

UNIVERSIDADE FEDERAL FLUMINENSE
INSTITUTO DE GEOCIÊNCIAS - DEPARTAMENTO DE GEOLOGIA
PROGRAMA DE GRADUAÇÃO EM GEOFÍSICA

Análise e Modelagem de Parâmetros Petrofísicos de Reservatório
Utilizando Algoritmos Inteligentes.

Thonia Cardoso Senna

Orientador:

Rogério de Araujo Santos

Co-orientador:

Fernando de Roque

NITERÓI – RJ

Agosto de 2013

Modelagem e Análise de Parâmetros Petrofísicos de Reservatório Utilizando Algoritmos Inteligentes.

Thonia Cardoso Senna

Trabalho de conclusão de curso apresentado ao Programa de Graduação em Geofísica da Universidade Federal Fluminense em cumprimento às exigências para obtenção do título de bacharel em geofísica aprovado por:

Dr. Rogerio De Araujo Santos
Petrobras e Universidade Federal Fluminense

Ms. Fernando de Roque
Petrobras

Dr. Guilherme Fernandes Vasquez
Petrobras

Dr. Rodrigo Bagueira de Vasconcellos Azeredo
LAR, Universidade Federal Fluminense

NITERÓI - RJ

Agosto de 2013

Dedico este trabalho a Deus e a todos os jovens que, ao contrário de mim, não tiveram as mesmas oportunidades de dedicarem-se aos estudos.

AGRADECIMENTOS

Primeiramente, a Deus, que fez com que este obstáculo não fosse grande demais que, com a fé eu não pudesse superar.

Aos meus pais Wilson e Janine e ao meu irmão Breno que sempre investiram e acreditaram em mim, pelo incentivo constante e apoio incondicional e à minha avó Maria (*in memoriam*), que me criou e estaria materializando um sonho na minha formatura. À minha segunda mãe Susanna Eleonora Sichel e minha irmã Luiza, que sempre estão ao meu lado. À minha tia Margot, por ter me ajudado a chegar até aqui e nunca ter negado seu colo materno quando eu precisava.

Ao meu orientador, prof. Dr. Rogerio de Araujo Santos e ao meu co-orientador, Fernando de Roque, por me guiarem com paciência, ao prof. Dr. Rodrigo Bagueira e ao geofísico da Petrobras Guilherme Vasquez, igualmente pela paciência e desvelo na análise deste trabalho .

À UFF, em especial ao LAGEMAR e cada um de seus funcionários, por ter me auxiliado nesta empreitada, em especial às secretárias Vanessa e Ana Paula, pela gentileza e solicitude sempre que precisei e à professora Eliane da Costa Alves, pela dedicação ao nosso curso.

Ao Observatório Nacional, especialmente ao professor Cosme Ferreira, que foi meu primeiro orientador e incentivador e que foi muito paciente comigo em minha primeira Iniciação Científica, tão importante em minha formação.

Aos meus amigos de fora da UFF, pela compreensão de minha ausência física em diversos momentos e por estarem sempre por perto. Aos amigos que a UFF me deu. Levarei sempre comigo os momentos de alegria, *stress* e cumplicidade.

À minha amiga Giselle Alves, pela ajuda com SciLAB e por caminhar sempre ao meu lado.

À compreensão dos colegas da Schlumberger, Michelle Chaves, Maria Clara, Marina Fagundes, Carina Ramos, Fábio Novaes, Pedro Barros, Steve Klug e Rafael Aleixo, que flexibilizaram meus horários para que eu pudesse conciliar o estágio com as atividades acadêmicas.

Aos amigos do SIS (Schlumberger Information Solutions), Allison Guedes, Cicero Neves e Leandro Martins, pela paciência e apoio científico.

A todos outros que, de forma direta ou indireta, possibilitaram que eu alcançasse mais esta conquista.

RESUMO

O presente trabalho consiste na implementação, aplicação e avaliação de um método de simulação de porosidades efetivas baseando-se em algoritmos inteligentes a partir das densidades de pontos pertencentes às mesmas amostras, cujos parâmetros foram medidos em laboratório e são referentes a um poço do Campo Escola de Namorado.

O levantamento geofísico de poço permite a obtenção indireta de medidas contínuas de diferentes propriedades físicas da sequência de rochas atravessadas por um poço, ao passo que a análise de testemunhos consiste numa obtenção direta de tais propriedades, que são medidas de maneira discreta, em profundidades específicas. Tais mensurações podem então ser analisadas, e interpretadas, e, sendo conjugadas com os perfis de poços, possibilitam a elaboração de modelos matemáticos e geológicos, o diagnóstico e a distribuição de fluidos intersticiais, bem como a identificação de camadas-guia através de assinaturas geofísicas peculiares apresentadas pelas mesmas, fornecendo informações sobre as propriedades da rocha *in situ* e permitindo a correlação entre poços a níveis estratigráficos, e, conseqüentemente, a inferência de zonas produtoras.

Porosidade é definida como a porcentagem ou fração de espaços vazios da rocha em relação ao volume total da mesma, constituindo assim um parâmetro de indiscutível relevância na detecção de possíveis reservatórios, uma vez que quantifica a capacidade que uma dada litologia apresenta de reter fluidos e explicita seu potencial como rocha reservatório, respaldando a tomada de decisões.

Visando uma contextualização mais eficiente do leitor em relação ao estudo doravante apresentado, será feita uma revisão teórica das propriedades físicas intimamente relacionadas com a porosidade, sobre as quais esta obra está alicerçada, bem como aspectos relevantes das redes neurais artificiais, nicho computacional no qual os parâmetros utilizados foram tratados. Posteriormente, será explicada a metodologia empregada, os resultados obtidos e, na conclusão, a verificação da viabilidade das ferramentas empregadas e da consistência dos resultados gerados pelos algoritmos inteligentes com a teoria apresentada anteriormente.

Palavras- chave: *testemunhos, algoritmos inteligentes, redes neurais artificiais, porosidade efetiva.*

ABSTRACT

The present work consists in the implementation, application and evaluation of a method to simulate effective porosity based on intelligent algorithms from density values. These petrophysical parameters were measured in a Petrobras' laboratory, and were extracted from cores collected in Namorado Field, located in Campos Basin, Brazil.

The geophysical well survey allows obtaining indirect and continuous measurements of various physical properties of a rocks sequence crossed by a well, while the core analysis consists in obtaining direct evidence of such properties, which are measured discretely, at specific depths. Such direct measurements can then be analyzed and combined with well logs, making it possible the development of mathematical and geological models, the diagnosis and distribution of interstitial fluids, as well as the identification of guide-layers through its specific and distinctive geophysical signature, providing information about the properties of the rock in situ and the correlation between wells, in stratigraphic levels, and, thus the inference productive zones.

The porosity is defined as the percentage of voids in relation to the total volume of a lithology, and hence constitutes an undeniably relevant parameter for detecting possible reservoirs, since it quantifies the ability that a given lithology has to retain fluids and explicits its potential as reservoir rock, supporting decision making. Aiming at a more efficient contextualization of the reader in relation to the study henceforth presented, there will be a theoretical review of the physical properties closely related to the porosity, on which this work is based, as well as relevant aspects of artificial neural networks, computational niche where the parameters were treated. Subsequently, the methodology and the results obtained are presented, and in the conclusion, the verification of the feasibility of the tools employed and the consistency of the results generated by intelligent algorithms with the theory presented will be covered.

Keywords: Core analysis, Intelligent Algorithms, Artificial Neural Networks, Effective Porosity.

SUMÁRIO

1- Introdução.....	8
2- Objetivo.....	9
3- Base de Dados.....	10
4- Porosidade.....	11
4.1- Tipos de Porosidade.....	11
4.1.1- Classificação quanto à Gênese.....	11
4.1.2- Classificação quanto à Comunicabilidade Inter-Poros.....	11
4.2- Fatores que Governam os Valores de Porosidade.....	12
4.3- Medição da Porosidade.....	14
4.3.1- Medidas Diretas.....	14
4.3.2- Medidas Indiretas.....	14
4.3.2.1- Perfil de Porosidade Neutrônica.....	14
4.3.2.2- Perfil de Densidade.....	15
4.3.2.3- Perfil Sônico.....	17
5- Considerações sobre Redes Neurais Artificiais.....	18
5.1- O Neurônio Artificial.....	19
5.2- Treinamento: Processos de Aprendizado.....	20
5.3- Redes Neurais Baseadas em Retro-Propagação do Erro.....	22
5.4- Funções de Ativação.....	24
6- Metodologia.....	25
7- Resultados.....	28
8- Discussões e Conclusões.....	31
9- Referências Bibliográficas.....	33

1- INTRODUÇÃO

A importância do conhecimento da porosidade efetiva como parâmetro de reservatório reside no fato de este parâmetro quantificar a capacidade de armazenamento de fluidos em poros não isolados da rocha reservatório. Normalmente as medições ocorrem em laboratório, através de testemunhos extraídos do poço.

No entanto, a testemunhagem onera os levantamentos e nem sempre é possível (por exemplo, se a rocha apresentar baixa cimentação), fazendo com que nem todos os poços contem com este recurso. No caso do poço ser testemunhado, apesar das medidas realizadas no laboratório serem usualmente bastantes confiáveis- embora nem sempre sejam reproduzidas as condições ambientais da rocha *in situ* – estas são discretas, geralmente esparsas ao longo de um poço, tornando-se útil a inferência computacional do comportamento das curvas de porosidade poço abaixo, a fim de que se tenha uma estimativa contínua de um parâmetro relevante, derivada de dados medidos de forma direta.

O resultado deste trabalho, caso seja aperfeiçoado futuramente, não apresenta a menor pretensão de substituir ou rarefazer o uso da testemunhagem, essencial na geofísica de poço, mas de sim extrair ainda mais informações de seus resultados através de uma técnica computacional robusta.

Neste trabalho avaliou-se a viabilidade das redes neurais para uma formação geológica específica, com princípios que podem ser reproduzidos para a obtenção de porosidades efetivas em outros reservatórios. A metodologia baseou-se em redes neurais artificiais implementadas com o software *MATLAB*, com o precioso auxílio dos engenheiros de software da empresa SCHLUMBERGER, que forneceram todo o diferencial teórico necessário para a execução da presente obra.

2- OBJETIVO

A idéia deste trabalho consiste em apresentar uma nova abordagem do cálculo da porosidade, de forma a testar a robustez e a confiabilidade de um algoritmo inteligente baseando-se em redes neurais artificiais, cuja fundamentação teórica será apresentada posteriormente. Por tratar-se de uma área que já foi amplamente analisada por diversos profissionais renomados, os resultados obtidos pelo algoritmo poderão ser comparados quantitativa e qualitativamente com outras referências, sendo confrontados com os esperados (medição em laboratório) e correlacionados entre si.

A presente proposta ambiciona, desta forma, apresentar e testar uma ferramenta que consiste num método baseado em redes neurais artificiais, algoritmos inspirados no processamento do cérebro humano que possui habilidade de aprendizado através de treinamento (ou seja, aptidão no reconhecimento e inferência de padrões, e, com base nestes padrões ou leis de formação, busca eficiência e robustez na solução de problemas a ela apresentados), bem como habilidade de adaptação a situações adversas, governadas por imprecisões severas de medidas físicas e/ou precariedades dos dados. Analisando-se metodologias comumente utilizadas para a obtenção das porosidades, percebe-se que a Equação de Wyllie, que relaciona densidade e porosidade, é a mais empregada. Todavia, o emprego desta relação pressupõe o conhecimento prévio da litologia e das propriedades do fluido. Pelo fato da relação entre estas propriedades ser conhecida desde os primórdios da geofísica de poço e também das medidas de testemunhos em laboratório serem obtidas de forma discreta e muitas vezes esparsas ao longo de um poço, torna-se útil que se procure estabelecer - através de um algoritmo inteligente - uma forma de inferir o comportamento destes parâmetros ao longo da formação de interesse. Tal resultado, além de orientar a equipe técnica acerca da capacidade do reservatório, facilita a interpretação das camadas adjacentes.

A idéia é que a rede neural reconheça tais padrões (densidade-porosidade) e codifique convenientemente assinaturas geológicas. No entanto, como a Geologia não é uma ciência exata, seus parâmetros raramente são codificados de forma completa por equações matemáticas, são esperados erros. Tais incertezas devem-se ao fato de haver outros fatores que alteram a porosidade efetiva, nem sempre afetando a densidade, bem como à parca quantidade de pontos que populam o espaço amostral de medidas consideradas neste trabalho.

3- BASE DE DADOS

A base de dados considerada neste trabalho é resultante da medida de propriedades físicas dos testemunhos de um poço do Campo de Namorado, localizado na Bacia de Campos, Brasil. As mensurações foram realizadas em um laboratório da PETROBRAS, diretamente sobre os testemunhos e estão tabeladas na tese de mestrado de Bastos (1993). Os dados de porosidade foram obtidos por um porosímetro de Boyle. Confina-se a amostra que se deseja medir em uma célula do tipo Hassler (figura 1) e introduz-se nitrogênio nesta amostra. A redução da pressão mensurada é diretamente proporcional ao volume de gás que adentrou os poros e, conseqüentemente, ao volume poroso que se deseja medir. Uma vez que o volume total da amostra seja conhecido, temos a porosidade: $100 \cdot (\text{Volume da amostra ocupado pelos poros}) / (\text{Volume total da amostra})$. As densidades foram obtidas pela razão entre a massa e o volume dos sólidos totais acrescidos da água estrutural (argila). A porosidade das amostras varia de 1,6% a 23,2% e é predominantemente secundária, intergranular devido à dissolução de cimento anidrítrico. Outra categoria de porosidade diagnosticada nos testemunhos em questão é de “encolhimento”, resultante da perda de volume através de uma reação química que transforma a gipsita em anidrita, provocando o aparecimento de poros alongados ao redor dos grãos. Valores inesperados de porosidade (“*outliers*”) são, neste caso, resultantes deste fenômeno (Bastos,1993).



Figura 1: Célula Hassler acoplada ao porosímetro Ultrapore-300 e permeâmetro Ultraperm-500. Fonte: <http://www.ufflar.com/>

4- POROSIDADE

Este parâmetro petrofísico, por consistir na porcentagem de espaços vazios em uma rocha quando comparados ao seu volume, é uma das propriedades mais relevantes na indústria de exploração de hidrocarbonetos, afinal, relaciona-se com a capacidade de armazenamento de fluidos de uma determinada litologia.

4.1- TIPOS DE POROSIDADE

A porosidade pode ser classificada tanto a respeito de sua gênese quanto a respeito da comunicabilidade entre seus poros.

4.1.1- CLASSIFICAÇÃO QUANTO À GÊNESE

A respeito de sua causa, de sua formação, a porosidade pode ser classificada como:

-Deposicional (ou primária): regida pela quantidade de espaços vazios resultantes do processo de sedimentação. Os arenitos, por exemplo, apresentam espaços vazios entre os grãos que os compõem, espaços estes formados durante seu processo de acumulação.

-Pós-deposicional (ou secundária): governada por processos posteriores ao momento da deposição, subsequente ao processo de litificação. Uma fratura que ocorra no corpo rochoso, por exemplo, ou dissoluções carbonáticas que podem atingir magnitudes de vugos ou até mesmo cavernas (porosidade vugular), são exemplos de ocorrências de porosidade secundária.

4.1.2- CLASSIFICAÇÃO QUANTO À COMUNICABILIDADE INTER-POROS

Além das classificações supracitadas, a porosidade também pode dicotomizar-se em absoluta ou efetiva. A primeira diz respeito à porcentagem total de espaços porosos na rocha, ao passo que a segunda considera apenas aquela de interesse comercial. Desta forma, a porosidade efetiva contabiliza somente os poros interconectados (ou não-isolados) e tal distinção é fundamental, uma vez que nas mensurações advindas das ferramentas de perfilagem de poços, são computadas porosidades totais, enquanto a recuperação de fluidos é controlada pela porosidade efetiva, conferindo-lhe interesse comercial. A presença de argila no sedimento em questão reduz a porosidade efetiva, uma vez que obstrui os poros.

Assim, embora a porosidade medida pelos perfis considere tanto os vazios interconectados ou não, (conforme pode ser visto na figura 2), tal porosidade aparente pode ser aproximadamente corrigida para a porosidade de interesse (efetiva) a partir do volume de argila presente no sedimento em questão. Basta saber que a porosidade aparente é a soma do volume de argila com a porosidade efetiva.

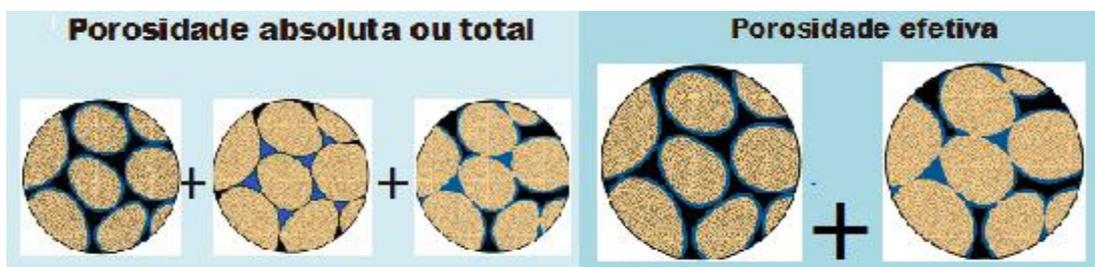


Figura 2- Diagrama esquemático, cujo objetivo é explicitar a diferença entre porosidade absoluta e efetiva.

4.2- FATORES QUE GOVERNAM OS VALORES DE POROSIDADE

A porosidade pode ser afetada por diversos fatores, sendo os mais importantes:

-Arranjo de grãos- o *packing* dos grãos (ou empacotamento) tem sido considerado um importante fator influenciador da porosidade. As maiores porosidades normalmente registradas são provenientes de sedimentos com partículas achatadas e caoticamente empacotadas. Na figura 3, (a) e (b) estão ilustrados dois diferentes *packings* ideais e suas devidas porosidades matemáticas.

-Seleção de partículas- um dos fatores que governam com maior significância o valor da porosidade. Quanto melhor a seleção dos grãos, maior será a porosidade- o que é bastante intuitivo, pois sedimentos bem selecionados apresentam poucas partículas de menor granulometria, que podem obstruir os poros resultantes da acomodação dos sedimentos mais grosseiros. Ver figura 3, (c) e (d).

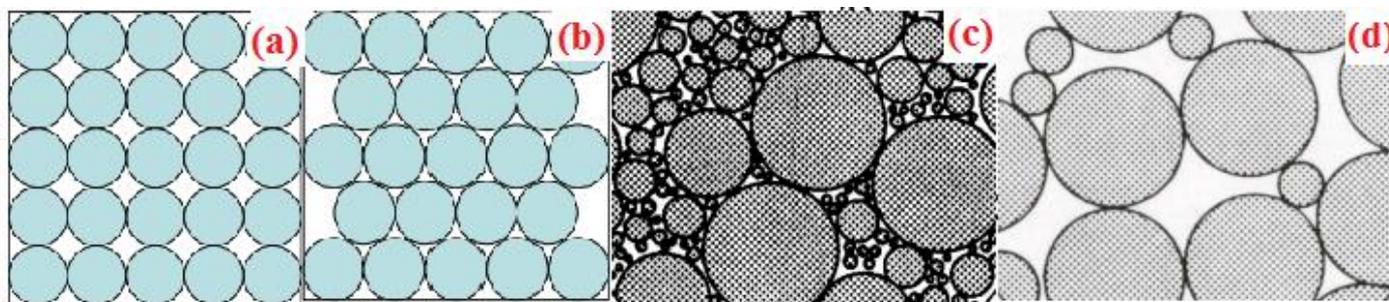


Figura 3- Influência do arranjo das partículas (a) e (b) e de seu selecionamento (c) e (d) na porosidade. Em (a) está esquematizado um arranjo cúbico, que fornece uma porosidade de 47,64%. Em (b), o arranjo romboédrico, com porosidade de 25,95%. Em (c) é mostrado o impacto dos grãos mal selecionados na porosidade, que é calculada neste exemplo como sendo 17%. Quando o selecionamento melhora (d), a porosidade passa a 32%. Modif. de Suguio(1973).

-Tamanho das partículas- tem sido notado na prática que partículas mais grosseiras apresentam porosidade menor que partículas de menor granulometria, provavelmente por sua trama ou disposição dos grãos (*packing*) ou por sua orientação, o que pode ser percebido na tabela 1, modificada de Pettijohn (1957).

Tabela1- influência do tamanho dos grãos na porosidade. Modificada de Pettijohn, 1957.

Granulação	Porosidade (%)
Areia Grossa	39-41
Areia Média	41-48
Areia Fina	44-49
Silte Fino	50-54

-Forma dos grãos- quanto mais irregulares forem as partículas, maior valor de porosidade será registrado na rocha.

-Cimentação- é intuitivo e também percebido na prática que, após o preenchimento dos poros por cimento, a porosidade diminui. No caso de um arenito de porosidade de 30-40%, esta pode passar a 15-20% após a cimentação.

-Compactação- As camadas que se encontram soterradas sofrem compactação por parte dos sedimentos a esta sobrejacentes, causando decréscimo de porosidade . Um arenito pode passar- a título de ilustração- de 35-40% para 15-20% (Suguio, 1973). Na figura 4, pode-se observar melhor o efeito da compactação perante a porosidade.

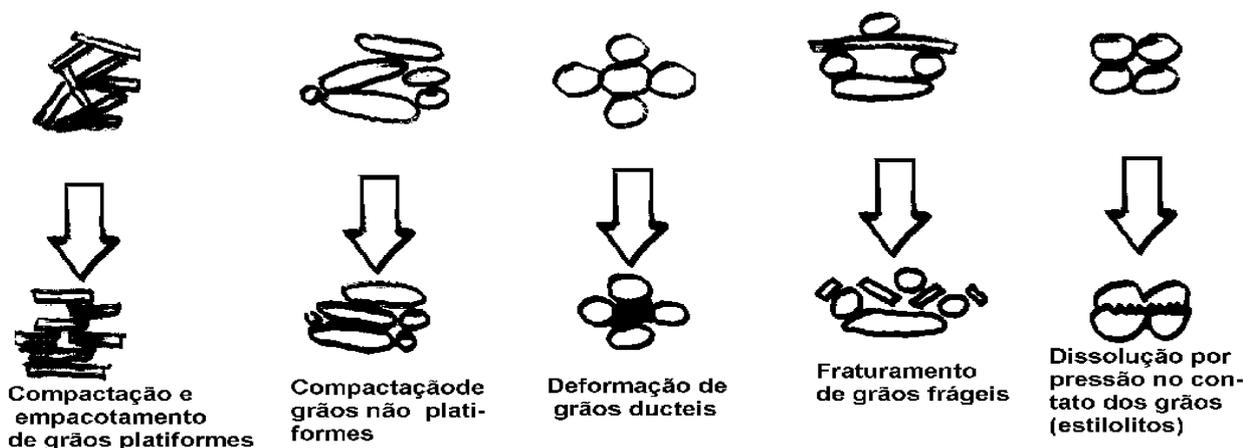


Figura 4- Alguns dos possíveis efeitos da compactação sobre a porosidade. Modif. De Suguio, 1973.

4.3- MEDIÇÃO DA POROSIDADE

Diversos métodos podem ser empregados na medição da porosidade. Podem ser considerados como diretos- no caso de medição em laboratório, analisando uma amostra- ou indiretos- caso em que as medidas são realizadas no interior do poço, por ferramentas de perfilagem.

4.3.1- MEDIDAS DIRETAS

A medida direta refere-se ao resultado da leitura de uma magnitude mediante o uso de instrumento. Como exemplo, podemos citar a medição de um valor de corrente elétrica através de um amperímetro ou de uma massa com uma balança. Podemos considerar também a medição por estimativa visual macro ou microscópica- a primeira através de uma lupa e a segunda de um microscópio. No entanto, tais medidas nem sempre são confiáveis, devido a sua subjetividade. Dentre as formas de medição direta da porosidade, a análise em um porosímetro de Boyle, que já foi explicada anteriormente, foi a técnica empregada na obtenção dos dados utilizados neste trabalho.

4.3.2- MEDIDAS INDIRETAS

A medida indireta é aquela que resulta da aplicação de uma relação matemática que vincula a grandeza a ser medida com outras que podem ser medidas de forma direta. Na mensuração da porosidade, estas são fornecidas pelas ferramentas de perfilagem neutrônica, de densidade e sônica explicadas a seguir. Valores de porosidade absoluta são inicialmente obtidos e, posteriormente, corrigidos para fornecer uma aproximação da porosidade efetiva.

4.3.2.1- PERFIL DE POROSIDADE NEUTRÔNICA

Este perfil é medido utilizando uma fonte de nêutrons, que são partículas destituídas de carga elétrica cujo valor de massa aproxima-se da massa dos átomos de hidrogênio. Elementos não-radioativos são bombardeados com nêutrons de alta energia cinética, que têm sua velocidade reduzida por espalhamento inelástico na primeira interação com a formação e, após esta atenuação, o novo nível energético possibilitará sucessivas interações do tipo elástica.

Através das sucessivas e múltiplas colisões, que causam espalhamento elástico, os nêutrons perdem parte da energia com que foram injetados e a quantidade de energia perdida será proporcional à massa do núcleo colidido. A medição refletida neste perfil é referente esta classe de espalhamento. As leis físicas que hegemonicamente regem a formulação das equações interpretativas são referentes à conservação da energia e do momento em colisões elásticas e as medidas são governadas basicamente pela quantidade de hidrogênio na formação. Isto se deve ao fato de que a massa nuclear do hidrogênio é

de magnitude semelhante à do nêutron incidente, fazendo com que, efetivamente, sejam os átomos de hidrogênio os principais responsáveis pela resposta de amplitude do sinal captado.

No entanto, é sabido que a maior concentração de hidrogênio está presente nos fluidos intersticiais presentes nos poros, fazendo com que a porosidade e o sinal detectado estejam diretamente relacionados. Assim sendo, quanto maior a quantidade de hidrogênio, maior o volume de fluidos aprisionados na rocha, e, conseqüentemente, maior será sua porosidade.

Além deste perfil ser utilizado na avaliação da porosidade, também o é na detecção de gás.

4.3.2.2- PERFIL DE DENSIDADE

O perfil de densidade tem sua fundamentação prática e teórica alicerçada na interação da radiação gama com o meio, utilizando-a na obtenção de um registro contínuo das variações destas interações, que dependerão das massas específicas (densidades) de cada camada rochosa atravessada pela ferramenta.

O dispositivo medidor deste perfil consiste em uma fonte de raios gama, que incidirão sobre a formação com alta energia e interagirão com seus elétrons, produzindo uma resposta que é identificada em um detector da variabilidade destas interações. As interações podem ser classificadas em três categorias: Efeito Fotoelétrico, Efeito Compton e Produção de Pares elétron-pósitron, sendo este último sem interesse na técnica aqui descrita.

No efeito fotoelétrico, o raio gama colide com os elétrons e cede para os mesmos toda sua energia, fazendo com que estes sejam ejetados e passem a interagir com átomos adjacentes. Geralmente são substituídos por outro elétron vizinho. O efeito Compton, ilustrado na figura 5 também é observado em interações dos raios gama com os elétrons, no entanto, somente uma parte da energia daqueles é cedida a estes.



Figura 5 - Diagrama esquemático do Efeito Compton. O fóton incidente transfere uma parte de sua energia E_0 para um elétron e um fóton de energia reduzida E' deixa o local da colisão obliquamente à direção de incidência. (Modificada de Bassiouni, 1994).

A frequência na qual este efeito ocorre é proporcional ao número de elétrons por unidade de volume e a figura 6 ilustra de forma esquemática as respostas típicas de densidade das principais litologias. A equação 2 descreve a relação entre a densidade da formação e o número de elétrons por unidade de volume, onde n_e representa o número de elétrons; N_0 , a constante de Avogadro; Z , o número atômico; A , o peso atômico; e , ρ_b , a densidade da formação.

$$n_e = N_0(Z/A)\rho_b \text{ (Equação 1)}$$

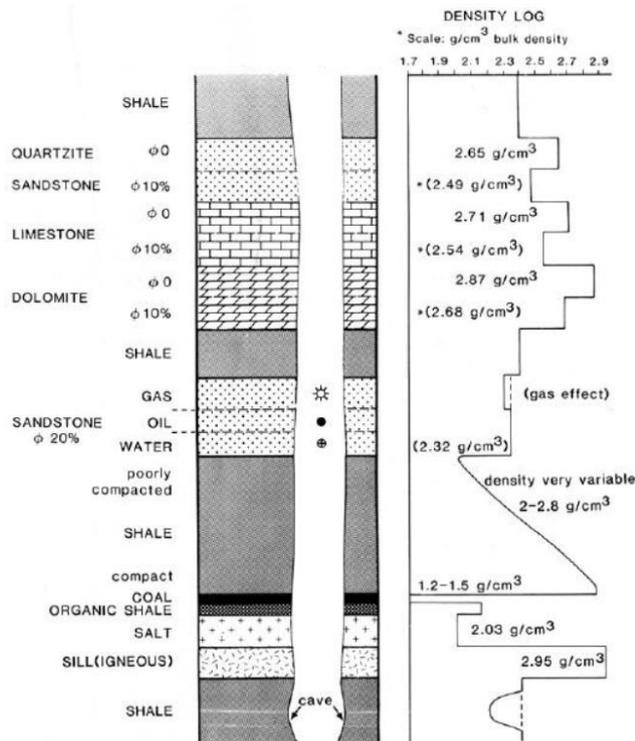


Figura 6 - Padrões típicos de densidade das principais litologias (Rider, 2002)

Assim, através da medida da densidade da rocha e do fluido na formação, a equação de Wyllie pode ser utilizada na obtenção da porosidade.

$$\rho_b = (1 - \varphi) \cdot \rho_M + \varphi \cdot \rho_f \text{ (Equação 2)}$$

Onde:

- ρ_b : densidade resultante da amostra;
- ρ_M : densidade da matriz rochosa que compõe a amostra;
- ρ_f : densidade do fluido que ocupa os poros da amostra;
- φ : porosidade da amostra.

4.3.2.3- PERFIL SÔNICO

O perfil sônico (*ou perfil acústico ou DT*) é resultado da medição da velocidade de propagação do som no meio sólido atravessado pela ferramenta, e, por isso, é empregado em conjunto com a interpretação sísmica, uma vez que permite correlacionar tempos da sísmica com as profundidades do perfil, permitindo assim efetuar uma calibração tempo-profundidade.

Primeiramente mede-se o tempo de trânsito, na unidade microssegundo por pé ($\mu\text{s}/\text{ft}$) e também é chamado de vagarosidade (*slowness*) e dele deriva-se a velocidade.

Além desta aplicação, o perfil sônico também apresenta grande valia na determinação da litologia (utilizando-se a razão entre velocidade de ondas compressão e velocidade de ondas cisalhantes), correlação de poços, indicação da porosidade secundária, avaliação do cimento situado entre o revestimento do poço e a formação e determinar a impedância acústica (em combinação com o perfil de densidade).

A ferramenta convencionalmente utilizada apresenta uma fonte que emite impulsos ultrassônicos com uma frequência constante e dois receptores distanciados de um valor conhecido (normalmente cerca de 300 mm), conforme mostrado na figura 7.

Os pulsos são propagados pela formação e atingem os receptores que, ativados, registram os sinais recebidos. O que será medido é o tempo gasto pela onda no percurso entre dois receptores. De acordo com a camada atravessada, a onda pode viajar mais ou menos rapidamente, propagando-se mais rapidamente em sólidos que em fluidos. Este perfil fornece uma relação direta com a porosidade, pois, dadas duas rochas de mesma composição mineralógica, a que contiver maior volume de fluido intersticial apresentará maior porosidade e maior tempo de trânsito.

Desta forma, este perfil estabelece uma relação direta entre a velocidade do som medido na rocha e a sua porosidade, utilizando o tempo de trânsito e uma equação semelhante à de Willye (Gomes, 2002).

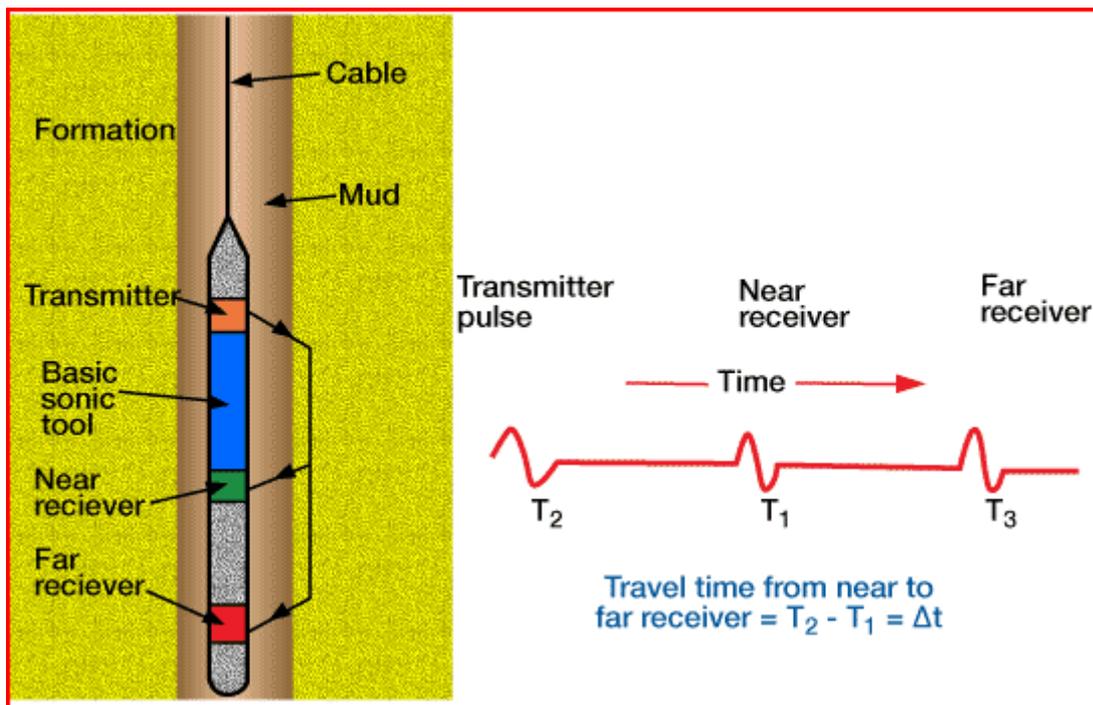


Figura 7- Representação esquemática de uma típica ferramenta de perfilagem sônica. Disponível em www.ipims.com/schlumberger

5- CONSIDERAÇÕES SOBRE REDES NEURAIS ARTIFICIAIS

Sistemas de redes neurais artificiais foram criados com apoio em fatos que a neurociência descobriu acerca do funcionamento do cérebro humano, possibilitando que conhecimentos contidos em um problema possam ser decodificados e representados por conexões entre células nervosas. Por serem baseadas nas redes neurais biológicas, as redes neurais apresentam capacidade de treinamento, generalização a partir de exemplos e a abstração de características essenciais de informações que contêm fatos irrelevantes e, desta forma, proporciona fantástica capacidade de processamento e armazenamento de informação (Gomes, 2002), o que as difere de um algoritmo sequencial, dado que as informações, durante o processamento, são difundidas por toda sua arquitetura- o que é ilustrado na figura 8, em que cada entrada X_i é recebida por mais de um neurônio da rede.

Esta distribuição permite que as informações sejam redundantemente representadas no interior da rede, fazendo com que, mesmo que uma parte da rede seja destruída, a informação contida nesta parte ainda possa ser recuperada por estar presente em outras partes da mesma. Isto confere ao método robustez e alta tolerância a falhas. Também admirável é sua capacidade de adaptação a condições severas de imprecisão e parcialidade dos dados, problemas cotidianos no trabalho do Geofísico.

Neste trabalho será predominantemente explorada a habilidade que as redes neurais artificiais apresentam de reconhecer padrões, bem como de discernir e extrair características estatisticamente relevantes dos comportamentos dos dados de entrada.

Segundo Poulton (1992), o objetivo do treinamento da rede neural é fazer com que esta produza, a partir de um número finito de exemplos, uma parametrização ou função de mapeamento que possa ser aplicada a dados completamente inéditos para a rede. Durante esta fase, que será doravante explicada, os pesos são mantidos constantes e os testes são realizados. O treinamento cessa quando as incertezas calculadas pelo algoritmo atingem um patamar de estabilidade. Todos os fatores supracitados, bem como o costume em lidar com este tipo de formulação, justificaram a utilização desta importante ferramenta na abordagem deste trabalho.

Basicamente, uma rede é composta por uma camada de entrada, que recebe informações externas, camada interna, onde ocorre o processamento dos dados e reconhecimento de padrões, e a camada de saída, que interage novamente com o meio externo, conforme ilustrado na figura 8. Para saídas com valores discretos, a rede deve agir como um classificador e o modelo binário é a abordagem mais clássica. Caso se deseje uma saída contínua, a rede montada deverá exercer também papel de interpolador.

Analogamente ao cérebro humano, as redes neurais são formadas por neurônios, elementos processadores não-lineares que são dispostos em camadas e representados por dendritos, núcleo e axônio. Os dendritos representam um conjunto de sinapses (impulsos nervosos que um neurônio transmite a neurônios a ele vizinhos), às quais são atribuídos valores denominados pesos sinápticos, que ponderam a conexão entre camadas.

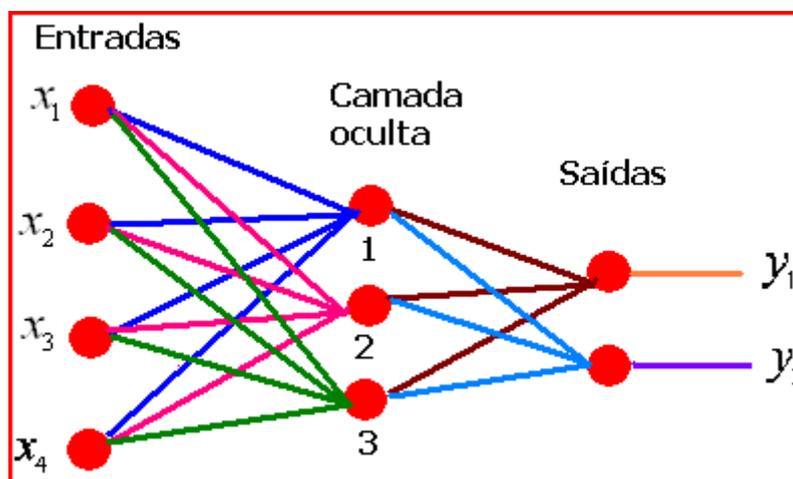


Figura 8 - Representação esquemática de uma rede neural artificial.

5.1- O NEURÔNIO ARTIFICIAL

Inspirado no comportamento do neurônio biológico, o neurônio artificial apresenta total analogia com este, e, sendo a unidade fundamental na operação de uma rede neural artificial, é responsável pelo processamento das informações.

Sinapses também ocorrem no interior de uma rede neural artificial. Um conjunto sináptico consiste em um grupo de valores ponderadores que caracterizam ligações entre neurônios. Um sinal

fornecido por um neurônio conecta-se a um outro neurônio e é tratado de acordo com o peso sináptico referente a estes dois neurônios. Uma vez que a saída de um neurônio é recebida, sendo entrada em outro neurônio, esta é combinada com o ponderador através de uma função de ativação, que será mostrada mais adiante neste trabalho.

A analogia funcional entre o modelo bioneurológico e o computacional sugere que os pesos correspondam aos dendritos de nosso cérebro, as funções de ativação ao núcleo celular e o axônio, às saídas do neurônio artificial, conforme ilustrado na figura 9.

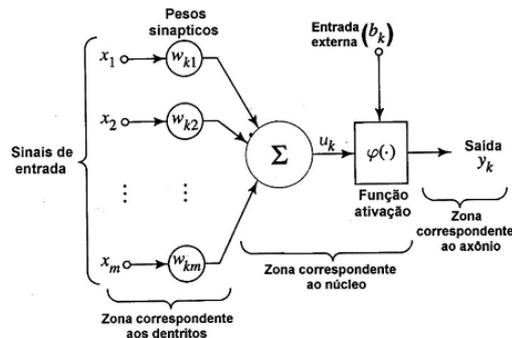


Figura 9- Analogias funcionais existentes entre o neurônio biológico e o artificial (LIMA, 2000).

5.2- TREINAMENTO: PROCESSOS DE APRENDIZADO

Conforme explicado anteriormente, o aprendizado a partir do diagnóstico de uma lei de formação não-linear de geração de saídas consistentes com o vetor alvo é uma das mais notáveis características de uma rede neural artificial.

Na criação da rede, o usuário configura um conjunto bastante específico de regras que a rede deve seguir para encontrar a solução desejada.

Quando a rede chega a uma solução generalizada que mapeia o vetor de entrada numa aproximação aceitável do vetor de saída, diz-se que a mesma aprendeu a decodificar o problema. O aprendizado exige um treinamento, no qual ocorrem ajustes dos pesos a fim de que a adaptabilidade a diferentes entradas seja aperfeiçoada. Antes que o treinamento seja realizado, é recomendável que o usuário ajuste o percentual de pontos que a rede separará em três subconjuntos para serem usados no treinamento, na validação e no teste. Cada um destes três subconjuntos são mutuamente excludentes e seus elementos variam a cada teste executado.

Isto torna mandatória- caso se deseje um bom ajuste- a realização de vários treinamentos, até que bons resultados sejam conseguidos.

Normalmente, cada vez que um treinamento é realizado, o MATLAB (*software* em que os dados foram processados) fornece automaticamente gráficos de regressão para que o usuário possa saber como foi o desempenho de sua rede naquele treinamento. Para isto, é fundamental que se saiba interpretar os resultados do treinamento.

A implementação de redes neurais é um processo que requer bastante experiência. Primeiramente, deve-se fazer uma análise visual dos resultados, adquirida com a prática. Se estes estiverem satisfatórios (conceito subjetivo, mas proveniente do costume em lidar com esta técnica), os valores numéricos devem ser examinados. O gráfico de “*training*” mostra o desempenho da rede para os pontos que esta utilizou em seu treinamento. O gráfico de “*validation*” fornece ao usuário a noção de como a rede se saiu para alguns pontos não utilizados no ajuste dos pesos. Isto mostra o quão “viciada” a rede encontra-se nos dados utilizados no treinamento. O gráfico de “*test*” mostra o desempenho da rede no ajuste de pontos que não foram utilizados no ajuste de pesos e nem na validação. Este gráfico fornece ao usuário uma idéia de como a rede se sairia caso a esta fossem apresentados pontos inéditos. Na figura 10, podem ser vistos quatro exemplos de gráficos para uma rede que foi testada, e, posteriormente descartada por suas precárias representações das porosidades efetivas do problema.

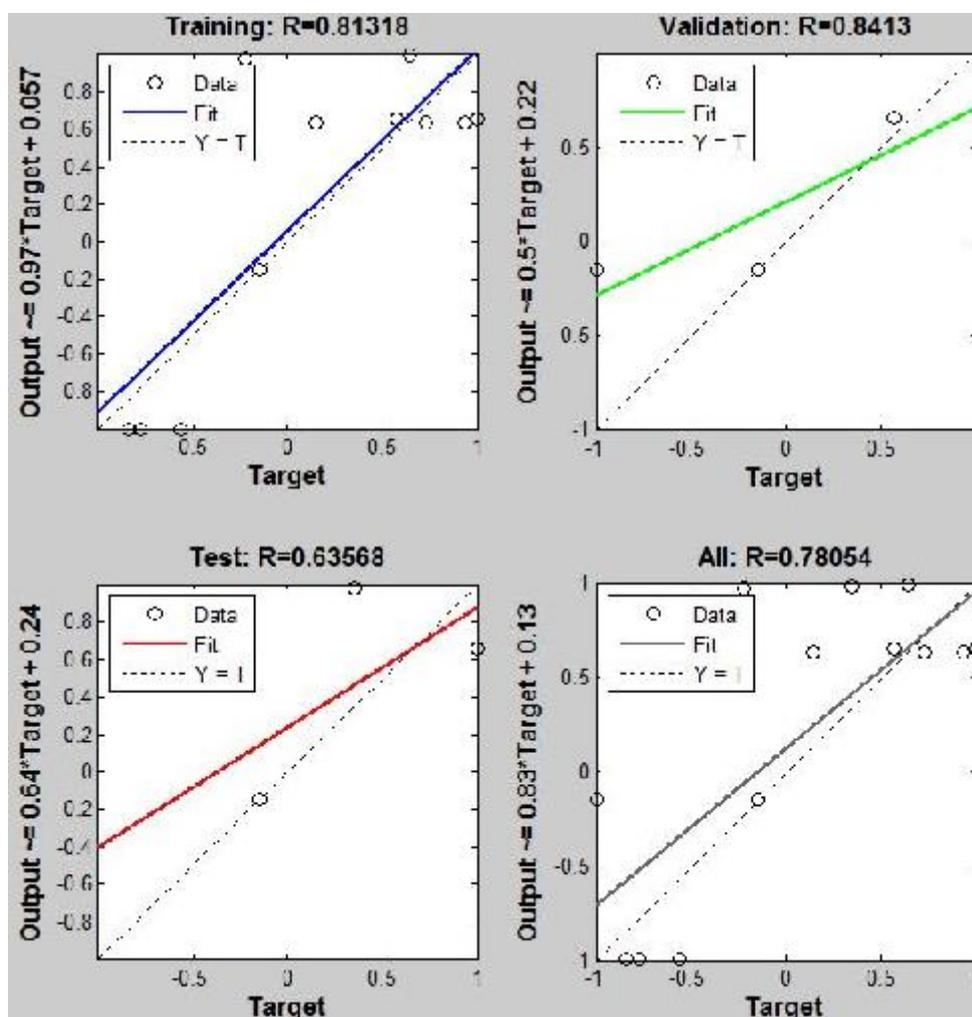


Figura 10- gráficos ilustrativos resultantes de um exemplo de simulação de rede.

As redes neurais podem ser configuradas utilizando-se diversos processos de aprendizado. No entanto, a familiaridade com este tipo de ferramenta conduziu à escolha de um processo de aprendizado por correção de erros, que implica, a grosso modo, em definir a maneira com que os erros são calculados. Cada cálculo gera um valor de erro, que é disposto graficamente. No final, uma curva é gerada, assim como apresentado na figura 11. Neste processo, é realizada uma varredura sobre a curva de erros. O objetivo é a detecção do ponto de mínimo global da curva de erros.

De maneira geral, o aprendizado pode ser classificado em dois tipos:

-Supervisionado- um agente externo fornece uma referência acerca do objetivo a ser alcançado. Este é o tipo de aprendizado adotado no presente trabalho.

-Não-Supervisionado- também conhecido como *self-organizing*, neste tipo de aprendizado nenhuma referência acerca da resposta desejada é fornecida por agentes externos.

5.3- REDES NEURAS BASEADAS EM RETROPROPAGAÇÃO DE ERROS

Neste modelo de rede, também conhecido como *backpropagation*, o reconhecimento dos padrões é realizado através de dois passos: inicialmente, a rede recebe o vetor de entradas (densidades obtidas em laboratório), processa-o através dos parâmetros configurados pelo usuário e produz uma resposta que, ao chegar na camada de saída, é comparada com o vetor- alvo (que neste trabalho é a porosidade dos testemunhos).

A comparação destes primeiros valores produzidos pela rede com o vetor *target* gera um valor de erro. O fluxo contrário de informação ocorre à medida que este erro migra da camada de saída até a camada de entrada, provocando um reajuste dos pesos sinápticos a fim de que se calcule uma nova saída, de menor erro.

A retropropagação do erro, esquematizada na figura 12, ocorre até que seja encontrada uma solução dada pela rede como ótima ou até que sejam cumpridos o número máximo de iterações estipuladas pelo usuário, e que, portanto, dependerá dos parâmetros de criação da rede.

Para a configuração da rede deste trabalho foi decidido que o método de aprendizado a ser conjugado com a retropropagação de erros seria o *gradient-descent*, baseado na regra de Widrow-Hoff, que, ao ser generalizada para redes de múltiplas camadas, tem apresentado bons resultados na modelagem de diversos problemas à medida que busca otimizar parâmetros livres através da busca de valores na direção de maior magnitude do gradiente negativo da curva de erros (*steepest descent gradient searching*).

A solução é baseada no cálculo da superfície de erro, mostradas nas equações 4, 5, 6 e 7, gerada a partir dos valores de erros calculados para cada ciclo. Quando esta superfície for do tipo parabolóide, haverá apenas um mínimo na função de erro (no ponto de derivada nula).

Todavia, nem sempre os problemas apresentam nível de complexidade baixos e a superfície de erros pode ser extremamente irregular e a derivação pode ser inexequível. Quando isto acontece, as redes sujeitam-se a problemas de mínimos locais ao invés de um único mínimo global (ver figura 12).

$$\Delta w_{ji}^l = \eta \cdot \delta_j^l \cdot y_i^{(l-1)}(n)$$

$$\Delta b_j^l = \eta \cdot \delta_j^l$$

Δw_{ji}^l = ajuste da sinapse do neurônio escondido (ou da camada de entrada) i para o neurônio j da camada l;

Δb_j^l = ajuste do “bias” do neurônio j na camada l;

η = taxa de aprendizagem;

δ_j^l = gradiente do neurônio j na camada l;

$y_i^{(l-1)}$ = a saída do neurônio i.

$$\delta_j^l = \begin{cases} e_j^l \cdot F'_j[net_j^l(n)] & \text{se } l = L \\ F'_j[net_j^l(n)] \cdot \sum_k \delta_k^{(l+1)} \cdot w_{jk}^{(l+1)}(n) & \text{se } l < L \end{cases}$$

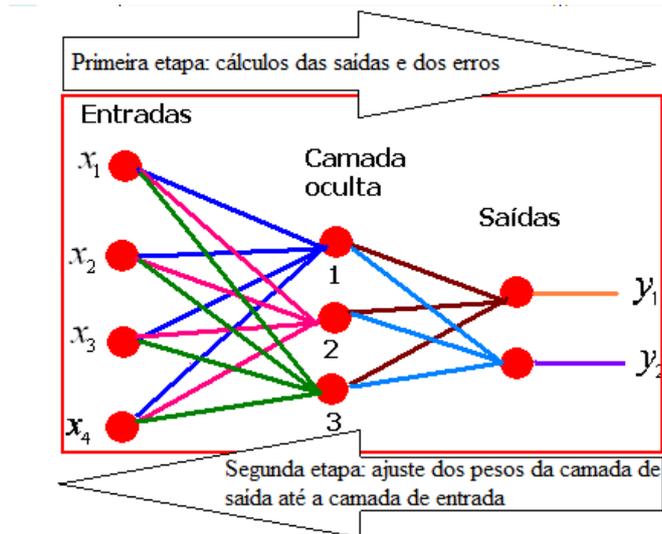


Figura 11- Modelo esquemático do funcionamento de uma rede neural de arquitetura backpropagation.

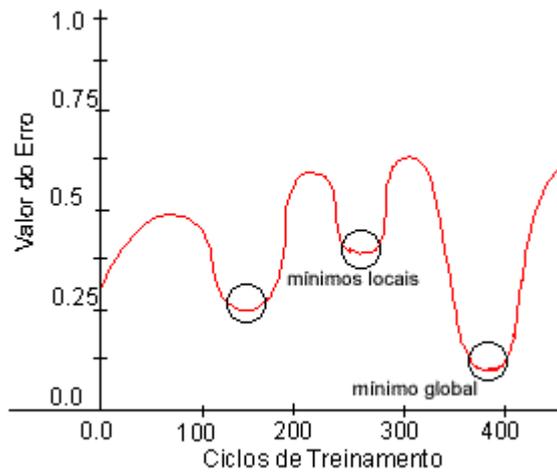


Figura 12- Gráfico de uma possível superfície de erros mostrando mínimos locais e mínimo global.

5.4- FUNÇÕES DE ATIVAÇÃO

De acordo com Miranda (2000), uma função de ativação define a saída de um neurônio dentro de um intervalo específico, com base em seu nível de atividade. Age limitando a amplitude de saída de um neurônio ao intervalo fechado $[0,1]$ ou $[-1,1]$. Basicamente, foram testadas para este problema combinações de três funções de ativação diferentes, sendo estas:

-Função rampa

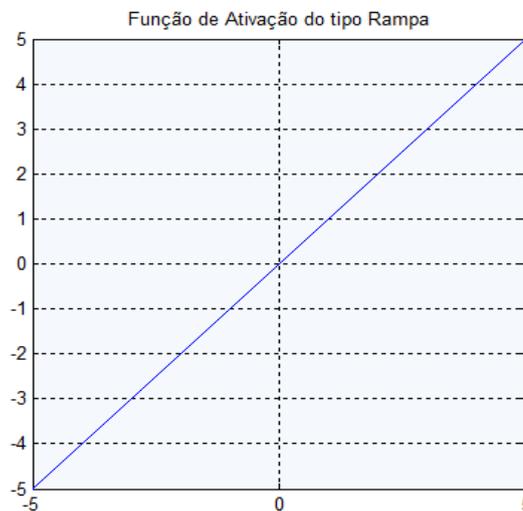


Figura 13- Ilustração da função de ativação do tipo rampa.

-Função logaritmo-sigmoidal



Figura 14- Ilustração da função de ativação do tipo logaritmo-sigmoidal.

-Função tangente sigmoidal



Figura 15- Função de ativação do tipo tangente sigmoidal.

6-METODOLOGIA

Os algoritmos inteligentes consistem em um recente campo de estudo inserido na ciência da computação cuja preocupação é, através de tentativas de explicar e emular comportamentos inteligentes, automatizá-los- o que é especialmente útil em situações em que o volume de dados é grande. Estes algoritmos inteligentes podem ser, por exemplo, modelados por redes neurais artificiais, computação evolutiva ou inferência *fuzzy*. A metodologia deste trabalho baseia-se na técnica computacional de redes neurais, explicada anteriormente neste trabalho.

Um algoritmo inteligente deve ser capaz de armazenar conhecimento, aplicá-lo à resolução de problemas e agregar outros conhecimentos adquiridos. Adicionalmente, é uma ferramenta poderosa, que colabora na resolução de diversos problemas, provenientes de vários campos da ciência e da engenharia, transformando dados em informação e informação em conhecimento (Nikraves, 2004).

A partir de vetores de densidade e porosidade obtidos através da análise laboratorial de testemunhos, (tabela 2) deseja-se mapear a relação existente entre estes dois parâmetros neste reservatório através de uma rede neural de retropropagação de erro, que foi explicada anteriormente.

Tabela 2- Plugues utilizados e respectivas profundidades, porosidades e densidades. Modif. de Bastos, 1993).

Plugue	Prof.(m)	ϕ (%)	ρ (g/cm ³)
943h	2504.90	22.5	2.66
944h	2505.30	23.0	2.65
945h	2505.40	23.2	2.65
945v	2505.40	23.2	2.65
D4873h	2505.70	19.4	2.63
947h	2505.90	20.3	2.66
D4874h	2505.95	14.8	2.60
948h	2506.25	23.1	2.65
949h	2506.80	16.2	2.69
950h	2507.10	18.6	2.65
950v	2507.10	18.6	2.65
D4875h	2507.40	14.0	2.66
951h	2507.60	10.0	2.71
D4876h	2507.75	5.0	2.69
954h	2508.55	3.3	2.74
D4878h	2509.55	1.9	2.71
D4879h	2509.70	1.6	2.72
955h	2509.85	4.0	2.74
956h	2510.20	10.8	2.72
956v	2510.20	10.8	2.72
958h	2510.95	6.3	2.74

A justificativa para a escolha deste tipo de arquitetura reside na sua habilidade, respaldada pela literatura e por vivência em redes neurais, de ajustar funções de alta complexidade, pois funciona através da comparação da saída da rede com a saída-alvo, calcula vetores de erro, a partir dos quais redistribui internamente os pesos de forma a melhorar a qualidade da saída. Tais comparações são realizadas até que o menor erro seja alcançado ou que o número de “ciclos” seja atingido.

A proposta deste trabalho é, portanto, verificar a viabilidade da solução por redes neurais para este “dataset”, fornecendo dados de entrada (densidades), treinando a rede no reconhecimento de padrões destes dados e, armazenando o conhecimento experimental a fim de se conseguir realizar uma parametrização desta relação entrada-saída, de forma que, cada vez que sejam apresentados à rede novos valores de densidade, esta consiga mapeá-los, fornecendo as respectivas porosidades.

A implementação da rede foi realizada nos *softwares* MATLAB e SciLAB através de linhas de comando. O fluxograma da criação desta categoria de algoritmo apresenta as seguintes etapas: criar os padrões, inicializar a rede, definir parâmetros de treinamento, treinar e testar a rede. A cada vez que os parâmetros eram ajustados, a rede era treinada e, caso as respostas fossem satisfatórias, as saídas eram plotadas num gráfico (Porosidade fornecida pela rede X Porosidade fornecida pelo testemunho).

Foram testadas centenas de configurações de parâmetros (diferentes arquiteturas, funções de ativação, aprendizagem, número de neurônios, etc.), com auxílio da literatura e dos engenheiros de *software* da empresa *SCHLUMBERGER*, que forneceram materiais e leitura e tiraram dúvidas durante a realização deste trabalho.

Na fase de inicialização da rede são definidas especificidades comportamentais da rede, como os padrões de entrada, o número de neurônios, funções de ativação e algoritmo de treinamento. Os dados de treinamento (entrada e saída) foram vetores contidos no vetor de pares ordenados (densidade,

porosidade) assinalados, respectivamente, com “*” e “o” na figura 16, onde são mostrados em suas profundidades originais.

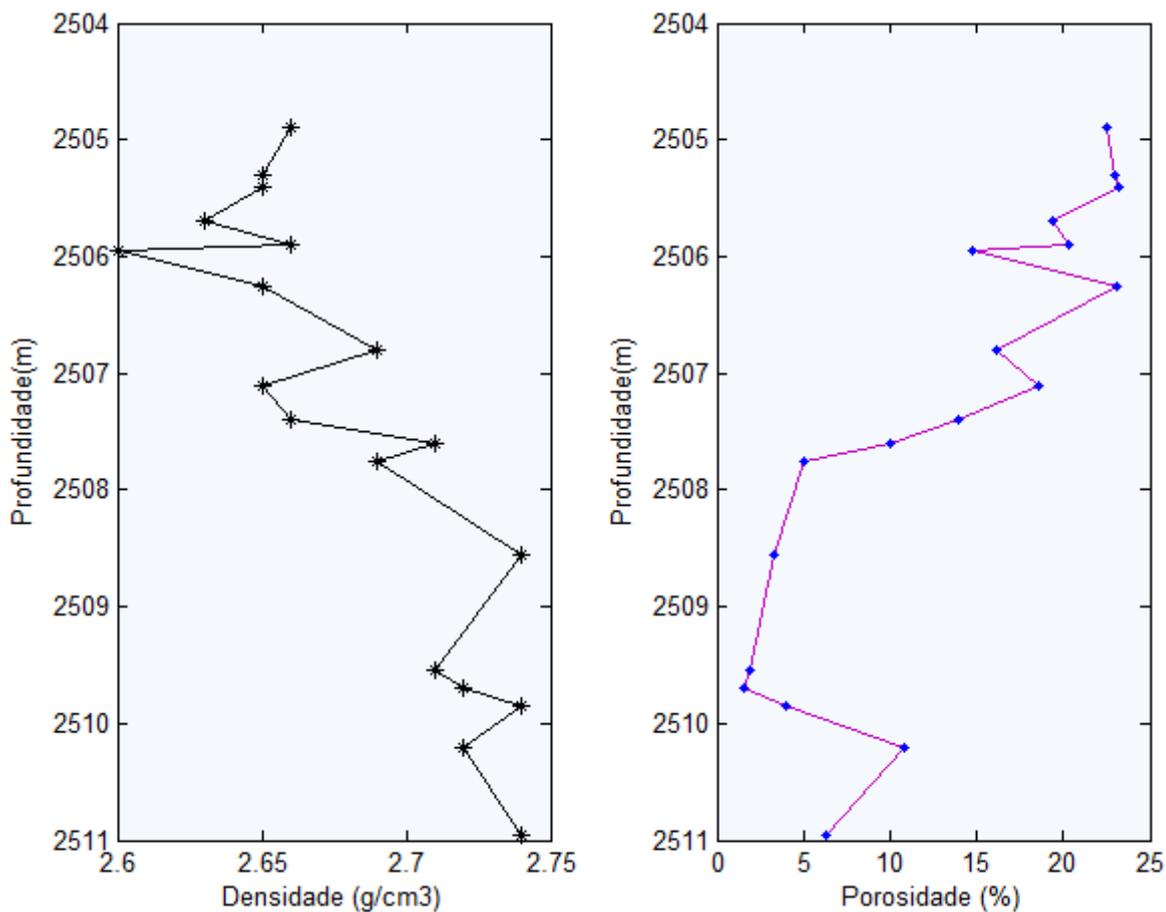


Figura 16- Pares ordenados densidade (esquerda) e porosidade (direita) obtidos através de testemunhos. Bastos, 2002.

Inicialmente, foram selecionados alguns valores intermediários de densidade dos testemunhos, a partir dos quais a rede foi treinada (para um número de amostras inferior aos mostrados na figura 16).

A cada vez que o resultado de um treinamento era satisfatório e coerente, a rede era salva e a segunda etapa de testes começava: a robustez da rede foi testada para vários subconjuntos de pares ordenados pertencentes ao conjunto de valores medidos em laboratório. Este procedimento visou verificar a capacidade de reconstrução da rede e adaptação a situações de vetores de diversas magnitudes (porque a escassez de dados é um problema frequente).

A rede foi treinada, desta forma, com um número de amostras inferior ao total disponível, a fim de que a rede aprendesse o padrão que levava as entradas às saídas. Após aprovada nesta fase, foram apresentados à rede valores que a mesma não conhecia, a fim de que fosse validado o resultado final.

A função de ativação eleita para a rede foi a sigmoideal. A rede conta com uma camada na qual os dados de densidade são recebidos (*input layer*), com uma camada oculta (*hidden layer*) – que contava

com 12 neurônios processadores e outra de saída (*output layer*), na qual os dados de porosidade são ejetados.

A fim de saturar a função e otimizar a performance da rede, os vetores foram normalizados com o auxílio da função “mapminmax” do MATLAB, tanto na entrada e na saída quanto no treinamento. Quando a rede fornecia a resposta e esta era satisfatória, os valores de porosidade- entre -1 e 1 devido à normalização- foram transformados em valores realistas. Esta é uma técnica corriqueira, aprendida na prática, com o manuseio deste tipo de problemas.

7-RESULTADOS

Inicialmente a rede foi treinada com um vetor de pares ordenados (densidade, porosidade) cujos elementos são subconjuntos do vetor de dados total. A rede foi treinada só através destes pontos (menos pontos que o espaço amostral disponível) e a porosidade fornecida pela rede foi plotada na figura 16, a título de comparação, com a porosidade esperada.

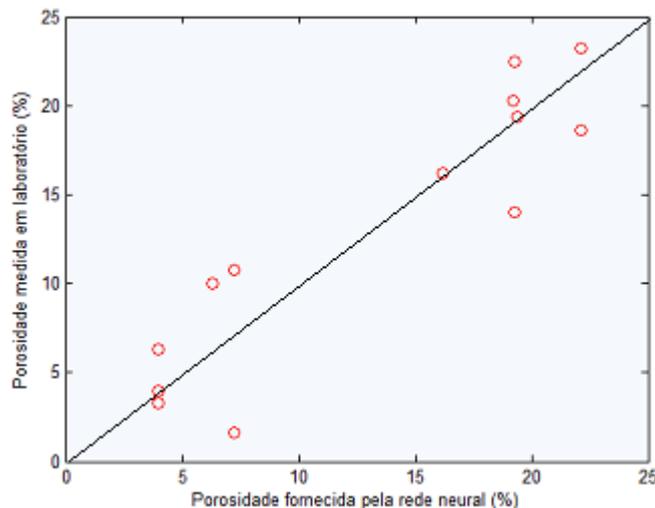


Figura 17- gráfico comparativo entre a saída fornecida pela rede e a saída-alvo.

Posteriormente, foram apresentados à rede todos os dados disponíveis, que constituem um espaço amostral maior que o utilizado no treinamento dos dados. Desta forma, a rede precisou adaptar-se a pontos desconhecidos e a resposta foi plotada sobre o gráfico acima, que já continha os círculos vermelhos. Os asteriscos azuis mostram a operação da rede sobre o novo conjunto de pontos.

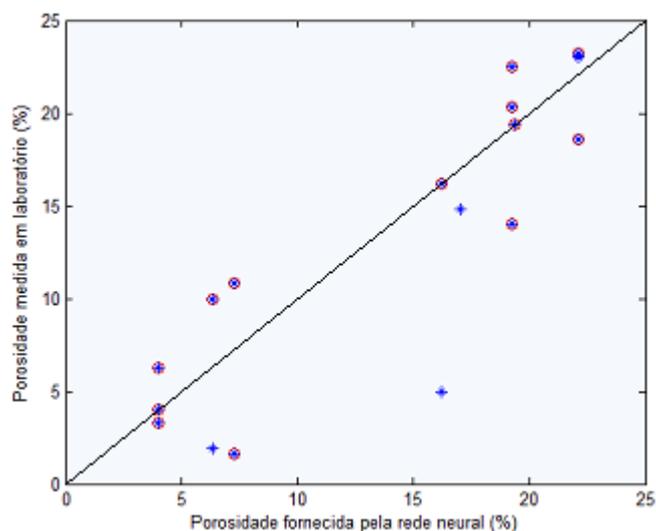


Figura 18- gráfico de verossimilhança que compara as operações da rede sobre os dois conjuntos de pontos (total e parcial). O conjunto total, composto por todas as amostras disponíveis, é representado por asteriscos azuis e o conjunto parcial, por círculos vermelhos.

Através da análise dos dados de laboratório, percebe-se que estes nem sempre seguem um padrão que torne simples uma generalização pelas redes, que, no caso de *outliers*, foi precária devido à reduzida quantidade de pontos em face da complexidade do problema.

Mesmo em condições severas de imprecisão e reduzido espaço amostral, os pontos mostrados na figura 17, que, numa condição ideal, deveriam situar-se sobre a reta $y=x$ (caso em que a rede estimaria exatamente os valores de porosidade dos testemunhos), não se encontram tão distantes da realidade—salvo alguns *outliers*, facilmente identificados no gráfico da figura 18.

A rede mapeia sempre o mesmo valor de entrada (densidade) ao mesmo valor de saída. No entanto, na base de dados que foi empregada neste trabalho, há valores idênticos de densidade cujas porosidades diferem em dezenas, dificultando a ação da rede. A título de ilustração, há um ponto real no espaço amostral cujo valor de densidade é de $2,69 \text{ g/cm}^3$ e porosidade $16,2\%$ e outro, de mesma densidade, cuja porosidade correspondente é 5% . Há outros exemplos assim, como dois pontos de mesma densidade ($2,72 \text{ g/cm}^3$), cujas porosidades são $1,6\%$ e $10,8\%$. Considerando o mau-comportamento dos valores e a reduzida quantidade de exemplos disponíveis para que a rede aprenda, o resultado acima mostrado pode ser considerado satisfatório pois, dadas as adversidades das medidas e a complexidade do problema, os pontos estão aceitavelmente próximos da reta $y=x$.

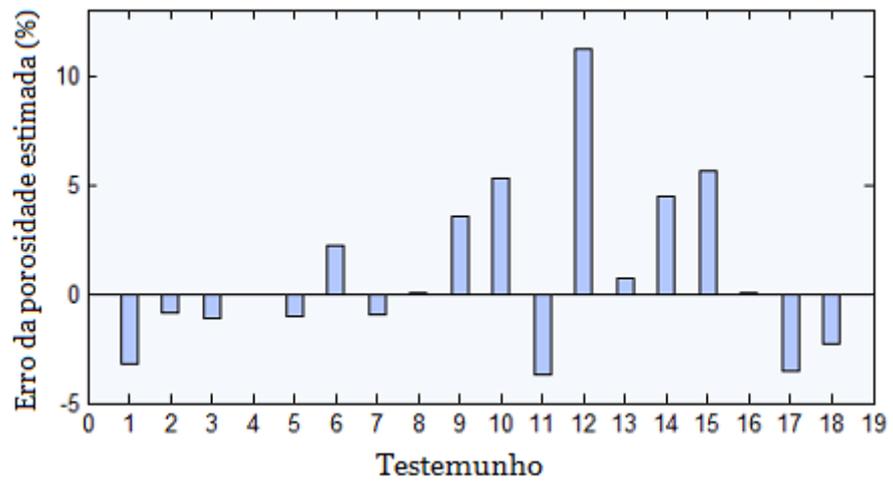


Figura 19- quantificação dos erros fornecidos nas medidas da porosidade.

8- DISCUSSÕES E CONCLUSÕES

Conforme foi abordado na presente proposta, tamanha relevância do conhecimento mais fidedigno possível da porosidade efetiva faz com que seja plausível um mapeamento para que se tenha ciência de seu comportamento e do quão impactada esta é por outras propriedades físicas das rochas.

Desde os primórdios da Geofísica de poço, é conhecida, através da equação de Wyllie, a relação entre a densidade e a porosidade. No entanto, o emprego de tal equação pressupõe o conhecimento de parâmetros que nem sempre são medidos.

Sabida a relevância do cálculo da porosidade efetiva, fornecida de maneira direta somente através da análise de testemunhos- ou seja, de maneira discreta e muitas vezes parca ao longo de um poço- buscou-se, através deste método, estabelecer através de uma interpolação não-linear uma curva contínua de porosidade efetiva, derivada da ação de um algoritmo robusto diretamente sobre os valores advindos da testemunhagem, que produza um resultado coerente com aqueles medidos em laboratório.

Neste trabalho, a abordagem do problema foi realizada através de uma rede neural de arquitetura *backpropagation*, com 12 neurônios processadores sigmoidais. O problema foi analisado com o respaldo científico de engenheiros de software da empresa *SCHLUMBERGER* e a melhor configuração encontrada foi esta, na qual alguns valores de porosidade fornecidos pela rede coincidem com os valores fornecidos para o testemunho (incidentes na reta $y=x$ na figura 18), outras saídas foram plotadas próximas da curva (mas não exatamente sobre a mesma), e há ainda *outlier*.

O fato de todas as saídas fornecidas pela rede não estarem localizadas sobre a reta $Y=X$ - o que indicaria que as saídas da rede seriam idênticas aos valores observados no testemunho- não invalida a abordagem por redes neurais pois seu uso é corriqueiro em ajustes e interpolações não-lineares. Tal fato está relacionado ao reduzido número de amostras ao qual se teve acesso no treinamento e na avaliação da rede neural, bem como à dificuldade de preditabilidade da porosidade através só da densidade com um espaço amostral tão reduzido.

O aprendizado pela rede de padrões de porosidade- variável esta governada por diversos outros parâmetros e cujo comportamento não é dos mais triviais- exigiria um número maior de pares ordenados (densidade, porosidade). A rede foi treinada com subconjuntos de um conjunto que, por si só, já contava com poucas amostras e, considerando o reduzido número de pontos empregados no condicionamento e amarração do problema, o comportamento da rede forneceu valores relativamente bons- que poderiam ser ainda melhores com o fornecimento de uma base de dados mais completa e, de repente, com o reajuste dos parâmetros da rede para as novas condições iniciais do problema, afinal, dentre as limitações de uma rede neural estão a dificuldade para definir seus parâmetros e a falta de garantia de uma convergência do algoritmo para uma solução ótima.

Através da experiência adquirida com o uso de redes neurais- tanto para este trabalho quanto para modelar outras situações cotidianas- é possível afirmar que uma mesma rede pode obter saídas bastante diferentes a depender de seus parâmetros de treinamento. Igualmente importante é o fato de que, para os mesmos vetores de entrada, cada vez que é solicitado um treinamento, os resultados podem ser muito diferentes. Isto ocorre porque a rede elege alguns pontos (cuja quantidade é um dos parâmetros que o usuário precisa escolher na construção de sua rede) a serem afastados do treinamento e utilizados para o teste e para a validação de seu resultado e a cada vez que o treinamento é realizado, diferentes pontos (embora a mesma quantidade) são separados para estes fins. No entanto, como em toda amostra, há pontos capazes de representar melhor (ou pior) um conjunto de dados, gerando treinamentos também de melhor ou pior performance a depender dos pontos escolhidos para tal. O usuário preenche com valores percentuais os campos denominados pelo *MATLAB* como “*training*”, “*testing*” e “*validating*”, reservando para cada etapa, uma porcentagem dos pontos a ser utilizada.

Indubitavelmente, diante de tantos graus de liberdade, a abordagem por redes neurais é, de certa forma, tendenciosa e, muitas vezes instável- limitações que de maneira alguma afetam suas indiscutíveis vantagens e capacidade de reconstrução caso uma parte de suas informações sejam destruídas.

A rede foi testada para condições de severidade e imprecisões. No caso de contarmos com um número maior de amostras, seria de inestimável valia para a academia o retrabalhamento de tais dados, propondo uma nova rede com mais *inputs*, capaz de estimar com alto grau de confiabilidade valores desconhecidos de porosidade- tarefa que as redes neurais certamente cumpririam com maestria- ficando então esta sugestão para futuros trabalhos.

BIBLIOGRAFIA

- BASSIOUNI, Z. *Theory, Measurement and Interpretation of Well Logs. SPE Textbook Series, Vol.4.*
- BASTOS, A.C. *Velocidades de ondas compressionais e cisalhantes como indicadores de litologia e tipo de fluido contido em rochas porosas.* (Dissertação de mestrado)- Centro de Geociências, Belém, UFPA,2002.
- ELLIS, D. e SINGER, J. (2007) *Well Logging for Earth Scientists*, Second Edition, Springer,Dordrecht,Netherlands.
- GOMES,L.G. *Estimativa de perfis de permeabilidade e porosidade utilizando rede neural artificial.* (Dissertação de Mestrado)-Centro de Geociências, Belém, UFPA, 2002.
- KEAREY, P.; BROOKS, M.; HILL, I. *Geofísica de Exploração.* São Paulo: Oficina de textos, 2009. 437 p.
- LIMA,K.T.P. *Determinação automática de porosidade e zoneamento de perfis através de rede neural artificial competitiva.* (Dissertação de Mestrado)-Centro de Geociências, Belém, UFPA, 2000.
- 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, G. G. *Perfilagem Geofísica em Poço Aberto.* Salvador – BA, 2004.
- NIKRAVESH, M. *Soft computed based computational intelligence for reservoir characterization.* Expert systems with applications, v:26, n.1, p.19-38, 2004.
- PETTIJOHN,F.J. 1957. *Sedimentary Rocks*, 2Ed. New York, Harper and Brothers.
- POULTON, M.;STERNBERG,B.; GLASS,C. *Location of subsurface targets in geophysical data using neural networks.*Geophysics,1992, 57(12), 1534-1544.
- RIDER, M.; 2002. *The Geological Interpretation of Well Logs.* 2ª Edição. Rider-French Consulting Ltd, Sutherland, Scotland, 280p.
- SUGUIO, K. 1973. *Introdução à sedimentologia.*São Paulo, Edgard Blücher, Ed. Da Universidade de São Paulo.