão sobre o líquido este penetrará nos poros da amostra reduzindo seu nível no capilar.

Registrando-se a redução do nível de mercúrio no capilar é juntamente com a pressão aplicada, uma curva porosimétrica é obtida informando que volume de poros do material foi penetrado pelo mercúrio a uma dada pressão.

O registro é efetuado num computador que permite tratar os dados obtidos através de um software específico, como mostra a Figura 7.

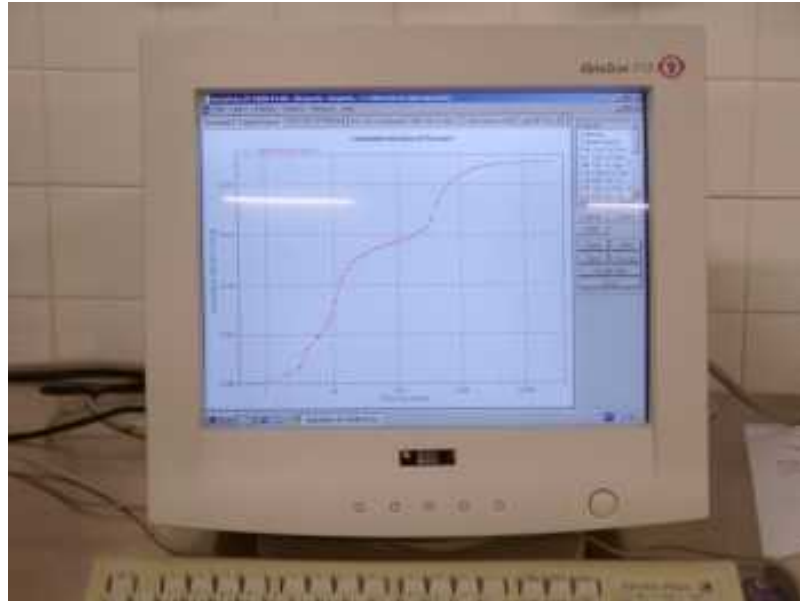


Figura 7 – Software tratando os dados obtidos no porosímetro de mercúrio.

4 - MEDIDAS INDIRETAS

As medidas indiretas são realizadas por meio dos seguintes perfis geofísicos de poço, denominados de perfis de porosidade:

1. Perfil de Densidade: Mede a densidade da rocha e a relaciona com o valor da porosidade, utilizando a equação de Willye, a ser apresentada adiante (NERY, 2004).

2. Perfil Sônico: Estabelece uma relação direta entre a velocidade do som medido na rocha e a sua porosidade, utilizando o tempo de trânsito (NERY, 2004).

3. Perfil Neutrônico: Mede o índice de hidrogênio (HI) da formação e o relaciona com a porosidade (NERY, 2004).

Nessas medidas indiretas os parâmetros usados são:

- Parâmetros dos fluidos
- Parâmetros da matriz

A seguir serão apresentados dentre esses perfis, apenas o perfil de densidade, que foi o perfil usado neste trabalho.

4.1 - PERFIL DE DENSIDADE

O perfil de densidade consiste em um registro contínuo das variações da densidade das formações atravessadas por um poço. Nos casos de rochas reservatório, a medição realizada pelo perfil inclui tanto a densidade da matriz da rocha, quanto a dos fluidos contidos no espaço poroso (NERY, 2004).

A ferramenta de densidade consiste de uma fonte radioativa de raios gama, geralmente se utiliza Cobalto-60 ou césio-137 (SERRA, 1984), montada em um mandril com patins metálicos, os quais são pressionados contra a parede do poço. A fonte é a responsável

pela emissão de raios gama de alta energia, que interagem com os elétrons dos átomos da formação.

Raios gama são ondas eletromagnéticas que não tem massa e que se movem à velocidade da luz. Estes raios gama, ou fótons, colidem com a matéria e sofrem três tipos de interação, dependendo da energia incidente: produção de pares elétron-positron, espalhamento Compton e efeito fotoelétrico (SERRA, 1984).

O espalhamento Compton é o tipo principal de reação para medidas de densidade. Ela inicia quando um fóton incidente colide com um elétron mais externo de um átomo, e sua energia ($h\nu$) se divide em energia cinética do elétron ejetado desse átomo e um fóton espalhado numa direção, fazendo um ângulo q com a direção incidente original. Essa colisão simplifcadamente elástica (espalhamento inelástico) entre o raio gama e um elétron individual permite que o fóton prossiga desviado por esse choque, mas reduzido em energia (SERRA, 1984).

A primeira geração da ferramenta de densidade era constituída de uma fonte de raio gama e um único detector de radiação. Contudo, para compensar a constante interferência do filtrado de lama e do reboco, a segunda geração de ferramentas incorporou dois detectores de radiação em um mandril para captar a radiação espalhada pela rocha, como mostra a Figura 8. A ferramenta é mantida em contato com a parede do poço por um braço hidráulico, que tem também como função fazer a leitura do diâmetro do poço, que auxiliará nas correções da densidade.




Figura 8 – Ferramenta de densidade.

Atualmente, a ferramenta de densidade que é utilizada é a que possui um emissor e dois receptores localizados a distâncias fixas da fonte. Os raios gama espalhados que chegam aos detectores são contados como um indicador da densidade da formação.

O número de colisões é função direta do número de elétrons na formação; e este, por sua vez corresponde à densidade eletrônica (ρ_e) que pode ser relacionada à densidade volumétrica (ρ_v) da formação pela relação abaixo:

$$\rho_e = 2\rho_v \frac{\sum Z_i}{M} \quad (4)$$

Sendo:

ρ_e = Densidade eletrônica,

ρ_v = Densidade volumétrica,

M = Peso molecular,

$\sum Z_i$ = Somatória dos números atômicos de todos os átomos que constituem as moléculas do composto.

Para a maior parte dos materiais encontrados numa formação:

$$2 \frac{\sum z_i}{M} \approx 1 \quad (5)$$

O que significa que, na maioria dos casos, $\rho_s = \rho_b$ (BROCK, 1986).

O valor de (ρ_b) no perfil corresponde à soma das densidades de todas as partes componentes da formação, isto é, é uma função da matriz, porosidade e densidade dos fluidos presentes nos poros, que são relacionados da seguinte maneira, equação 6:

$$\rho_b = \phi \rho_f + (1 - \phi) \rho_{ma} \quad (6)$$

O perfil é utilizado para identificar minerais evaporíticos, detectar zonas de gás, determinar a densidade de hidrocarbonetos e avaliar reservatórios areno-argilosos e litologias complexas. A profundidade de investigação da sonda diminui à medida que aumenta a densidade da rocha (ASQUITH; GIBSON, 1982; BROCK, 1986).

A porosidade calculada pela curva do perfil de densidade (SCHLUMBERGER, 1985), é dada pela equação 7.

$$\phi = \frac{\rho_{ma} - \rho_b}{\rho_{ma} - \rho_f} \quad (7)$$

Onde ϕ é a porosidade, ρ_{ma} é a densidade da matriz, ρ_f é a densidade do fluido. Um dos determinantes da incerteza relacionada às medidas de porosidade dos perfis de densidade é associado aos valores de densidade da matriz. Estes valores variam usualmente entre 2,65 a 2,85 g/cm^3 , dependendo da litologia presente na profundidade em que a medida de densidade foi realizada. Como dificilmente uma determinada litologia possui composição (química e mineralógica) constante ao longo dessa camada, a exata aplicação deste valor

é o principal fator de incerteza para esta medida (LERCHE, 1997). Outra fonte de incerteza está relacionada à densidade do fluido, que apresenta relação direta com a concentração de cloreto encontrado na água de formação. Entretanto, em escala de reservatório, a incerteza relacionada a esta variável pode ser considerada desprezível. Finalmente, há a incerteza da medição obtida no aparelho, que geralmente é considerada de 5% (HEARST; NELSON, 1985).

A grande variação de valores da densidade nas rochas reservatório deve-se principalmente ao fator porosidade, com contribuições menores do fluido (ar, água ou hidrocarboneto) presente nos poros. Na Tabela 1, são apresentados valores de densidade para rochas de reservatório (LUIZ; SILVA, 1995).

Tabela 1: Densidade de rochas compiladas de Luiz e Silva (1995).

	VARIACÃO DA DENSIDADE (g/cm ³)		DENSIDADE MÉDIA (g/cm ³)	
	Poros com fluido	Poros sem fluido	Poros com fluido	Poros sem fluido
ARENITO	1,61 – 2,76	1,60 – 2,68	2,35	2,24
FOLHELHO	1,77 – 3,20	1,56 – 3-20	2,40	2,10
CALCÁRIO	1,93 – 2,90	1,74 – 2,76	2,55	2,11
DOLOMITA	2,28 – 2,90	2,04 – 2,54	2,70	2,30

5 - REDE NEURAL ARTIFICIAL

A construção de uma rede neural artificial tem sido motivada pela estrutura do cérebro humano e pela forma como essa “maquina” é capaz de processar e armazenar milhões de informações em milésimo de segundos (HAYKIN, 2001). A capacidade e a velocidade de organização e a armazenamento das informações nos neurônios, para a realização de tarefas como reconhecimento e percepção, são extremamente altas, sem comparação com qualquer computador existente (WONG, 1998).

Considere, por exemplo, a visão humana, que é uma tarefa de processamento de informação. Essa é uma função do sistema visual para fornecer uma representação do ambiente que nos rodeia e, mais importante, para fornecer a informação necessária para interagir com o meio ambiente. Para ser mais específico, o cérebro realiza rotineiramente vários tipos de reconhecimento como lembrar um rosto familiar, isso ocorre em cerca de 100 - 200 milissegundos, enquanto que tarefas de menor complexidade podem assumir dias em um computador convencional (HAYKIN, 2001).

A rede neural artificial é uma máquina projetada para simular ou modelar a forma como o cérebro executa uma determinada tarefa ou função de interesse, por meio de algoritmos matemáticos (HAYKIN, 2001); essas redes são sistemas de neurônios artificiais ligado por conexões sinápticas e dividido em camadas (WONG; GEDEON; TAGGART, 1995), (WONG; TAGGART; JIAN, 1995), como mostra a Figura 9:

- 1- *Camada de entrada*, onde os padrões são apresentados à rede.
- 2- *Camada intermediária ou oculta*, onde se processam as informações da rede.
- 3- *Camada de saída*, onde o resultado final é concluído e apresentado.




Figura 9 – Arquitetura neural é tipicamente organizada em camadas.

As redes neurais processam os dados e aprendem, podendo descobrir relações altamente complexas entre várias variáveis que são apresentadas a elas. As redes neurais mapeiam os dados de entrada nos dados de saída, não importando a complexidade da relação existente entre eles.

As redes neurais assemelham-se ao cérebro em dois aspectos:

- 1- *O conhecimento* é adquirido através de um processo de aprendizagem.
- 2- *Interconexões* ou pesos sinápticos são usados para armazenar o conhecimento adquirido.

5.1 – NEURÔNIO ARTIFICIAL

Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões.

A operação de uma unidade de processamento, ou neurônio artificial, como proposta por McCulloch e Pitts (1943), pode ser resumida da seguinte maneira, como mostra a Figura 10:

- 1- Sinais são apresentados à entrada;
- 2- Cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- 3- É feita a soma ponderada dos sinais que produz um nível de atividade;
- 4- Função de ativação.

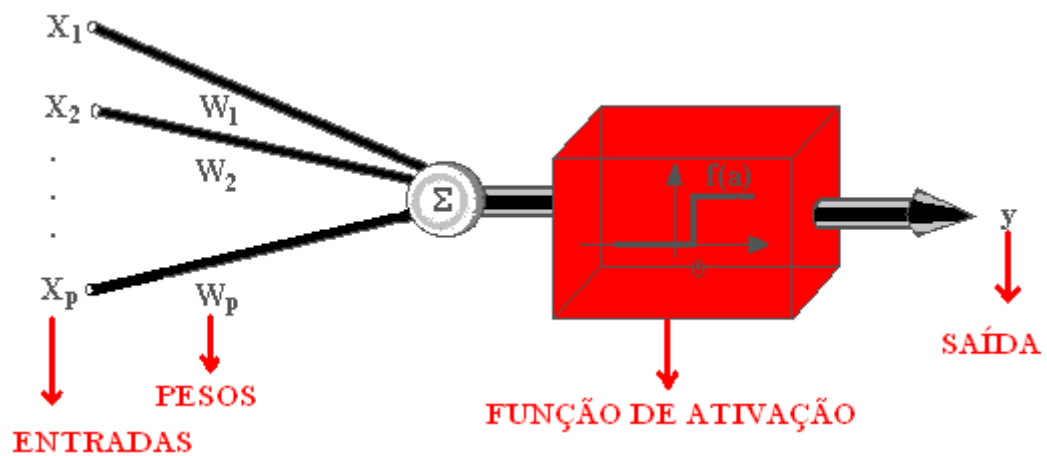


Figura 10 – Neurônio artificial.

Suponha que tenhamos p sinais de entrada X_1, X_2, \dots, X_p e pesos W_1, W_2, \dots, W_p e limitador t , com sinais assumindo valores booleanos (0 ou 1) e pesos valores reais.

Neste modelo, o nível de atividade a é dado por:

$$a = W_1 X_1 + W_2 X_2 + \dots + W_p X_p$$

A saída y é dada:

$y = 1$, se $a \geq t$ ou $y = 0$, se $a < t$.

5.2 – FUNÇÕES DE ATIVAÇÃO

A função de ativação define a saída de um neurônio dentro de um especificado intervalo, com base em seu nível de atividade (MIRANDA, 2000). E pode ser classificada como:

- Função degrau simples (treshold function), é descrita como:

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

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

$$Y_k = \begin{cases} 1,0 & \text{se } P_k \geq 0 \\ 0 & \text{se } P_k < 0 \end{cases}$$

Com base no modelo neural de Mcculloch e Pitts (1943), o neurônio produz uma saída efetiva somente se o seu nível de atividade for maior que zero, como mostra a Figura 11.




Figura 11: Função degrau simples (treshold function).

➤ Função rampa (piecewise-linear function) é descrita como:

$$\varphi(P_k) = \begin{cases} 1,0 & \text{se } P_k \geq \frac{1}{2} \\ 1,0 & \text{se } -\frac{1}{2} < P_k < \frac{1}{2} \\ 0 & \text{se } P_k \leq -\frac{1}{2} \end{cases}$$

A função rampa diminui a função degrau se o fator de amplificação for tomado muito grande. Esta função pode ser comparada como uma aproximação de um amplificador linear, como mostra a Figura 12.




Figura 12: Função rampa (piecewise-linear function).

➤ Função sigmóide (sigmoid function) é a função mais utilizada na construção da rede neural e é definida como uma função contínua, suave e crescente. Esta função se apresenta em dois tipos:

1. Função logística (logistic function) é descrita como:

$$\varphi(P_k) = \frac{1}{1 + e^{(-\gamma P_k)}} \quad (8)$$

Onde γ é o parâmetro de inclinação da curva. A variação deste parâmetro implica na obtenção de funções com diferentes inclinações, podendo assumir qualquer valor do intervalo fechado $[0, 1]$. A função logística tenderá à função degrau simples, quando o parâmetro de inclinação tender ao infinito.

2. Função tangente hiperbólica (hyperbolic tangent function) é descrita como:

$$\varphi(P_k) = \frac{1 - e^{-\gamma P_k}}{1 + e^{-\gamma P_k}} \quad (9)$$

Esta função produz valores de saída do neurônio no intervalo fechado $[-1, 1]$, permitindo a existência de valores negativos, como mostra a Figura 13.




Figura 13: Função logística (logistic function), mostrando, em função do parâmetro γ , a variação da transição entre os dois estados (0 e 1).

5.3 - PROCESSOS DE APRENDIZADO

A propriedade mais importante das redes neurais artificiais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso ocorre através de um processo iterativo de ajustes aplicado a seus pesos sinápticos, o treinamento. O aprendizado ocorre quando a rede neural artificial atinge uma solução generalizada para um determinado problema.

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto existem os seguintes paradigmas de aprendizado:

- *Aprendizado Supervisionado*, quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada;
- *Aprendizado Não Supervisionado* (auto-organização), quando não existe uma agente externo indicando a resposta desejada para os padrões de entrada;

A fase de aprendizado deve ser verdadeira, a fim de evitar modelos falsos, pois a rede neural artificial se baseia nos dados para extrair um modelo geral. Todo o conhecimento de uma rede neural artificial está armazenado nos pesos sinápticos. A maioria dos dados deve ser separada para o treinamento da rede neural artificial, esses dados são escolhidos aleatoriamente, a fim de que a rede *aprenda* as regras e não *decore* exemplos. O restante dos dados somente é apresentado à rede neural artificial na fase teste a fim de que a rede possa *deduzir* corretamente o inter-relacionamento entre os dados.

5.4 – ALGORITMOS DE APRENDIZAGEM BACKPROPAGATION

Durante o treinamento com o algoritmo backpropagation, a rede opera em uma seqüência de dois passos. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado. O erro é propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado, como mostra a Figura 14.

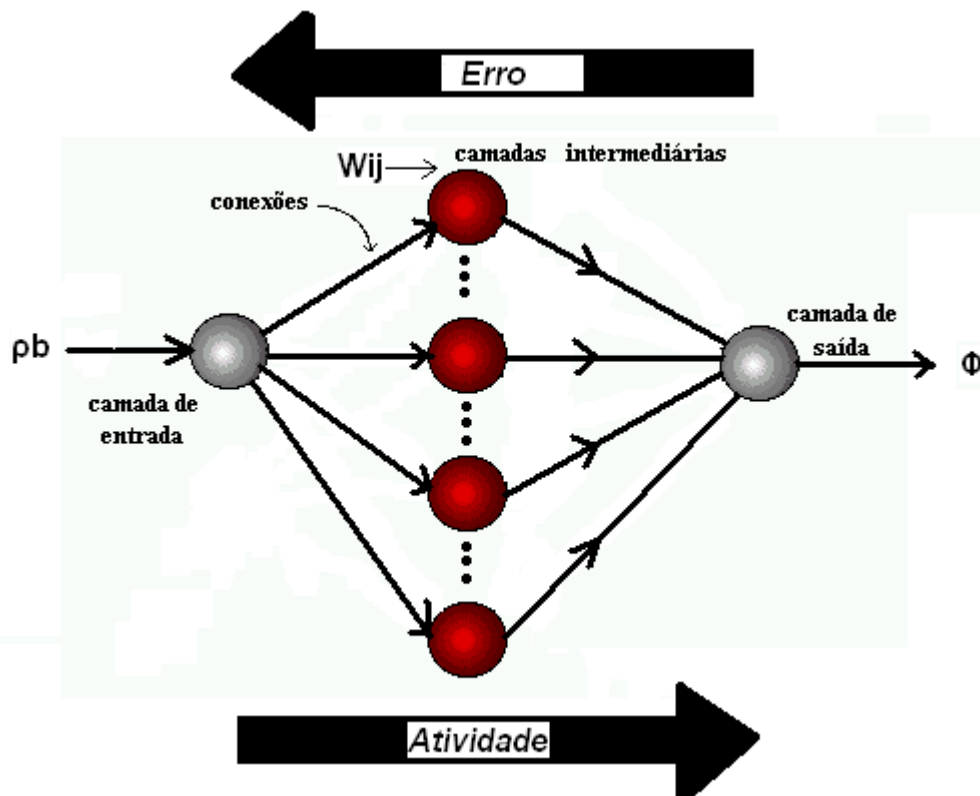


Figura 14 – Esquema de Treinamento Backpropagation.

Assim, é possível identificar duas fases distintas no processo de aprendizagem do backpropagation: aquela onde as entradas se propagam entre as camadas da rede, da camada de entrada até a camada de saída, e aquela em que os erros são propagados na direção contrária ao fluxo de entrada.

6 – TEOREMAS DAS APROXIMAÇÕES DE FUNÇÕES

A situação geral do mapeamento entre a entrada e a saída, pode ser mostrada da seguinte maneira (GOMES, 2002).

Dado um conjunto de dados de entrada com N valores diferentes $\{X_i \in \mathbb{R}^2 / i = 1 \text{ à } N\}$, e um conjunto de saída com N valores $\{d_i \in \mathbb{R}^2 / i = 1 \text{ à } N\}$, pode-se encontrar uma função $F: \mathbb{R}^2 \rightarrow \mathbb{R}^1$ que satisfaça a condição de interpolação (HAYKIN, 2001).

$$F(X_i) = d_i \quad i = 1, 2, \dots, N \quad (10)$$

Desta forma, a superfície de interpolação F obrigatoriamente passará em todos os pontos dos dados de treinamento. A técnica da rede com base em backpropagation consiste em escolher uma função F com a seguinte forma,

$$F(X) = \sum_{i=1}^N w_i \varphi(\|X - X_i\|). \quad (11)$$

Usando as condições de interpolação da equação (10) na equação (11), obtemos um sistema de equações lineares simultâneas para os coeficientes ou pesos sinápticos desconhecidos w_i ,

$$\Phi w = d, \quad (12)$$

Onde Φ representa uma matriz (N x N) de interpolação, com elementos φ_{ji} , na forma;

$$\Phi = \{\varphi_{ji} / (j, i) = 1, 2, \dots, N\} \quad (13)$$

$$\varphi_{ji} = \varphi(\|X_j - X_i\|), \quad (14)$$

Onde φ é a função de ativação da camada e $\|X_j - X_i\|$ é a norma euclidiana.

Considere,

$$d = [d_1, d_2, \dots, d_n]^T \quad (15)$$

$$w = [w_1, w_2, \dots, w_n]^T \quad (16)$$

Assumimos que Φ é não-singular, ou seja, que existe uma matriz inversa Φ^{-1} .

Resolvendo a equação (10) para o vetor de peso sináptico w , obtemos;

$$w = \Phi^{-1} d, \quad (17)$$

Os pontos $\{x_i\}_{i=1}^N$ são diferentes, sendo isto exigido para a não-singularidade da matriz de interpolação Φ , independente dos valores dos N pontos de dados ou do tamanho dos valores de entrada x_i .

7 – METODOLOGIA

Neste trabalho aplica-se a técnica computacional conhecida como *rede neural artificial*, biologicamente inspirada no comportamento do cérebro humano. A arquitetura apresentada é treinada com base no teorema da aproximação de funções, produzindo um mapeamento dos dados apresentados na *camada de entrada* e as respostas desejadas, na *camada de saída*.

O treinamento ocorre através de um processo iterativo de ajustes aplicados aos pesos sinápticos. Neste processo é determinada a relação ou função de mapeamento entre os dados do perfil de densidade e os valores de porosidade medidos em laboratório, para as mesmas profundidades. Deste modo, a partir do perfil de densidade e da porosidade determinada na análise de testemunho, para pontos de mesma profundidade, constrói-se os pares ordenados de entrada e saída desejada que formam o conjunto de treinamento da rede. O resultado teórico do treinamento é mostrado na Figura 15, com a definição da função de interpolação pelos pontos do conjunto de treinamento.

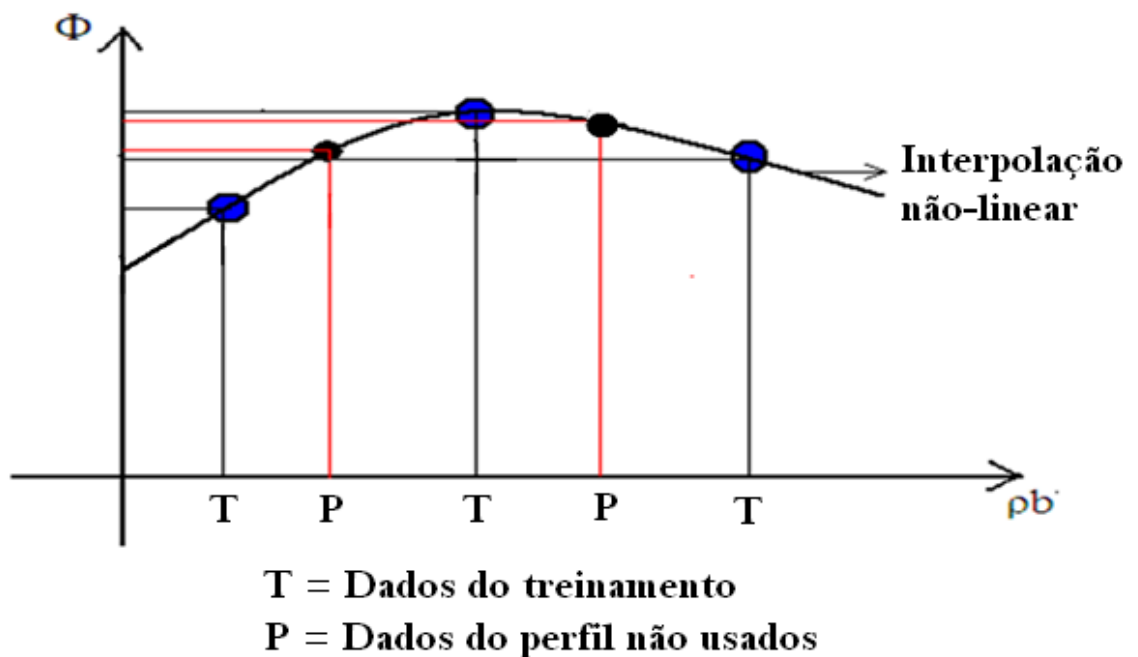


Figura 15 – Interpolação não-linear dos dados de treinamento.

O comportamento esperado da rede treinada é que ela seja capaz de estimar ou interpolar a função de mapeamento para valores de densidade não presentes no conjunto de treinamento, como mostrado pelos círculos pretos menores na Figura 15.

7.1 - ARQUITETURA DA REDE NEURAL

Neste trabalho estamos interessados nas qualidades de generalização ou na capacidade de estabelecer uma relação de ajuste entre os dados de entrada e os das respostas desejadas.

A arquitetura da rede neural utilizada é composta por três camadas. A primeira camada é a camada de entrada constituída por uma única unidade sensorial, responsável pela recepção do perfil de densidade. A segunda camada é a camada intermediária composta por 250 neurônios processadores que utilizam a função sigmóide como função de ativação. A terceira camada é a camada de saída composta por um único neurônio, responsável pela produção das estimativas da porosidade. A Figura 16 mostra a arquitetura de rede neural adotada neste trabalho de conclusão de curso.

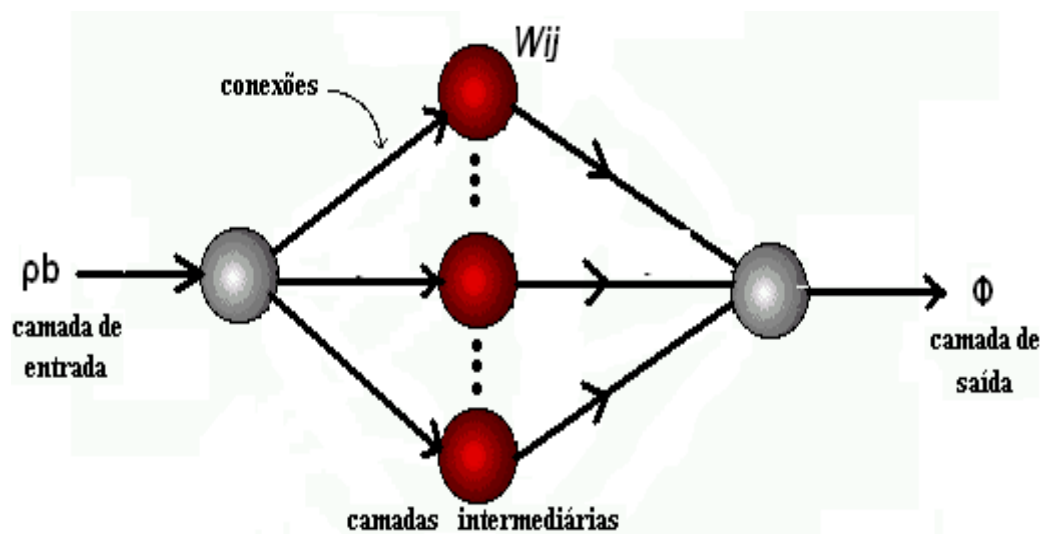




Figura 16 – Arquitetura da rede neural com três camadas: camada de entrada,

camada intermediária e a camada de saída.

7.2 - DADOS UTILIZADOS

São utilizados os resultados da análise de testemunho realizado sobre 18 (dezoito) amostras indeformadas de um poço petrolífero da Bacia de Campos (BASTOS, 1993), com valores de densidade no intervalo de 2,61 a 2,71 g/cm^3 , que são característicos para a rocha reservatório denominada de Arenito Namorado, como mostrado na Figura 17-A. A variação da densidade com a profundidade foi preservada. Sobre essas amostras foram realizadas as medidas diretas de porosidade, como mostrado na Figura 17-B, indicadas por meio dos asteriscos em azul. Os valores de profundidades foram arbitrados, de modo a possibilitar a representação de diversos intervalos testemunhados em um único perfil.






Figura 17 – (A): Perfil de densidade. (B): Perfil de porosidade.

8 – RESULTADOS

O objetivo da metodologia aqui apresentada é de produzir uma estimativa da porosidade, diretamente a partir dos valores de densidade. A rede neural treinada realiza uma interpolação não-linear dos valores no conjunto de treinamento composto por pares ordenados (densidade e porosidade) obtidos pela associação direta dos respectivos valores de densidade, extraídos do perfil e dos valores de porosidade obtidos durante os procedimentos da análise de testemunho. Na Figura 17-B, os pontos de porosidade utilizados para o treinamento da rede neural são marcados por asteriscos em azul.

Na fase de operação da rede neural backpropagation, foram utilizados 17 valores intermediários de densidade extraídos de diversas profundidades correspondentes ao arenito namorado e não conhecidos na fase de treinamento, com a finalidade de produzir uma avaliação da capacidade de generalização da rede neural para reproduzir valores de porosidade realistas, em função do resultado da análise de testemunho.

Na Figura 18 é apresentado o resultado do treinamento da rede, marcando por asteriscos em azul os pontos formados pelos pares ordenados com as abscissas representando os valores de porosidade produzidos pela rede neural e nas ordenadas os valores de porosidade obtidos na análise de testemunho, para um mesmo valor de densidade. A Figura 18 apresenta o resultado da operação da rede neural representado por círculos em vermelho. Observa-se uma aproximação razoável entre os valores de porosidade estimados pela rede e os valores produzidos na análise de testemunho em função da proximidade dos círculos em vermelho da reta a 45° produzida pelos dados de treinamento.




Figura 18 – Resultado do treinamento: Os asteriscos azuis mostram a operação da rede sobre o conjunto de treinamento. Resultados da operação: Os círculos em vermelho representam os valores da porosidade estimados pela rede.

A Figura 19 mostra o gráfico de erros produzido pela operação da rede neural sobre o conjunto de dados de operação. Observa-se que o erro máximo é da ordem de 2%.

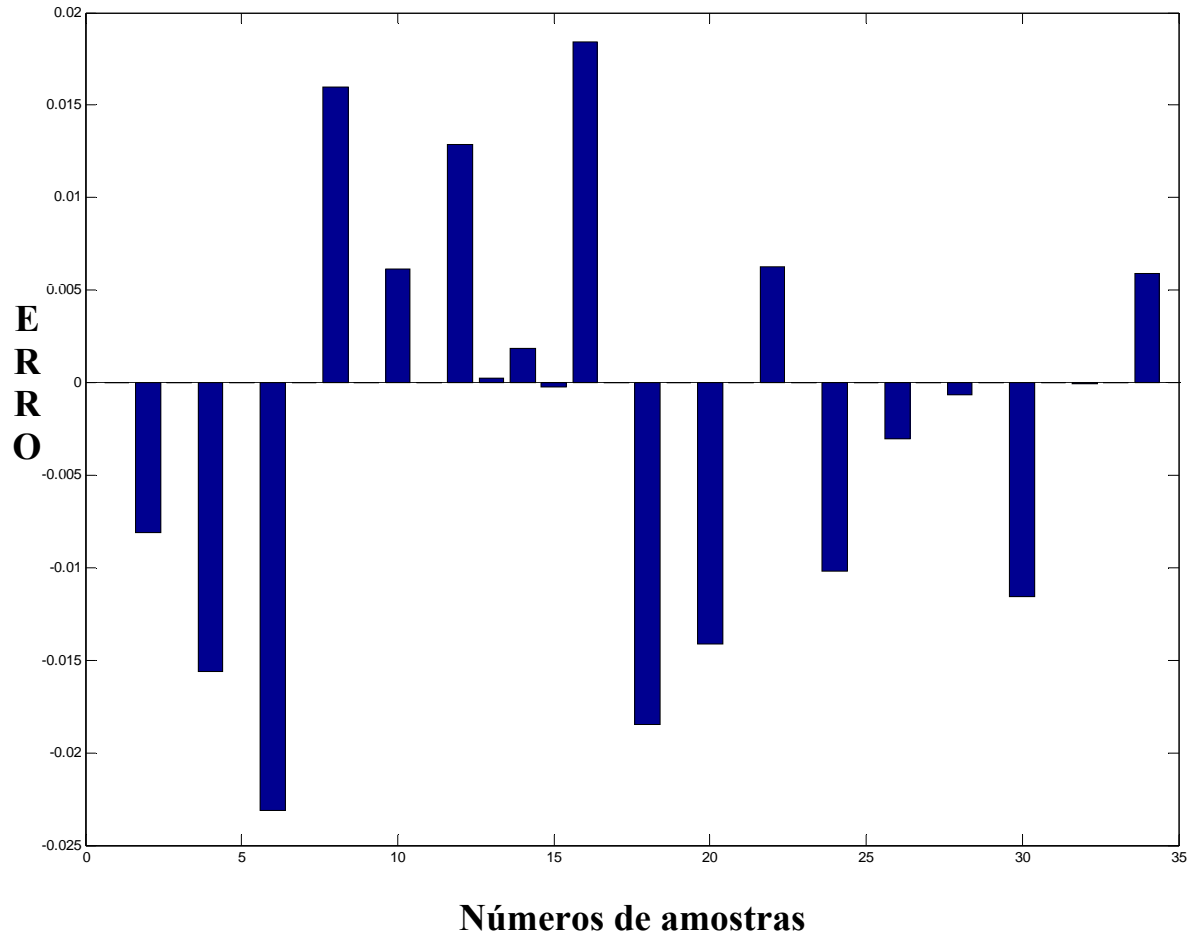


Figura 19 – Gráfico de erros.

A Figura 20-A mostra o perfil de densidade, mostrado anteriormente na Figura 17-A. A Figura 20-B mostra o perfil de porosidade produzido pela operação da rede neural representado pela linha em vermelho. Observa-se que a tendência não linear da dependência entre a densidade e a porosidade foi preservada.




Figura 20 – Resultado da aplicação da rede neural. (A) Perfil de densidade. (B) Perfil de porosidade direta em azul. O perfil de porosidade estimado pela rede neural é apresentado pela linha em vermelho.

9 – CONCLUSÃO

Neste trabalho, vimos que a porosidade é uma das mais importantes propriedades petrofísicas para a qualificação dos reservatórios de óleo e gás. A porosidade está relacionada à capacidade de armazenamento de fluidos nos espaços internos ou poros de uma rocha reservatório. Para estimar a porosidade nas rochas reservatórios são utilizadas duas fontes de dados, que são os testemunhos e os perfis geofísicos. A análise do testemunho que é realizada em laboratório fornece a medida direta da porosidade efetiva, enquanto que os perfis apresentam informações indiretas sobre a porosidade total, mas contínuas ao longo da profundidade do poço.

Entre essas duas fontes não se pode dizer qual é a melhor, as duas dão respostas razoáveis. Mas considerando que a análise dos testemunhos dá a porosidade efetiva, ela é melhor. Desse modo ao se treinar a rede neural com dados de porosidade efetiva, as estimativas de porosidade serão melhores do que as do perfil de densidade que é total.

A estimativa da porosidade é de fundamental importância e de interesse para indústria do petróleo, por isso procuramos uma melhor precisão dos valores da porosidade. Neste trabalho, por meio da rede neural backpropagation, nós integramos os dados do perfil com os dados do testemunho por fazer uma interpolação não-linear com a possibilidade de ter uma estimativa de valores mais realistas para o cálculo da porosidade efetiva. E o comportamento esperado da rede treinada é que ela seja capaz de interpolar também os valores de densidade não presentes no conjunto de treinamento

A capacidade da rede neural backpropagation de estimar a porosidade da formação ficou evidente nesse trabalho, pudemos observar, utilizando medidas do poço obtidas em laboratório, no caso dados da análise do testemunho sobre 18 (dezoito) amostras obtidas de um poço petrolífero nas profundidades correspondentes a ocorrência do Arenito Namorado,

na Bacia de Campos, que a interpolação não-linear produzida pela rede neural apresenta resultados compatíveis com os das análises do testemunho. E sendo capaz também de estimar mais 17 dados de valores de densidade não presentes no conjunto de treinamento.

REFERÊNCIAS

- ASQUITH, G.; GIBSON, C. *Basic well log analysis for geologists*. Oklahoma: AAPG, 216p, 1982.
- BASTOS, A. C. *Velocidades de ondas compressão e cisalhantes como indicadores de litologia e tipo de fluido contido em rochas porosas*. (Dissertação de mestrado) – Centro de Geociências, Belém, UFPA, 1993.
- BROCK, J.G. *Applied open-hole log analysis*. Texas: Gulf Publishing Company, V.2, 284p, 1986.
- GOMES, G. L. *Estimativa dos perfis de permeabilidade e de porosidade utilizando rede neural artificial*. (Dissertação de mestrado) – Centro de Geociências, Belém, UFPA, 2002.
- LUIZ, J. G.; SILVA C. M. L. *Geofísica de prospecção*. Belém, UFPA, 146p, 1995.
- GRATON, L. C.; FRASER, H. J. *Systematic packing of spheres with particular relation to porosity and permeability*. *Journal of geology*, 43: 785 – 909, 1935.
- HAYKIN, S. *Redes neurais – Princípios e Práticas*. 2ª Ed., Porto alegre, Bookman Companhia Editora, 2001.
- HEARST, J.R.; NELSON, P.H. *Well logging for physical properties*. New York: McGraw-Hill Book Company, 571p, 1985.
- LERCHE, I. *Geological risk and uncertainty in oil exploration: uncertainty, risk and strategy*. Academic Press, Inc 1997.
- McCULLOCH, W.; W. PITTS. *A logical calculus of the ideas imminent in nervous activity*. *Bulletin of Mathematical, Biophysics* 5: 115-33p, 1943.
- MIRANDA F. I. A. *Identificação automática das primeiras quebras em traços sísmicos por meio de uma rede neural direta*. (Dissertação de mestrado) – Centro de Geociências, Belém, UFPA, 2000.
- NERY. GIRÃO G. *Perfilagem de poço*. HYDROLOG Serviços de perfilagem Ltda, 2004..
- SCHLUMBERGER, *Avaliação das formações no Brasil – WEC Brasil*. Schlumberger, Brasil, 1985
- SERRA, O. *Fundamentals of well-log interpretation*. Amsterdam: Elsevier Science Publishers B. V., V.1, 423p, 1984.
- SUGUIO, K. *Introdução à sedimentologia*. São Paulo, Edgard Blucher, Ed. da Universidade de São Paulo, 1973.
- WASHBURN, E.W. *The dynamics of capillary flow*. *Phys. Rev.*, 17:273p, 1921.
- WONG, P. M. *Use of interpolation neural networks for permeability estimation from well logs*. School of Petroleum Engineering, The University of New South Wales. Sydney, 18 – 25p, 1998..
- WONG, P. M., GEDEON, T. D., TAGGART, I. J. *An improved technique in porosity predictions: A neural network approach*. *IEEE Transactions on geosciences and remote sensing*. 44: 971 – 980p, 1995.
- WONG, P. M., HENDERSON, D. J., BROOKS, L. *Permeability determination using neural network in the revva filed, offshore Índia*. *SPE Reservoir Evaluation and Engineering*. 1: 99 – 104p, 1998.
- WONG, P. M., TAGGART, I. J., JIAN, F. X. *A critical comparison of neural networks and discriminant analysis in lithofacies, porosity and permeability predictions*. *Journal of Petroleum Geology*. 18: 191 – 206p, 1995.