



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE GEOCIÊNCIAS
FACULDADE DE GEOFÍSICA
TRABALHO DE CONCLUSÃO DE CURSO

KÍVIA DO CARMO PALHETA GOMES

**IDENTIFICAÇÃO DE FÁCIES RESERVATÓRIO EM PERFIS DE POÇO
ATRAVÉS DE REDE NEURAL MULTICAMADAS**

**Belém - Pará
2009**



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE GEOCIÊNCIAS
FACULDADE DE GEOFÍSICA
TRABALHO DE CONCLUSÃO DE CURSO

KÍVIA DO CARMO PALHETA GOMES

**IDENTIFICAÇÃO DE FÁCIES RESERVATÓRIO EM PERFIS DE POÇO
ATRAVÉS DE REDE NEURAL MULTICAMADAS**

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 - Pará
2009**

KIVIA DO CARMO PALHETA GOMES

**IDENTIFICAÇÃO DE FÁCIES RESERVATÓRIO EM PERFIS DE POÇO
ATRAVÉS DE REDE NEURAL MULTICAMADAS**

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 Gouvêa Luiz – Membro
Doutor em Geofísica
Universidade Federal do Pará

Roberto Vizeu Lima Pinheiro – Membro
Doutor em Geologia
Universidade Federal do Pará

*A minha filha, Júlia Fernanda
Gomes e Silva, com muito amor e carinho.*

AGRADECIMENTOS

Ao Prof. André José Neves Andrade agradeço a oportunidade e a confiança depositada em mim ao longo desse ano de trabalho.

Aos meus pais, José Maria Nascimento Gomes e Maria do Carmo Palheta Gomes, pelo grande amor, afeto e educação destinados a mim, que me permitiram chegar até aqui.

As amigas, Ana Carolina, Roberta Azevedo, Laryssa Oliveira (Bia) pela construção de uma amizade sólida durante nesses quatro anos de curso.

Ao Patryck Bertolo que ao longo deste trabalho foi fundamental.

Ao meu eterno amigo Hamilton Lima Júnior.

Ao meu amigo de sempre Carlos Rangel Costa Santos.

A todos os professores do curso de geofísica.

A todas as pessoas que diretamente ou indiretamente contribuíram na confecção desse trabalho.

"Se quiser por à prova o caráter
de um homem, dê-lhe poder. "
(Abraham Lincoln)

RESUMO

O aumento da produção de hidrocarbonetos em um campo petrolífero é de extrema importância para a indústria do petróleo e profundamente dependente do conhecimento dos reservatórios em função das suas propriedades petrofísicas, que variam segundo as diversas fácies geológicas atravessadas pelos poços. A mais completa descrição das fácies reduz potencialmente os erros na predição destas propriedades, refletindo em estimativas de volumes de hidrocarboneto mais realistas.

A aplicação das técnicas de testemunhagem é, normalmente, realizada em um número restrito de poços perfurados em um campo, fazendo com que descrições detalhadas das fácies, pela análise de testemunhos, tornem-se rarefeitas e conseqüentemente não permitindo uma caracterização realista dos reservatórios.

Neste trabalho é apresentado um algoritmo inteligente capaz de produzir o transporte da informação das fácies realizada pela análise do testemunho para todos os poços perfilados em um campo petrolífero, através do projeto de uma rede neural treinada para realizar um mapeamento da informação geológica extraída do testemunho em termos das propriedades físicas registradas nos perfis.

A aplicabilidade desta metodologia é verificada com a utilização de três poços offshore, testemunhados e perfurados no Campo de Namorado, Bacia de Campos, Brasil. Para os casos aqui avaliados a rede neural apresentou resultados compatíveis com a análise de testemunho e de forma completamente independente da dimensão do conjunto de treinamento.

Palavras-Chave: Geofísica de Poço. Algoritmos Inteligentes. Rede Neural Artificial.

ABSTRACT

Increase of oil production is an important challenge for oil industry and deeply dependent of a realistic knowledge of reservoir petrophysical properties, which vary with the change of geological facies crossed by the borehole.

The facies description helps to reduce the misinterpretation in the petrophysical properties and in the oil reserves calculations. The coring techniques are made only in a few wells in an oil field causing a sparse detailed facies descriptions and consequently not allowing a more realistic reservoir characterization.

In this work is presented an intelligent algorithm that is able to make the transport of facies information generated by core analysis for all the logged wells in an oil field, by the project of an artificial neural network, which is trained to map the geological information in terms of physical properties registered in the wireline logs.

The applicability of this methodology is verified using three cored, offshore boreholes, drilled in Namorado oil field, Basin of Campos, Brazil. For the cases appraised here, the neural network exhibits results compatible with core analysis and in a way completely independent of the dimension of the training set.

Keywords: Wireline logging; intelligent algorithms; artificial neural networks.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fase de uma amostra de rocha a lâmina delgada	19
Figura 2 – Arquitetura típica de uma rede neural multicamadas.	28
Figura 3 – Neurônio biológico.....	29
Figura 4 – Neurônio artificial.....	30
Figura 5 – Função degrau simples.	31
Figura 6 – Função logística.	31
Figura 7 – Função tangente hiperbólica.	32
Figura 8 – Rede neural com três camadas.	34
Figura 9 – Generalização da rede neural.	39
Figura 10 – Arquitetura da rede neural.....	42
Figura 11 – Perfis convencionais do Poço-A.....	44
Figura 12 – Descrição das fácies do Poço-A.....	44
Figura 13 – Perfis convencionais do Poço-A. O sombreado em azul marca o intervalo de treinamento.	45
Figura 14 – Identificação da fácies de referência pela rede neural.	45
Figura 15 – Perfis convencionais do Poço-B.....	46
Figura 16 – Descrição das fácies do Poço-B.....	47
Figura 17 – Identificação da fácies de referência pela rede neural.	47
Figura 18 – Perfis convencionais do Poço-C.....	49
Figura 19 – Descrição das fácies do Poço-C.	50
Figura 20 – Identificação da fácies de referência pela rede neural.	50

LISTA DE TABELAS

Tabela 1 – Granulometria das rochas clásticas.....	17
Tabela 2 – Composição das rochas carbonáticas.....	17

SUMÁRIO

1	INTRODUÇÃO	12
2	FÁCIES SEDIMENTAR	14
2.1	ROCHAS SEDIMENTARES.....	14
2.1.1	Rochas sedimentares clásticas	15
2.1.2	Rochas sedimentares carbonáticas	15
2.1.3	Rocha sedimentares químicas	16
3	MÉTODOS DE IDENTIFICAÇÃO DE FÁCIES	18
3.1	MÉTODOS DIRETOS	18
3.1.1	Análise por Difração de Raios-X	18
3.1.2	Microscópio Petrográfico e Eletrônico	18
3.1.3	Método de Chayes	19
3.1.4	Coloração Diferencial	20
3.2	MÉTODOS INDIRETOS.....	20
4	GEOFÍSICA DE POÇO	21
4.1	PROPRIEDADES PETROFÍSICAS.....	21
4.1.1	Porosidade	21
4.1.2	Saturação de Fluido	22
4.1.3	Argilosidade	22
4.1.4	Permeabilidade	22
4.2	PERFIL DE POÇO	23
4.2.1	Perfil de Raios Gama Natural	23
4.2.2	Perfil de Porosidade Neutrônica	24
4.2.3	Perfil Sônico	24
4.2.4	Perfil de Densidade	25
4.2.5	Perfil de Resistividade Profunda	25
5	REDES NEURAIS MULTICAMADAS	27
5.1	NEURÔNIO BIOLÓGICO E ARTIFICIAL	28
5.2	FUNÇÃO DE ATIVAÇÃO	30
5.3	TREINAMENTO OU APRENDIZADO	33
5.4	FASE DE OPERAÇÃO.....	39
6	METODOLOGIA	40
7	RESULTADOS	43
8	CONCLUSÕES	51
	REFERÊNCIAS	52

1 INTRODUÇÃO

O aumento da produção de hidrocarbonetos em um campo petrolífero é de extrema importância para a indústria do petróleo. A produção de petróleo depende da mais realista avaliação das propriedades petrofísicas dos reservatórios, que variam segundo as diversas fácies geológicas atravessadas pelo poço (SERRA, 1985). A descrição precisa das fácies reduz significativamente o erro na predição das propriedades petrofísicas, como a permeabilidade, com impacto no cálculo do volumes de hidrocarbonetos.

A identificação das facies atravessadas por um poço petrolífero é uma das mais importantes atividades executada pelo geólogo durante a análise de testemunhos (QI; CARR, 2006), mas a descrição geológica de testemunhos para a identificação das facies apresenta um alto fator HH (homem/hora). Na grande maioria dos poços *onshore*, a operação de testemunhagem é rara e a recuperação das amostras de rocha ou testemunhos, durante este tipo de operação, é freqüentemente inferior a 100% (ELLIS, 1987). Por outro lado, a grande maioria dos poços *offshore*, são do tipo horizontal, que são adotados como a forma mais conveniente para o desenvolvimento dos campos marítimos. Neste caso, a sua geometria não possibilita a realização de operações de testemunhagem (ELLIS, 1987).

Considerando a interpretação qualitativa dos perfis geofísicos mensurados em um poço, apenas em um único caso a identificação de fácies pode ser realizada, quando o poço atravessa uma camada de rocha homogênea, como um evaporito. Neste caso, o perfil de densidade convencional pode identificar esta fácies pelo seu particular valor de densidade ($\rho_b = 2.1 \text{ g/cm}^3$). Na grande maioria das situações práticas, este tipo de ocorrência é a de pouca importância para a exploração de petróleo.

Apresenta-se neste Trabalho de Conclusão de Curso uma abordagem para a solução do problema da identificação de uma fácies reservatório em um poço não testemunhado, com a utilização de múltiplos perfis geofísicos de poço aberto. A abordagem será através do desenvolvimento de uma estratégia conveniente para o treinamento de uma rede neural direta multicamadas, será usado o algoritmo da retropropagação do erro para a produção de um mapeamento da

informação geológica extraída dos testemunhos obtidos em um poço, em termos das propriedades físicas registradas nos perfis.

Busca-se aqui, utilizar a habilidade e a capacidade de generalização de uma rede neural treinada com o algoritmo da retropropagação do erro para produzir um mapeamento da informação geológica extraída dos testemunhos em termos das medidas de propriedades físicas registradas nos perfis geofísicos de poço aberto e, ainda, possibilitar o transporte da informação geológica obtida em poço testemunhado, tomado como referência, para outros poços perfilados, mas não testemunhados, perfurados nas vizinhanças ou no mesmo cenário geológico do poço de referência.

A aplicabilidade desta metodologia foi verificada com a utilização dos perfis de raios gama natural (RG), resistividade profunda (RESt), sônico (DELt), densidade (RHOb) e porosidade neutrônica (PHIN) mensurados em três poços offshore, testemunhados e perfurados no Campo de Namorado, Bacia de Campos, Brasil.

2 FÁCIES SEDIMENTAR

O termo fácies corresponde à expressão em latim para aparência ou aspecto. No sentido geológico, refere-se aos aspectos litológicos, biológicos, estruturais e mesmo metamórficos, refletindo o ambiente deposicional, que possibilitam a diferenciação entre duas camadas de rochas sedimentares (SUGUIO, 1980).

A definição das fácies possibilita que um conjunto de rochas sedimentares seja reconhecido e diferenciado das outras rochas na vizinhança, incluindo-se no termo fácies, ainda a geometria, a composição química, as estruturas sedimentares, o padrão de paleocorrentes e a eventual presença de fósseis. A composição mineralógica define a sensibilidade da rocha à ação dos fluidos intersticiais (reações de dissolução e precipitação durante a diagênese), a textura e a gênese atuam diretamente sobre a porosidade e a permeabilidade, ao mesmo tempo em que a permeabilidade também é influenciada pelas estruturas sedimentares formadas.

A identificação das fácies é, geralmente, realizada a partir de identificação de características geológicas particulares diretamente sobre amostras de rocha provenientes, principalmente, de testemunhos ou, em alguns casos de afloramentos análogos ao reservatório (SUGUIO, 1980).

A identificação das fácies reservatório atravessadas por um poço é de extrema importância para a exploração de petróleo, uma vez que as variações das fácies controlam as variações das propriedades petrofísicas, que definem a qualidade do reservatório, reduzindo assim o risco exploratório.

2.1 ROCHAS SEDIMENTARES

As rochas sedimentares são constituídas de detritos de rochas pré-existentes. Essas rochas ao serem erodidas são transportadas através da água, vento ou gelo pela ação da gravidade até a sua sedimentação em depressões da crosta terrestre, denominadas bacias sedimentares. Após a deposição, os sedimentos são litificados e convertidos em rochas por um processo chamado diagênese. A diagênese inclui a compactação dos sedimentos e expulsão da água,

precipitação de minerais nos poros causando a cimentação e um amplo conjunto de reações químicas à baixa temperatura e pressão entre soluções aquosas e as rochas. Ao final do processo da diagênese têm-se a formação das rochas sedimentares, que são basicamente divididas em: clásticas, carbonáticas e químicas.

2.1.1 Rochas sedimentares clásticas

As rochas clásticas provêm de sedimentos produzidos por ação mecânica também chamados de detríticos, originários de processos nitidamente físicos de fragmentação ou quebra de rochas. Os sedimentos, assim considerados, podem variar em tamanho, desde partículas extremamente pequenas, até grandes blocos de rochas. Esse material está sujeito a ser transportado do local de intemperização até o ponto de acumulação através da água, ventos e geleiras. Existem diversos tipos de rochas sedimentares clásticas como, por exemplo, o arenito e o folhelho.

O arenito é uma rocha sedimentar originada da litificação e compactação de grãos predominantemente de quartzo depositado em ambiente continental, nos rios e lagos ou em ambientes marinhos, nas praias, deltas ou nas seqüências turbidíticas do talude continental.

O folhelho é um nome empregado para designar uma rocha argilosa com fissilidade, que é uma propriedade inerente a esses sedimentos de separarem-se em planos, cujas distâncias são essencialmente iguais aos diâmetros dos seus componentes (SUGUIO, 1980). Os folhelhos geralmente derivam de ambientes marinhos ou de água doce. Os folhelhos de origem marinha são caracterizados pela ocorrência de argilominerais do grupo da illita e da clorita, em contraposição aos de água doce, que são ricos em esmectita.

Podem-se classificar as rochas sedimentares de acordo com características específicas, as rochas sedimentares clásticas têm classificação baseada principalmente com relação ao tamanho do grão, como mostrado na Tabela 1.

2.1.2 Rochas sedimentares carbonáticas

As rochas carbonáticas apresentam como composição primária os carbonatos, têm origem biológica ou mais propriamente biodetrítica, formando-se em ambientes marinhos pela deposição de conchas e esqueletos de organismos

(corais, briozoários, etc.). Essas conchas e esqueletos são preservados como fósseis mais e menos fragmentados, perfeitamente reconhecíveis nas rochas pouco ou não metamorizadas. Os principais tipos de rochas carbonáticas são o calcário, composto predominantemente por calcita (CaCO_3) e o dolomito, composto pelo mineral dolomita ($\text{CaMg}(\text{CO}_3)_2$). As rochas sedimentares carbonáticas podem ser classificadas principalmente com base na composição do precipitado químico que as compõem, como apresentado na Tabela 2.

O calcário é um termo empregado para caracterizar um grupo de rochas que contem quantidades acima de 50% de carbonatos. Este tipo de rocha é formado a partir da dissolução de antigas conchas e esqueletos que se precipitam e depositam-se em ambiente de mar raso.

O dolomito é o carbonato duplo de cálcio e magnésio, ($\text{CaCO}_3 \cdot \text{MgCO}_3$), correspondendo a um teor teórico de cerca de 54% de carbonato de cálcio e 45,5% de carbonato de magnésio. A origem do dolomito constitui um grande enigma geológico. Sua origem pode ter sido secundária, por meio da substituição do cálcio pelo magnésio presente em compostos hidrotermais junto aos fluidos vindos de grandes profundidades, através de falhas geológicas profundas, ou da interação microbial em ambientes hipersalinos; ou ainda, de misturas de água doce e salgada.

2.1.3 Rochas sedimentares Químicas

As rochas químicas se originam da precipitação de substâncias contidas em solução nas águas dos mares ou lagoas salgadas, ou por precipitação de substâncias solúveis transportadas pelas águas, após saturação.

O evaporito ou depósito salino é uma rocha sedimentar formada pela cristalização e precipitação química de sais dissolvidos em meio aquoso, devido ao processo de evaporação. Seu ambiente de formação são as bacias fechadas sujeitas a evaporação intensa e seu precipitado gera depósitos de carbonatos, sulfetos, boratos e cloretos. Os evaporitos costumam estar associados a ambientes altamente produtivos em matéria orgânica. No registro geológico, é conhecida a associação de campos gigantes de petróleo e seqüências espessas de evaporitos. Os três tipos principais de evaporitos são halita (sal comum), anidrita e gipsita.

Tabela 1 – Granulometria das rochas clásticas.

Intervalo granulométrico (mm)	Tamanho do grão	Nome da Rocha
>256 a 2,0	Granulo, seixo, calhau e matacão	Conglomerado ou brecha
2,0 a 0,062	Areia	Arenito
0,062 a 0,004	Silte	Siltito
<0,004	Argila	Argilito

Fonte: (Peroni, 2003)

Tabela 2 – Composição das rochas carbonáticas.

Mineral	Litologia
Calcita (CaCO_3)	Calcário
Dolomita ($\text{CaMg}(\text{CO}_3)_2$)	Dolomito

Fonte: (Peroni, 2003)

3 MÉTODOS DE IDENTIFICAÇÃO DE FÁCIES SEDIMENTARES

Os métodos de identificação de fácies podem ser divididos em dois tipos principais, os métodos diretos, que são realizados por geólogos, em laboratório, diretamente sobre as amostras provenientes de testemunhos ou de afloramentos e os métodos indiretos, onde a identificação é estimada a partir da interpretação das medidas geofísicas de poço.

3.1 MÉTODOS DIRETOS

A amostragem ou testemunhagem das rochas é um procedimento realizado durante as operações de perfuração de um poço petrolífero, pelo qual é recolhida uma fração da rocha *in situ*. Assim, durante a amostragem devem ser tomadas todas as precauções para assegurar que as amostras não sofram alterações físicas e químicas no tempo entre a colheita e a sua análise no laboratório. A identificação manual de fácies de um reservatório de petróleo é um processo intensivo que envolve o gasto de uma quantidade considerável de tempo por parte de um especialista experiente, dentre as técnicas de identificação manual de fácies podemos citar algumas como a análise por difração de raios-X, microscópio petrográfico e eletrônico, método de Chayes e coloração diferencial.

3.1.1 Análise por Difração de Raios-X

A análise por difração de raios-X é o método para a determinação do arranjo atômico dos minerais a razão Si/O é alterada nos cristais de silicato mostrando as mudanças no seu arranjo atômico. À distância interplanar define o grupo estrutural ao qual pertence o argilomineral. Espaçamentos cerca de 7, 10 e 14 angstrom são característicos de caulinita, mica, e montmorillonita, respectivamente.

3.1.2 Microscópio Petrográfico e Eletrônico

Para os microscópios de luz transmitida, as amostras têm que ser o mais transparente possível. Assim, as rochas são cortadas numa fatia muito fina que é colada sobre uma lâmina de vidro. Este conjunto é depois desgastado com equipamento próprio de modo a que a espessura da lâmina de rocha não

ultrapasse os 0.03 mm, pois só assim se garante a transparência. Uma lâmina delgada demora cerca 6 horas para ser feita por um técnico experientado (Figura 1).

As amostras de rochas para serem estudadas com microscópios de luz refletida são polidas de modo a que a sua superfície reflita o mais possível a luz que vai incidir sobre elas. Este método é usado para identificação mineralógica através das propriedades óticas e cristalográficas.

Os minerais de argilas como caulinita, dicktita, haloista, hidromicas são minerais que possuem formas características que podemos reconhecer sob microscópio eletrônico. O aumento utilizado é da ordem de 15 000 a 75 000 vezes o tamanho natural.




Figura 1 – Fases de transformação de uma amostra de rocha a lâmina delgada. A- Amostra de mão de onde foi cortado um fragmento. B- Fragmento de rocha (cerca de 0,5 cm de espessura) e lâmina de vidro onde vai ser colada o fragmento. C- Colagem do fragmento na lamina de vidro. D- Amostra já colada na lamina de vidro. E- Amostra depois de ser desgastada. F- Lâmina delgada já finalizada, depois de polida e com lamela de vidro já colada. G- Lâmina polida já finalizada (Fonte:Brilha e Henriques, 2001)

3.1.3 Método de Chayes

Um método que consiste na medida do diâmetro do campo visual do microscópio e a contagem do número de grãos “cortados” pelas linhas de referência do microscópio, e, em seguida, divide-se o dobro do diâmetro pelo número de grãos. Este processo é repetido várias vezes até que se tenha um número de grãos “cortados” estatisticamente significativos. Deste modo, calcula-se a granulometria média da seção delgada pela fórmula.

$$\text{Granulometria média} = \frac{\sum 2d/n}{N}$$

Onde n é o número de grãos “cortados” pelas linhas de referência; d , o diâmetro do campo visual do microscópio; e N , o número total de campos visuais submetidos à contagem. É apropriado para estudos sedimentológicos em que se deseja ter idéias gerais sobre a distribuição granulométrica, por exemplo, para análises faciológicas; e fornece a granulometria média, mas não deve ser utilizado para determinação do grau de seleção ou dos tamanhos das partículas (CHAYES, 1956).

3.1.5 Coloração Diferencial

Certos minerais podem ser coloridos quando utilizado corantes orgânicos, como a benzidina, verde-malaquita e azul de metileno. O efeito da coloração deve-se a reações ácido-básicas e ao mecanismo de oxirredução. A absorção do azul de metileno pode ser utilizada como uma medida da capacidade de troca iônica dos minerais de argila.

3.2 MÉTODOS INDIRETOS

A identificação indireta de fácies é normalmente realizada a partir da interpretação de um conjunto de perfis corridos em um poço. Considera-se que as características geológicas que levam à determinação de uma fácies reflitam um conjunto de propriedades físicas registradas nos perfis de tal forma que a conveniente interpretação destas medidas possibilite a identificação das fácies (SERRA, 1985).

No cotidiano do desenvolvimento de um campo petrolífero, as fácies são primariamente identificadas e nomeadas através dos métodos diretos. Assim, é comum a realização de uma correspondência em profundidade destas fácies identificadas com os perfis, possibilitando a sua identificação nos vários poços não testemunhados. A correspondência, em profundidade, dos testemunhos com os perfis na interpretação visual ou qualitativa deve atentar para a ocorrência de ruído nos dados, que pode ser extremamente danosa à identificação das fácies

4 GEOFÍSICA DE POÇO

Após a perfuração de uma fase do poço, são descidas várias ferramentas com a finalidade de medir algumas propriedades físicas das rochas, esse processo é conhecido como perfilagem de poço. As interpretações destas medidas permitem a obtenção de informações importantes a respeito das formações atravessadas pelo poço, como a litologia, espessura das camadas e principalmente sobre as propriedades petrofísicas, que permitem a identificação e a qualificação produtiva dos reservatórios de hidrocarbonetos (LUTHI, 2001).

4.1 PROPRIEDADES PETROFÍSICAS

Propriedades petrofísicas são propriedades das rochas sedimentares através das quais é possível o estabelecimento de uma escala quantitativa da qualidade produtiva de um reservatório de hidrocarbonetos. Didaticamente as propriedades petrofísicas podem ser agrupadas em duas classes:

- Propriedades estáticas - são aquelas relacionadas aos volumes dos materiais em uma rocha sedimentar, como a porosidade, a saturação de fluido e a argilosidade.
- Propriedades dinâmicas - são aquelas relacionadas ao fluxo de fluido em um meio poroso, neste caso, a permeabilidade é a propriedade de maior interesse para a geofísica de poço.

4.1.1 Porosidade

A porosidade é a propriedade petrofísica que expressa a capacidade de armazenamento de fluido de uma rocha reservatório. Em termos do modelo de rocha, a porosidade é definida pela razão entre o volume de poros e o volume total da rocha. A porosidade das rochas sedimentares é uma função extremamente complexa de vários fatores deposicionais e pós-deposicionais, entre eles a forma e o arranjo dos grãos ou partículas, a razão de soterramento, profundidade, compressibilidade do fluido intersticial, tipo dos sedimentos acima e abaixo (podem impedir o fluxo de fluido), grau de seleção e tipo de fluido percolante (determina a ocorrência e o tipo da cimentação).

A porosidade pode ser obtida indiretamente através dos perfis sônicos, densidade e porosidade neutrônica; de forma indireta ou diretamente, através do porosímetro ou da bomba de mercúrio, em laboratório.

4.1.2 **Saturação de Fluido**

O conceito de saturação de fluido é determinado pela coexistência da água de formação e do hidrocarboneto no poro da rocha. A saturação de água é definida pela fração do volume do poro ocupada pela água; por sua vez, a saturação de hidrocarboneto é obtida pela subtração da unidade da saturação de água.

A saturação de óleo é a propriedade responsável pela caracterização de uma rocha como rocha reservatório e em termos da qualificação do reservatório. Quanto maior a saturação de óleo ou quanto menor for a saturação de água, melhor a qualidade do reservatório.

4.1.3 **Argilosidade**

A argilosidade é a fração do volume total da rocha sedimentar composta por argila. A designação geológica para argila classifica granulometricamente um material sedimentar. Para a geofísica de poço a argila pode ser constituída pela fração silte, finíssimos grão de sílica ou propriamente os argilominerais. Independente da sua forma, constituição química e distribuição pelo arcaço rochoso ou pelo poro, a argilosidade representa a soma global de todas essas frações volumétricas. Para a produção de petróleo, a argilosidade avalia a existência de possíveis barreiras ao escoamento oferecidas pela presença da argila nos poros.

4.1.4 **Permeabilidade**

Mesmo que uma rocha contenha um valor apreciável de porosidade e de saturação de hidrocarbonetos, não há garantia de que estes possam ser extraídos. Para que isso ocorra, é necessário que a rocha permita o fluxo de fluido através de seu interior, ao longo dos poros. A medida da capacidade de uma rocha permitir o fluxo de fluidos é chamada permeabilidade. Quando existe apenas um único fluido saturando a rocha, esta propriedade recebe o nome de “permeabilidade absoluta”.

Uma rocha reservatório sempre contém dois ou mais fluidos, de modo que a permeabilidade absoluta não é suficiente para se medir a facilidade com que determinado fluido se move no meio poroso. No caso da existência de mais de um fluido a facilidade com que cada um se move é chamada de “permeabilidade efetiva” ao fluido considerado.

4.2 PERFIL DE POÇO

Um perfil de poço é a representação gráfica, em relação à profundidade, das variações de uma ou mais propriedades físicas das rochas atravessadas pelo poço. Os perfis são obtidos pelo deslocamento ascensional e contínuo de uma ou mais ferramentas de perfilagem no interior de um poço. A sua principal utilização é a identificação dos vários tipos de rochas perfuradas para obter a localização daquelas que podem conter hidrocarbonetos e avaliar o seu significado comercial.

No que se refere aos parâmetros medidos pelos perfis geofísicos de poço, as rochas são distinguidas em função das variações de suas propriedades elétricas (resistividade elétrica e permissividade elétrica), acústicas (velocidade de propagação da onda elástica) e radioativas (radioatividade natural ou induzida). Qualquer que seja a ferramenta empregada para a qualificação de um reservatório, as propriedades de interesse (propriedades petrofísicas) não são fornecidas diretamente, na realidade, elas são inferidas a partir dos valores registrados nos perfis. Na grande maioria das vezes os perfis geofísicos de poço são o único meio de se quantificar *in situ* os volumes originais de hidrocarbonetos.

4.2.1 Perfil de Raios Gama Natural

É a representação gráfica das variações da radiação gama natural emitida pelas formações ao longo da profundidade do poço. Essa radiação é detectada quando os minerais constituintes das rochas contêm quantidades suficientes de isótopos do potássio (K^{40}), do urânio (U^{238}) e do tório (Th^{232}). As rochas selantes, como os folhelhos, normalmente possuem maiores quantidades de elementos radioativos e emitem uma maior quantidade de radiação gama que as rochas reservatório, como o arenito, a dolomita ou o calcário. Em particular, alguns arenitos e carbonatos também podem apresentar altos valores de radiação gama natural devido à presença anômala de material radioativo. O perfil de raios gama

(*RG* ou *GR*) é projetado para registrar aproximadamente a radiação presente nos primeiros 30 cm de rochas nas vizinhanças da parede do poço. Esta radiação é diretamente relacionada à proporção de folhelho ou argila presente em uma camada. Esta característica permite utilizá-lo com um indicador do teor de folhelho ou da argilosidade das rochas reservatório. Em particular, o perfil de raio gama é útil na distinção das litologias das rochas reservatório (arenitos e carbonatos) em relação aos folhelhos.

4.2.2 Perfil de Porosidade Neutrônica

Existem vários tipos de perfis neutrônicos que se diferenciam entre si pelo método utilizado na detecção de nêutrons. Os nêutrons são partículas destituídas de carga elétrica com sua massa quase igual ao núcleo do átomo de hidrogênio. Sendo partículas neutras, elas podem penetrar profundamente na matéria, interagindo elástica ou inelasticamente com os núcleos dos elementos, que constituem as rochas. Os perfis neutrônicos medem a atenuação de um fluxo original de nêutrons injetados na formação por meio de bombardeio com nêutrons de alta energia ou velocidade. Os nêutrons interagem principalmente com o hidrogênio presente nos poros e, assim produzem uma aproximação da porosidade de uma rocha. O elemento hidrogênio é encontrado na água intersticial e também nos hidrocarbonetos, preenchendo os espaços porosos das rochas. Alguns óleos, a depender de sua densidade, têm aproximadamente a mesma concentração de hidrogênio por unidade de volume que a água. Uma avaliação do conteúdo de hidrogênio é uma aproximação bastante razoável da porosidade.

4.2.3 Perfil Sônico

A velocidade do som varia segundo o meio em que suas ondas se propagam. Ela é maior nos sólidos, que nos líquidos e gases. Velocidade de propagação maior significa tempo de trânsito menor. Assim, o tempo gasto pelo som para percorrer uma mesma distância fixa nos sólidos é bem menor que nos líquidos e nos gases. Para meios multifásicos, a velocidade de propagação do som pode ser estimada por uma média das velocidades de propagação em cada material, ponderada pelos seus respectivos volumes.

Conhecendo-se a litologia, que determina o tempo de transito na matriz e o fluido intersticial, que determina o tempo de transito no poro, o perfil sônico mostra uma relação direta entre o tempo de transito medido no poço e a porosidade das rochas. Considerando duas rochas de mesma litologia, aquela que contiver maior volume de fluido em seus poros (maior porosidade) apresentará um maior tempo de trânsito, que uma rocha com menos fluidos (menor porosidade).

4.2.4 Perfil de Densidade

O perfil de densidade é um registro contínuo das variações das densidades das formações atravessadas por um poço. A ferramenta de densidade não responde diretamente à densidade da formação, mas sim ao número de elétrons por unidade de volume (densidade eletrônica). A calibração das medidas para uma litologia conhecida, normalmente o calcário, resulta na densidade da rocha. Para o caso das rochas reservatório, as medições realizadas por essa ferramenta incluem a densidade da matriz (característica de cada litologia) e a densidade dos fluidos no espaço poroso.

Na aplicação do perfil de densidade, raios gama emitidos por uma fonte as fontes de raios gama utilizada é geralmente Césio (Cs^{137}), que interagem com os elétrons dos átomos da formação. Esta interação pode ser de três modos diferentes: efeito fotoelétrico, efeito Compton e produção do par elétron-pósitron. Para a geofísica de poço, entretanto consideramos apenas o efeito Compton e o fotoelétrico, já que a produção do par necessita de elevada energia.

A identificação da litologia e o cálculo da porosidade são as principais informações que podem ser adquiridas pela interpretação do perfil de densidade.

4.2.5 Perfil de Resistividade Profunda

O perfil de resistividade fornece uma medida aproximada da resistividade das rochas nas proximidades da parede do poço, através da injeção de corrente elétrica e medição da diferença de potencial produzida. A injeção de corrente pode ser realizada por indução ou por contato galvânico. O perfil de resistividade pode ser utilizado para correlações geológicas e para a determinação da resistividade verdadeira das rochas quando as camadas são bastante espessas.

A resistividade das rochas dependerá da sua porosidade, da natureza dos fluidos contidos nos seus poros e da quantidade de sal neles dissolvidos. Em se

tratando dos fluidos os hidrocarbonetos apresentam uma alta resistividade, enquanto as águas da formação (água salgada) são boas condutoras. Esta grande diferença de resistividades de rochas preenchidas por hidrocarbonetos e aquelas preenchidas por água da formação, torna o perfil resistividade muito importante na avaliação da formação para a identificação de zonas armazenadoras de hidrocarbonetos. Outros fatores além da porosidade afetam o perfil resistividade, dificultando sua interpretação, como a litologia, quando uma pequena variação (como, por exemplo, de silte para argila pura) produz uma grande variação nos valores de resistividade.

5 REDES NEURAIS MULTICAMADAS

Uma rede neural é uma estrutura de processamento de informação paralela e distribuída, que consiste de elementos processadores (que possuem memória local e efetuam operações com as informações locais) ou neurônios artificiais agrupados na forma de camadas que por sua vez, são intensamente interconectadas. Cada elemento processador possui um único caminho de saída para uma dada informação processada, que pode se conectar a vários outros neurônios artificiais através de seus respectivos caminhos de entrada. O sinal de saída de um neurônio é completamente local; isto é, ele depende somente dos valores dos sinais de entrada e dos valores armazenados na sua memória local, ou sinapses (HECHT-NIELSEN,1987).

A idéia original das redes neurais artificiais é a de simular através de algoritmos algumas características similares àquelas observadas no funcionamento do cérebro humano (HAYKIN, 2001), destacando-se:

1. O conhecimento é adquirido pela rede neural, como no cérebro humano, através de um processo de aprendizado.
2. Os pesos existentes nas conexões sinápticas entre os neurônios artificiais, em analogia às sinapses nos neurônios biológicos, são responsáveis pela memória local ou pelo conhecimento aprendido.
3. Em semelhança ao cérebro humano, a capacidade de generalização baseada no conhecimento aprendido. Isto significa que uma rede neural consegue produzir saídas adequadas para entradas não observadas no seu processo de treinamento.

As redes neurais multicamadas são representadas por uma particular disposição dos neurônios, ou arquitetura, que consiste de um número de neurônios organizados em grupos ou camadas dispostas na direção de propagação do sinal de entrada, como mostrado na Figura 2. Neste tipo de rede encontramos três tipos de camadas, a camada de entrada, que recebe os dados de entrada e os propaga para o interior da rede. As camadas ocultas situam-se entre a camada de entrada e a de saída e possibilitam o processamento e o aprendizado da rede, extraindo progressivamente as características estatisticamente significantes dos dados de

entrada. A última camada é a de saída, onde é produzido o sinal de saída da rede para o seu exterior.

De um modo geral, uma rede neural multicamadas possui como principais características:

1. O modelo de cada neurônio ou elemento processador da rede possui uma função de ativação não linear. A função sigmoide é a função mais utilizada.
2. A rede possui pelos menos uma camada oculta.
3. A rede possui um alto grau de conectividade entre as camadas, traduzido pela dimensão da matriz de pesos sinápticos.

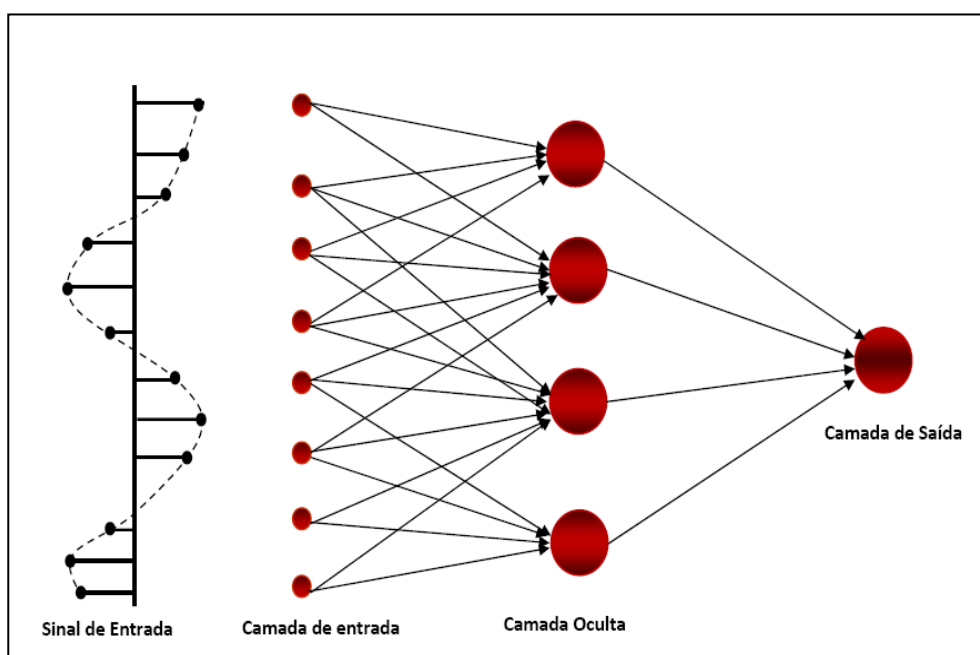


Figura 2 – Arquitetura típica de uma rede neural multicamadas.

5.1 NEURÔNIO BIOLÓGICO E ARTIFICIAL

O neurônio é a unidade básica do cérebro, isoladamente pode ser considerado como uma unidade de processamento, que aceita e combina estímulos de natureza eletroquímica proveniente de vários outros neurônios em seu corpo ou núcleo para produzir um único estímulo de saída, que é transmitido a outros neurônios. A intensidade dos estímulos que um neurônio recebe em seus dendritos (entradas) depende da proximidade física com os axônios (saída) de cada um dos neurônios emissores de estímulos. O axônio conecta-se aos dendritos de

outros neurônios através de ligações chamadas sinapses. As sinapses liberam substâncias químicas chamadas de neurotransmissores em função da intensidade do pulso eletroquímico a ser transmitido para que uma conexão seja realizada. Assim, as sinapses se responsabilizam pela conexão de um particular grupo de neurônios, que simultaneamente se responsabilizam por uma particular atividade cerebral ou pela solução de um problema específico, na Figura 3 podemos analisar a estrutura de um neurônio biológico.




Figura 3 – Neurônio biológico.

O neurônio artificial é a unidade de processamento fundamental das redes neurais artificiais e foi projetado para imitar as características morfológicas de um neurônio biológico. O neurônio artificial mostrado na Figura 4 possui várias entradas $(x_1, x_2 \dots x_p)$ que representam os estímulos do sistema ou as saídas de outros neurônios. A cada conexão é associada um peso $(w_{k1}, w_{k2} \dots w_{kp})$ representando a intensidade da ligação ou sinapse. No interior do núcleo é produzida uma combinação linear (Σ) das entradas pelos respectivos pesos, gerando um valor de potencial (p_k) , que é aplicado à função de ativação $(f(p_k))$ para a produção do sinal de saída (y_k) . A variação do sinal de saída classifica o neurônio artificial como:

1. Neurônio binário. O sinal de saída é discreto no conjunto $\{0,1\}$ ou no conjunto $\{-1,1\}$.

2. Neurônio contínuo. O sinal de saída varia continuamente no intervalo $[0,1]$ ou no intervalo $[-1,1]$.

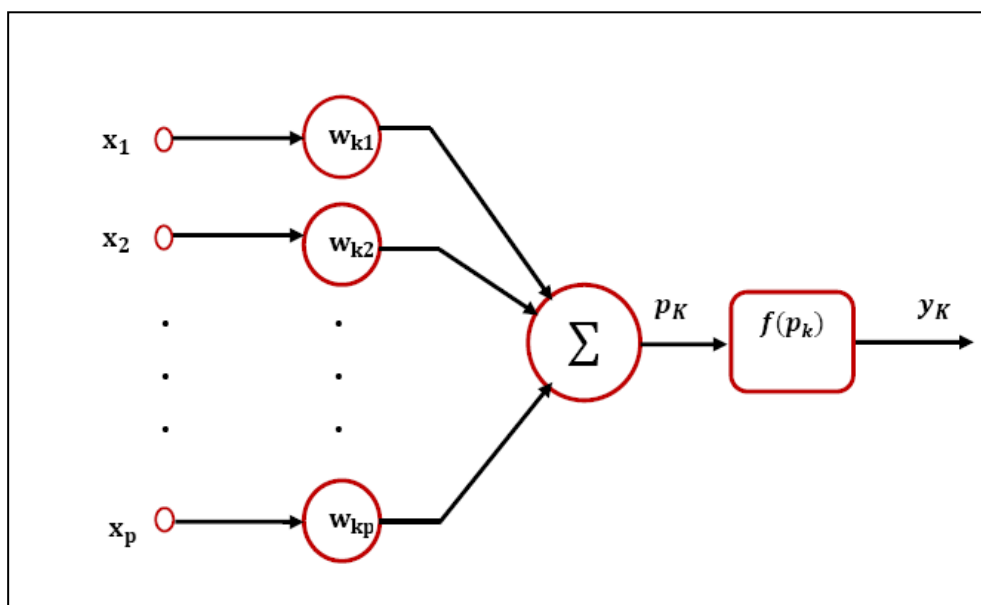


Figura 4 – Neurônio artificial.

5.2 FUNÇÃO DE ATIVAÇÃO

Uma função de ativação define a saída de um neurônio artificial baseada em seu nível de atividade ou potencial.

A função de ativação característica de um neurônio binário é a função degrau simples mostrada na Figura 5.

1- Função Degrau

É definida através da expressão:

$$f(p) = \begin{cases} 1, & p \geq 0 \\ -1, & p < 0 \end{cases}$$

Para o neurônio contínuo, a função sigmóide, que é uma função contínua, suave e crescente, é a função de ativação mais utilizada na construção das redes neurais artificiais. Ela pode aparecer em duas formas, como:

1- função logística

É definida através da expressão:

$$y = f(p) = \frac{1}{1 + e^{-ap}}$$

Onde a é o parâmetro de gradiente da curva, e p é o potencial. A função logística pode assumir qualquer valor do intervalo fechado $[0,1]$ como mostra a Figura 6.




Figura 5 – Função degrau simples.




Figura 6 – Função logística.

2- Função tangente hiperbólica

Produzindo valores de saída no intervalo fechado $[-1,1]$ e permitindo a existência dos valores negativos é destacada na Figura 7, e definida pela expressão:

$$y = f(p) = \frac{1 - e^{-ap}}{1 + e^{-ap}}$$




Figura 7 – Função tangente hiperbólica.

5.3 TREINAMENTO OU APRENDIZADO

A maioria dos modelos de redes neurais possui alguma regra de treinamento, em que os pesos de suas conexões são ajustados de acordo com os padrões apresentados, ou seja, elas aprendem através de exemplos (HAYKIN, 2001). Sendo assim a rede neural é capaz de extrair regras básicas a partir de dados reais

O objetivo do treinamento de uma rede neural artificial é fazer com que a aplicação de um conjunto de entradas produza um conjunto de saídas desejado, ou no mínimo um conjunto de saídas consistentes. O treinamento é realizado pela aplicação seqüencial dos vetores de entradas, enquanto os pesos da rede são ajustados convergindo para determinados valores.

Na rede neural multicamada é utilizada a Regra do Delta, ou a aprendizagem é realizada a partir de um processo contínuo de redução do erro existente entre a resposta atual de um neurônio a um estímulo e a sua correspondente resposta desejada (HAYKIN, 2001) e expressa na forma

$$w_{if}(t+1) = w_{if}(t) + \Delta w_{if}(t) \quad (1)$$

Onde o parâmetro $\Delta w_{if}(t)$ designado pela expressão

$$\Delta W_{ij}(t) = -n \frac{\partial E(t)}{\partial W_{ij}} \quad (2)$$

O parâmetro de aprendizagem (n) na equação 2, é constante e responsável pela velocidade do aprendizado. O sinal negativo significa a tomada da direção decrescente do gradiente no espaço dos pesos sinápticos.

A retropropagação do erro tornou-se um algoritmo muito utilizado no processo de aprendizagem de redes neurais principalmente em redes neurais multicamadas com uma ou mais camadas escondidas. Basicamente, o algoritmo de retropropagação consiste em dois passos computacionais: o processamento direto e o processamento reverso. No processamento direto, uma entrada é aplicada à rede neural e seu efeito é propagado pela rede, camada a camada.

Durante o processamento direto, os pesos sinápticos da rede permanecem fixos. No processamento reverso, um sinal de erro calculado na saída da rede é

propagado no sentido reverso, camada a camada. Ao final deste processo, os pesos sinápticos são ajustados de acordo com a regra do Delta. O algoritmo de retro-propagação do erro é considerado terminado quando estabelece valores para parâmetros livres, de forma que a derivada primeira da superfície de erro é próxima de zero ou de um número positivo muito pequeno, e a soma das funções que efetuam uma medida do erro em cada neurônio é próxima de zero ou de um número positivo muito pequeno

A seguir, apresentamos em detalhe o algoritmo de retropropagação admitindo uma rede neural direta com três camadas: uma camada de entrada, uma camada oculta e uma camada de saída como mostrado na Figura 8.

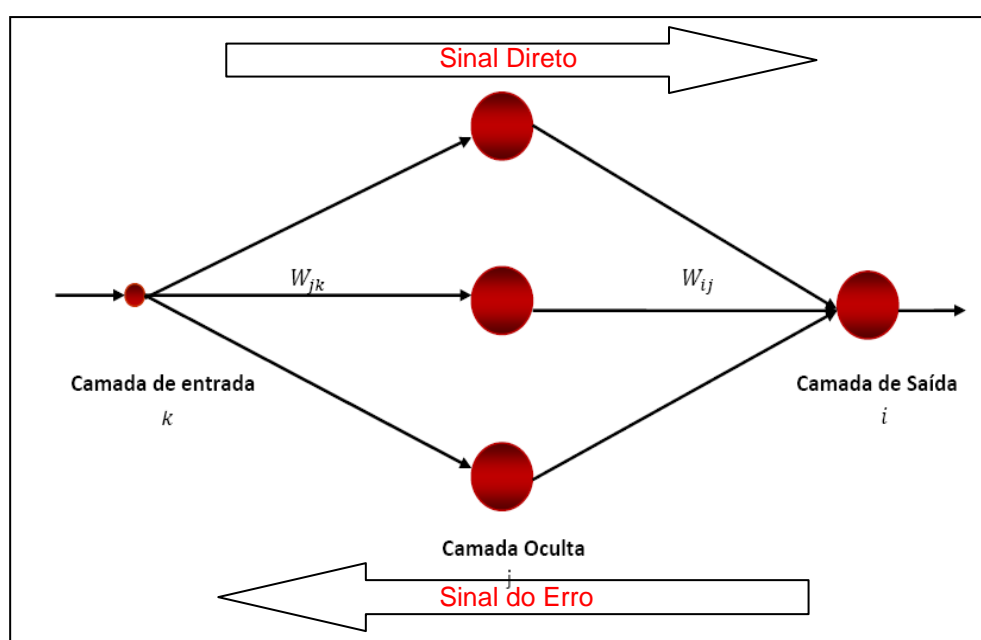


Figura 8 – Rede neural com três camadas.

O valor do sinal direto (de saída) do neurônio i ($S_i(t)$), pertencente à camada de saída da rede no instante t , isto é, na t -ésima apresentação de um mesmo par estímulo resposta ou na apresentação do t -ésimo par estímulo resposta, é mostrado a seguir

$$S_i(t) = f(p_i(t)) = \frac{1}{1 + e^{-p_i(t)}} \quad (3)$$

Assim a expressão para o potencial de ativação, considerando-se um número N de conexões com o neurônio i fica da seguinte forma:

$$P_i = \sum_{j=1}^N W_{ij} S_j \quad (4)$$

Como o neurônio i representa um neurônio arbitrário pertencente à camada de saída da rede, o seu estado $S_i(t)$ pode ser interpretado como um exemplo do sinal direto que se propagou pela rede desde a camada de entrada. Do mesmo modo os sinais diretos dos neurônios situados na camada oculta e que se conectam ao neurônio i serão designados por $S_j(t)$.

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

$$e_i(t) = D_i - S_i(t) \quad (5)$$

Na equação acima D_i representa a resposta desejada para o neurônio i .

A partir da equação anterior a função objeto ou função erro global é definida. Esta equação é característica do algoritmo de retro-propagação do erro para a camada de saída, supondo-se que apenas um único par estímulo-resposta seja apresentado à rede na forma

$$E(t) = \frac{1}{2} \sum_{i=1}^M e_i^2(t) \quad (6)$$

Interpreta-se essa equação como sendo a soma quadrática de todos os erros locais dos M neurônios que compõem a camada de saída da rede no instante de tempo t . Ela é a função dos pesos sinápticos W_{ij} , ou seja, dos parâmetros livres da rede.

O algoritmo de aprendizagem de retro-propagação do erro tem como objetivo básico o ajuste dos parâmetros livres da rede, de modo a promover uma minimização da função objeto $E(t)$. Assim de acordo com as equações 3 e 4 torna-se necessário considerar somente o ajuste sobre os valores dos pesos sinápticos, os quais serão calculados de acordo com os respectivos erros a cada instante de tempo. O ajuste sobre o peso sináptico W_{ij} , que representa a conexão entre o neurônio i da camada de saída e o neurônio j da camada oculta, no instante t , a partir da regra do Delta expressa na equação 1.

Para a determinação de $\Delta W_{ij}(t)$ torna-se necessário o cálculo da derivada parcial mostrada na equação 2. Para isto será utilizada a regra da cadeia do cálculo infinitesimal, obtendo

$$\frac{\partial E(t)}{\partial W_{ij}} = \frac{\partial E(t)}{\partial e_i(t)} \frac{\partial e_i(t)}{\partial S_i(t)} \frac{\partial S_i(t)}{\partial P_i(t)} \frac{\partial P_i(t)}{\partial W_{ij}(t)} \quad (7)$$

Desenvolvemos separadamente os termos da equação 7. Iniciamos com a diferenciação da equação 6 em relação à $e_i(t)$

$$\frac{\partial E(t)}{\partial e_i(t)} = e_i(t) \quad (8)$$

Diferenciando ambos os lados da equação 5 em relação à $S_i(t)$ e observando que a resposta desejada é constante durante todo o período de aprendizagem, temos que

$$\frac{\partial e_i(t)}{\partial S_i(t)} = -1 \quad (9)$$

Para a determinação do próximo termo, deriva-se a equação 3 em relação ao parâmetro $P_i(t)$

$$\frac{\partial S_i(t)}{\partial P_i(t)} = f'(P_i(t)) = -\frac{e^{-P_i(t)}}{(1 + e^{-P_i(t)})^2} \quad (10)$$

O termo $f'(P_i(t))$, na equação 10, representa a derivada da função de ativação em relação ao potencial de ativação do neurônio i no instante t . Diferenciando o último termo da equação 4 em relação ao peso sináptico $W_{ij}(t)$, obtemos

$$\frac{\partial P_i(t)}{\partial W_{ij}(t)} = S_j(t) \quad (11)$$

Para finalizarmos, substituímos as equações 8, 9, 10 e 11 na equação 7 obtendo

$$\frac{\partial E(t)}{\partial W_{ij}} = -e_i(t) f'(P_i(t)) S_j(t) \quad (12)$$

Com isto a equação 2 será reescrita na forma

$$\Delta W_{ij}(t) = n e_i(t) f'(P_i(t)) S_j(t) \quad (13)$$

Logo, para os neurônios localizados na camada de saída da rede, obtemos o sinal inverso e calculamos as modificações nos pesos sinápticos utilizando a equação 13.

Será considerado agora o caso dos neurônios localizados na camada oculta. É claro que não existe uma resposta desejada pré-especificada para estes neurônios e, portanto a determinação do sinal inverso não pode mais ser realizada utilizando-se a equação 5. O cálculo do sinal inverso para um neurônio j , localizado em uma camada oculta, será realizado de forma recursiva, em função dos sinais inversos de todos os neurônios da camada imediatamente anterior. A primeira camada para a qual se calcula o sinal inverso é a camada de saída da rede e assim, sucessivamente, até a camada de entrada.

Para a determinação da correção $\Delta W_{jk}(t)$ a ser aplicada ao peso sináptico $W_{jk}(t)$ utilizaremos a equação 2. O peso sináptico $W_{jk}(t)$ representa a conexão entre o neurônio j da camada oculta e o neurônio k da camada de entrada, no tempo t . Reescrevemos a equação 2 mostrando os novos índices, na forma

$$\Delta W_{jk} = -n \frac{\partial E(t)}{\partial W_{jk}} \quad (14)$$

A quantidade $E(t)$, para um neurônio j da camada oculta, será definida na forma

$$E(t) = \frac{1}{2} \sum_i^M e^2_i = \frac{1}{2} \sum_i^M \left[D_i - \frac{1}{1 + e^{-P_i(t)}} \right]^2 \quad (15)$$

Na equação 15, o índice i representa um neurônio pertencente à camada de saída da rede. A derivada parcial à direita da equação 14, a partir da regra da cadeia, pode ser escrita na forma

$$\frac{\partial E(t)}{\partial W_{jk}(t)} = \frac{\partial E(t)}{\partial S_j(t)} \frac{\partial S_j(t)}{\partial P_j(t)} \frac{\partial P_j(t)}{\partial W_{jk}(t)} \quad (16)$$

Discutiremos cada termo da equação 16, começando pelo termo $\frac{\partial E(t)}{\partial S_j(t)}$, para o qual aplicaremos a regra da cadeia na equação 15, obtendo o resultado parcial

$$\frac{\partial E(t)}{\partial S_j(t)} = \sum_i^M e_i(t) \frac{\partial e_i(t)}{\partial S_j(t)} \quad (17)$$

Utilizando novamente a regra da cadeia, a equação 17 pode ser desenvolvida para

$$\frac{\partial E(t)}{\partial S_j(t)} = \sum_i^M e_i(t) \frac{\partial e_i(t)}{\partial P_i(t)} \frac{\partial P_i(t)}{\partial S_j(t)} \quad (18)$$

Derivando a equação 5 em relação ao potencial, temos

$$\frac{\partial e_i(t)}{\partial P_i(t)} = -f'(P_i(t)) \quad (19)$$

Derivando a equação 4 em função de $S_j(t)$ chegamos ao seguinte resultado

$$\frac{\partial P_i(t)}{\partial S_j(t)} = W_{ij}(t) \quad (20)$$

Com isto a equação 18 fica escrita na seguinte forma

$$\frac{\partial E(t)}{\partial S_j(t)} = - \sum_i^M e_i(t) f'(P_i(t)) W_{ij}(t) \quad (21)$$

A equação 11, escrita agora para o neurônio j da camada oculta, é dada por

$$\frac{\partial P_j(t)}{\partial W_{jk}(t)} = S_k(t) \quad (22)$$

E a equação 10 fica na forma,

$$\frac{\partial S_j(t)}{\partial P_j(t)} = f'(P_j(t)) \quad (23)$$

A equação 16 pode então, ser escrita na forma final

$$\frac{\partial E(t)}{\partial W_{kj}(t)} = -S_k(t)f'(P_j(t)) \sum_i^M e_i(t)f'(P_i(t))W_{ij}(t) \quad (24)$$

A correção do peso sináptico W_{ij} de todas as camadas intermediárias ou ocultas será então escrita na forma

$$\Delta W_{jk}(t) = n S_k(t)f'(P_j(t)) \sum_i^M e_i(t)f'(P_i(t))W_{ij}(t) \quad (25)$$

5.4 FASE DE OPERAÇÃO

A fase de operação refere-se à maneira como a rede neural artificial processa os estímulos apresentados na sua camada de entrada e cria uma resposta em sua camada de saída.

A generalização é a principal característica de uma rede neural na fase de operação e responsável pela sua capacidade de solucionar problemas. A operação da rede pode ter influência de três fatores: O tamanho do conjunto de treinamento, a arquitetura da rede e a complexidade do problema tratado.

O que se espera de uma rede neural treinada é que ela tenha a capacidade de fazer uma generalização como mostra a Figuras 9, que apresenta o mapeamento do conjunto (espaço) de estímulos (entradas) no conjunto de saída

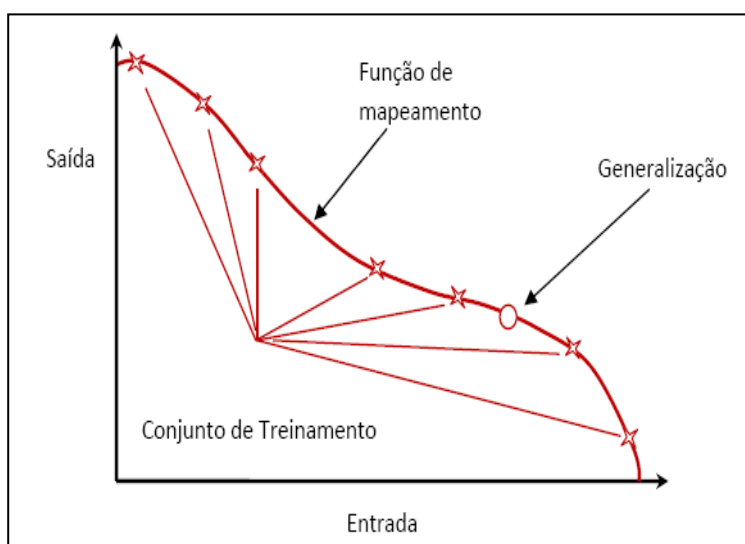


Figura 9 – Generalização da rede neural.

6 METODOLOGIA

Neste capítulo apresenta-se a solução do problema da identificação de uma facie reservatório em um poço não testemunhado, com a utilização de múltiplos perfis geofísicos de poço aberto, na forma de um problema de decisão, através do desenvolvimento de uma estratégia conveniente para o treinamento de uma rede neural direta multicamadas, com a utilização do algoritmo da retropropagação do erro para a produção de um mapeamento da informação geológica extraída do testemunho em termos das propriedades físicas registradas nos perfis.

A identificação de fácies é comumente realizada a partir da análise de testemunhos. Tradicionalmente, a identificação de fácies provem da observação direta do testemunho. Na grande maioria dos poços *onshore*, a operação de testemunhagem é rara e a recuperação das amostras de rocha é freqüentemente inferior a 100% (ELLIS, 1987). Além disso, descrição geológica de testemunhos para a identificação das facies apresenta um alto fator HH (homem/hora). Por outro lado, a grande maioria dos poços *offshore*, são do tipo horizontal, que é o componente fundamental o conveniente desenvolvimento dos campos marítimos e não permite a realização de operações de testemunhagem (SAGAFF e NEBRIJA, 2000).

Quando uma camada de rocha sedimentar não possui porosidade ou é constituída por um único material homogêneo, a identificação da fácies através da interpretação dos perfis geofísicos de poço aberto é imediata, como por exemplo, considere o caso de uma rocha evaporítica, como a halita (NaCl). Neste caso, o perfil de densidade é suficiente para diagnosticar presença deste mineral, a partir de seu valor característico de densidade ($2,1 \text{ g/cm}^3$). Infelizmente, os evaporitos não tem interesse como rocha reservatório. As rochas reservatório, importantes para a exploração de fluidos em subsuperfície, apresentam, na grande maioria dos casos, uma constituição mineralógica bastante complexa, como no caso dos arenitos, que na grande maioria das ocorrências, não é composto exclusivamente por quartzo, mas por variadas combinações de quartzo, argilominerais, calcário e outros minerais. Assim, a identificação de fácies através da interpretação de perfis é uma tarefa complexa, onde se assume que fácies diferentes apresentam

diferentes propriedades físicas que afetam diferentemente as respostas dos perfis (SERRA, 1985).

A questão pertinente é a da determinação de como as diferentes fácies alteram as propriedades físicas registradas nos perfis. A resposta a esta questão é não trivial. A abordagem para responder a esta questão, adotada neste trabalho de conclusão de curso, é a de apresentar uma rede neural treinada para produzir um mapeamento da informação geológica extraída do testemunho em termos das propriedades físicas registradas nos perfis.

O projeto da rede neural envolve três estágios:

- 1- A definição do número de camadas e do modo de interconexão entre elas.
- 2- A definição do número de neurônios em cada camada e as suas respectivas funções de ativação.
- 3- A definição de um conveniente conjunto de treinamento.

A arquitetura da rede neural para a identificação de uma fácies reservatório utilizando múltiplos perfis é formada por três camadas. A primeira camada possui um número de neurônios igual ao número de perfis a serem utilizados. Assume-se que foram efetuadas todas as correlações ambientais e que os intervalos dos perfis contenham o trecho testemunhado. A segunda camada é composta por 50 neurônios processadores, com a função sigmóide como função de ativação. A camada de saída é composta por um único neurônio com uma função linear como função de ativação e a cada intervalo de profundidade produzirá uma saída igual a um, quando da identificação da fácies reservatório de referência e um valor igual a zero para o caso contrário. Deste modo, como a rede é treinada para produzir um mapeamento da informação geológica extraída do testemunho em termos das propriedades físicas registradas nos perfis de poço, o sinal ideal de saída da rede neural será um vetor binário (0,1), contendo o valor 1(um) exatamente nos intervalos de profundidade correspondentes à ocorrência da fácies reservatório de treinamento, e zeros para todos os intervalos de profundidade de não ocorrência desta fácies. Espera-se, assim, que seja possível a determinação das espessuras das diversas ocorrências da fácies reservatório de referência, tanto no poço de treinamento, quanto nos outros poços do campo petrolífero, que cruzam o mesmo cenário geológico. Espera-se, ainda, que o processamento da rede neural seja

suficientemente robusto, para de forma independente da espessura da fácies de treinamento, que define o número de pontos no conjunto de treinamento, a rede neural treinada seja capaz de corretamente identificar a fácies reservatório de referência nos outros poços independente das espessuras nas quais elas ocorrem.

O conjunto de treinamento, para a identificação de uma fácies reservatório utilizando múltiplos perfis, possui as seguintes características:

- O conjunto de estímulos é formado por um intervalo de profundidade para todos os perfis, tal que contenha o intervalo testemunhado da fácies reservatório de referência, na forma de uma matriz em que cada linha corresponda a um tipo perfil e cada coluna corresponda aos valores das propriedades físicas mensuradas em cada ponto de profundidade do poço, no intervalo de profundidades adotado.
- O conjunto de respostas desejadas é formado por um vetor binário de mesma dimensão da linha da matriz de estímulos, no qual o valor um indica a ocorrência da fácies reservatório de referência e o valor zero, a sua ausência.

A arquitetura da rede neural aqui utilizada é mostrada na Figura-10.




Figura 10 – Arquitetura da rede neural.

7 RESULTADOS

A aplicação da rede neural aqui apresentada ocorrerá com a utilização de cinco perfis, que são raios gama natural (RG), resistividade profunda (RES), Perfil Sônico (DELt), perfil de densidade (RHOb) e o perfil de porosidade neutrônica (PHIN), registrados em 3 poços offshore perfurados na bacia de campos Brasil. Estes poços foram testemunhados e cruzam uma camada de arenito (arenito médio gradado) tomado como fácies reservatório de referência. O poço, aqui denominado de Poço-A é tomado como poço de referência para o treinamento da rede. Na Figura 11 mostra-se o conjunto de perfis tomado no Poço-A. A fácies de referência é destacada pelo sombreado em azul. Na Figura 12 apresenta-se a descrição faciológica do Poço-A determinada pela análise de testemunho. Apresenta-se ainda o perfil de raios gama natural de modo a possibilitar a interpretação da fácies de referência mostrada na Figura 11.

O intervalo de 3.020m a 3.048m de profundidade do Poço-A foi tomado como o intervalo de treinamento é mostrado na Figura 13 pelo sombreado em azul. Este intervalo de profundidade define a matriz de estímulos para o treinamento e o número de colunas define a dimensão do vetor binário de respostas desejadas.

A primeira avaliação do comportamento da rede neural treinada ocorre com a apresentação de todo o trecho perfilado do Poço-A. A Figura 14 apresenta o resultado da aplicação da rede neural. A Figura 14-A mostra o perfil de raios gama natural do trecho perfilado do Poço-A. A figura 14-B mostra a resposta da rede treinada para todo o trecho perfilado Poço-A. Observa-se que a rede incluiu a parte basal da fácies reservatório, não incluída no intervalo de treinamento. A espessura da fácies reservatório, definida pela rede neural é condizente com a espessura desta fácies no testemunho. A figura 14-C mostra o perfil de raios gama destacando em vermelho a ocorrência da fácies reservatório. Para a avaliação da capacidade de transporte da informação geológica extraída do poço A através do mapeamento da informação geológica produzida pela análise de testemunho em valores de propriedades físicas registrados nos perfis realizados pelo treinamento da rede neural para outros poços, que em uma aplicação prática seriam não testemunhados ou ainda para a verificação da geometria de poços horizontais no interior da camada reservatório.

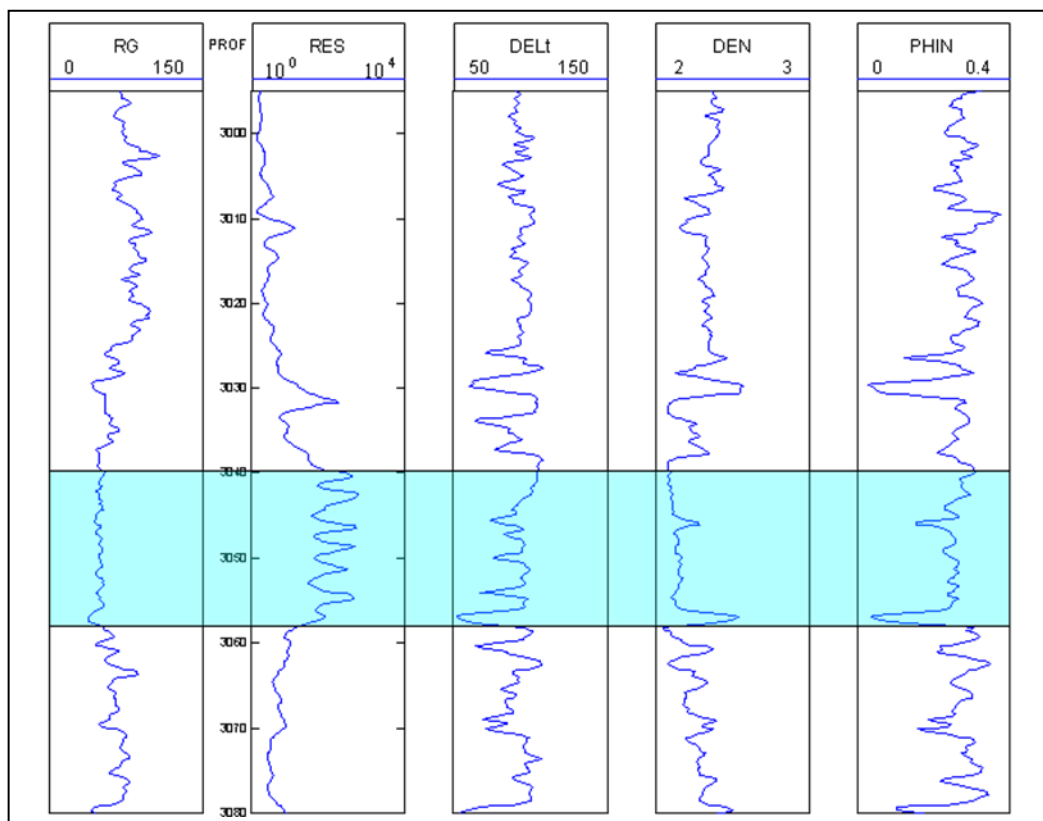


Figura 11 – Perfis convencionais do Poço-A

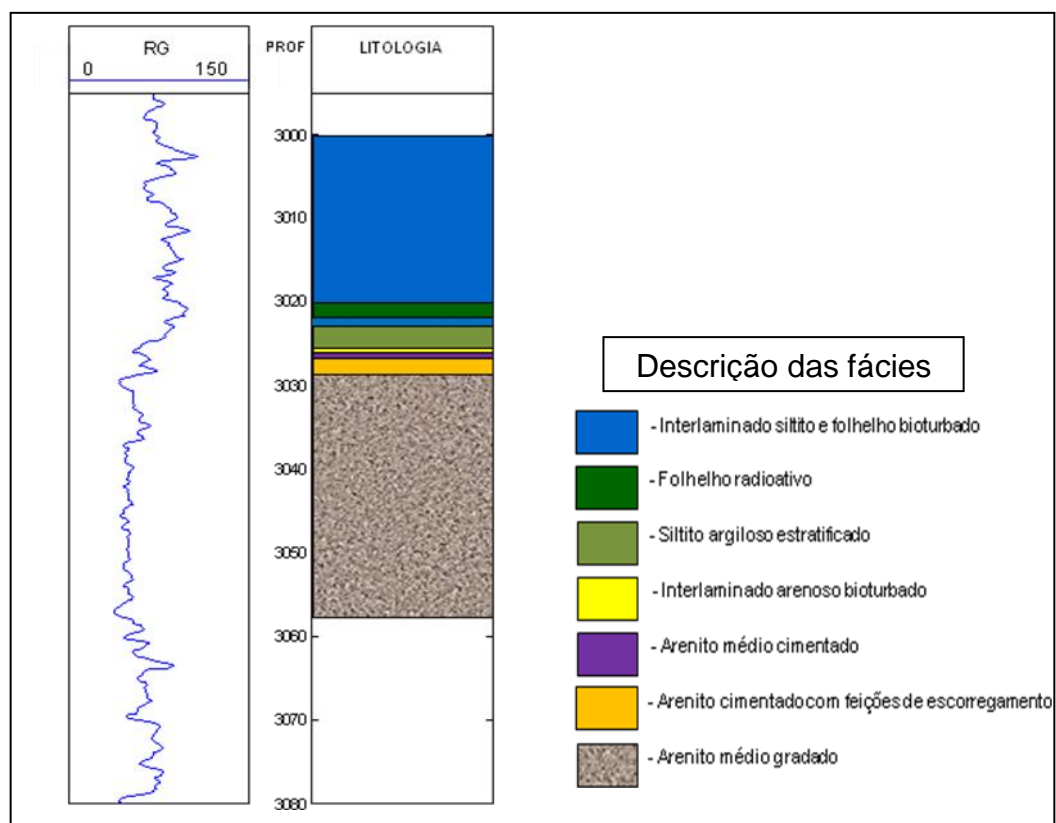


Figura 12 – Descrição das fácies do Poço-A.

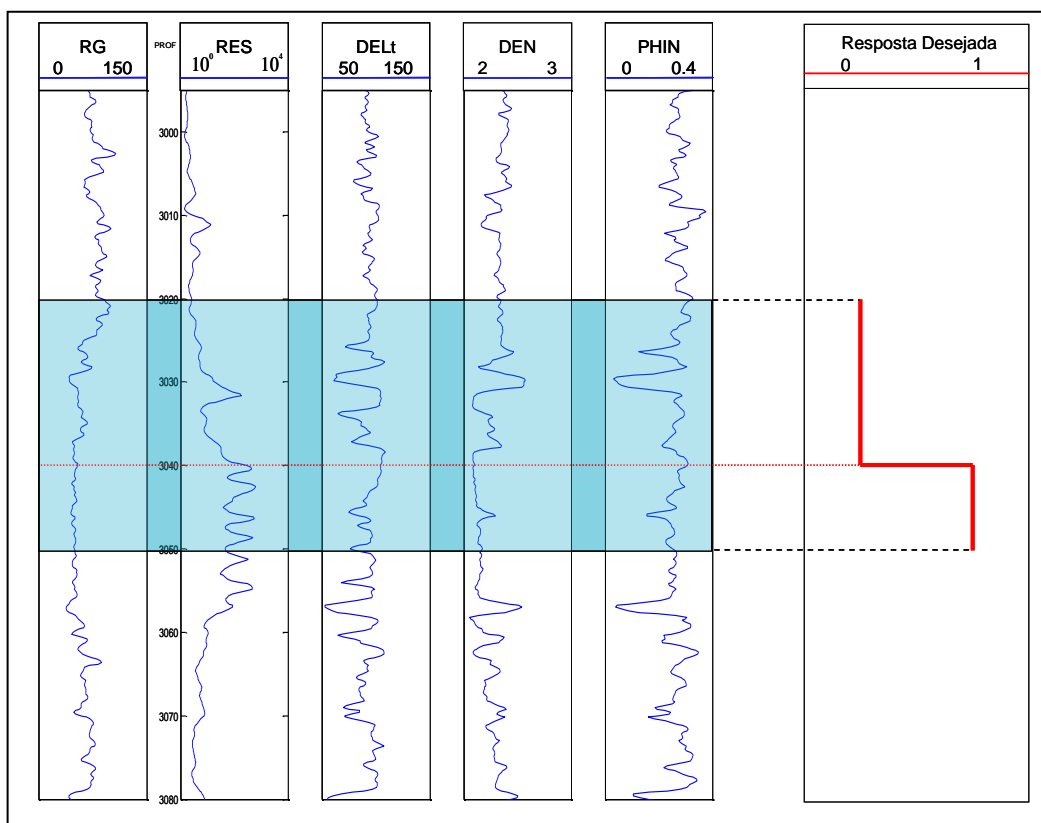


Figura 13 – Perfis convencionais do Poço-A. O sombreado em azul marca o intervalo de treinamento.

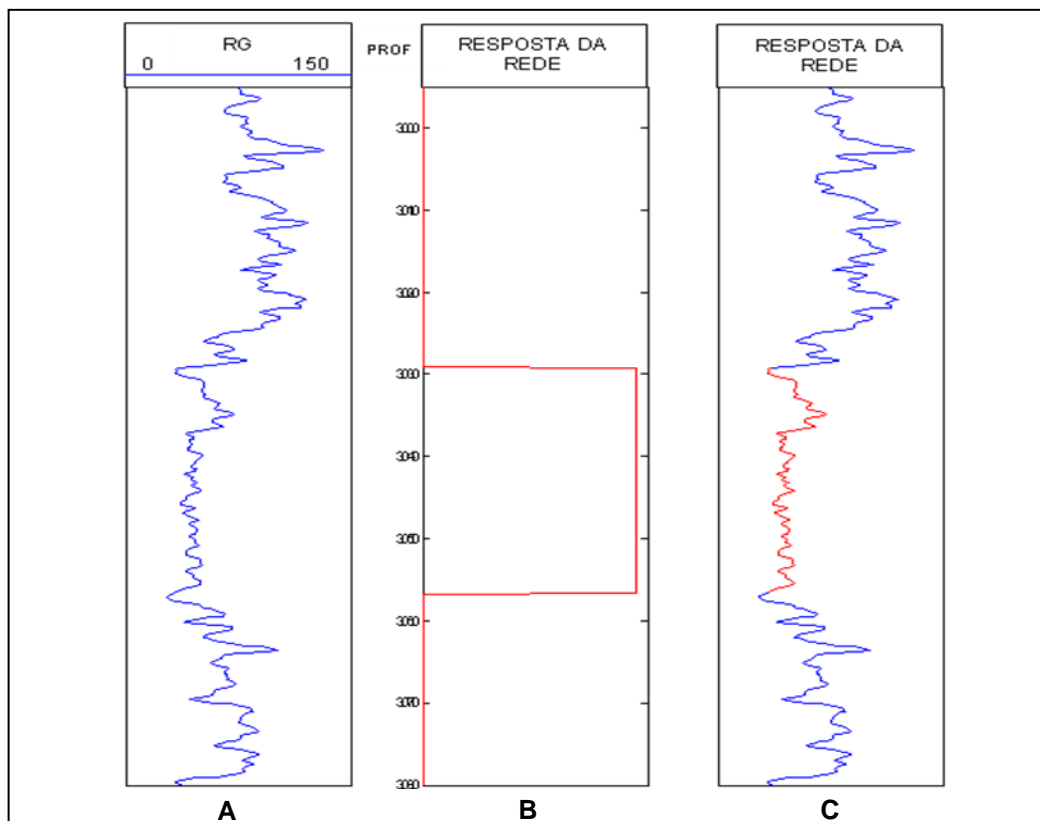


Figura 14 – Identificação da fácies de referência pela rede neural.

Neste trabalho de conclusão de curso avaliamos esta capacidade de transporte do mapeamento da informação geológica, utiliza-se dois poços testemunhados, aqui denominados como Poço-B e Poço-C, perfurados nas proximidades do Poço-A, de referência. A análise faciológica do Poço-B e do Poço-C indica a ocorrência da fácies reservatório de referência.

A Figura 15 mostra o conjunto de perfis mensurados em um trecho do Poço-B. A descrição faciológica do Poço-B obtida pela análise de testemunho é apresentada na Figura 16 em conjunto com o perfil de raios gama natural para referência com a Figura 15.

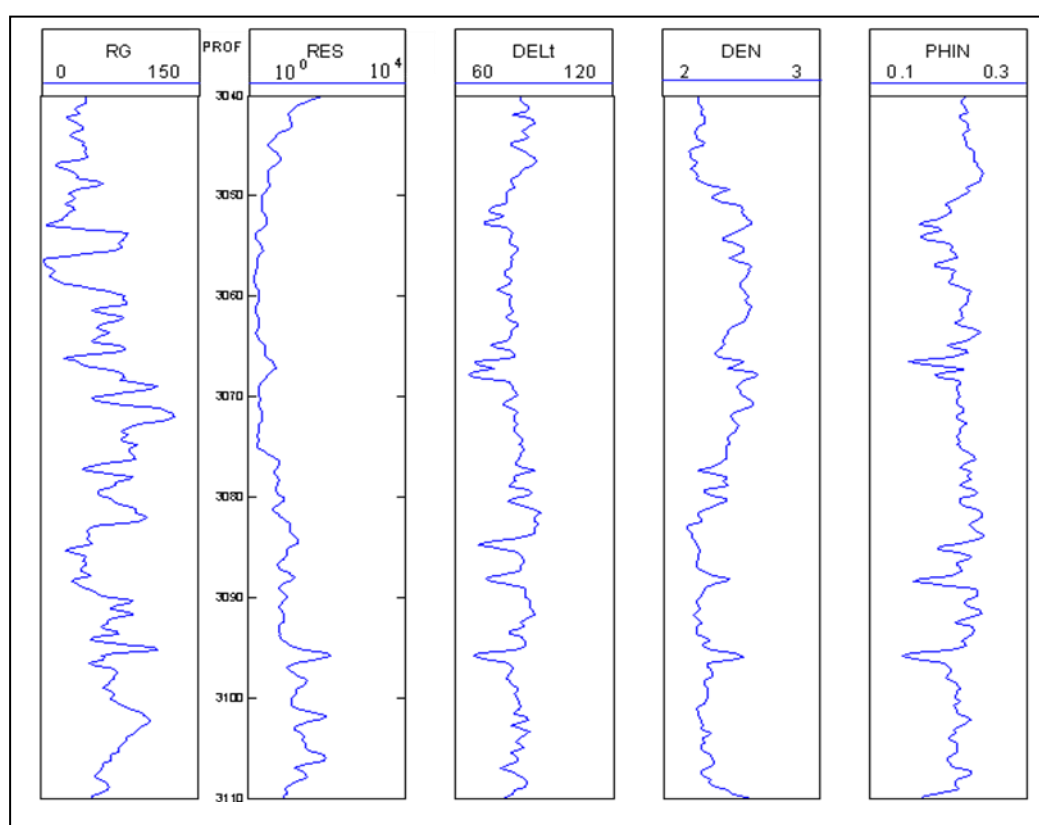


Figura 15 – Perfis convencionais do Poço-B.

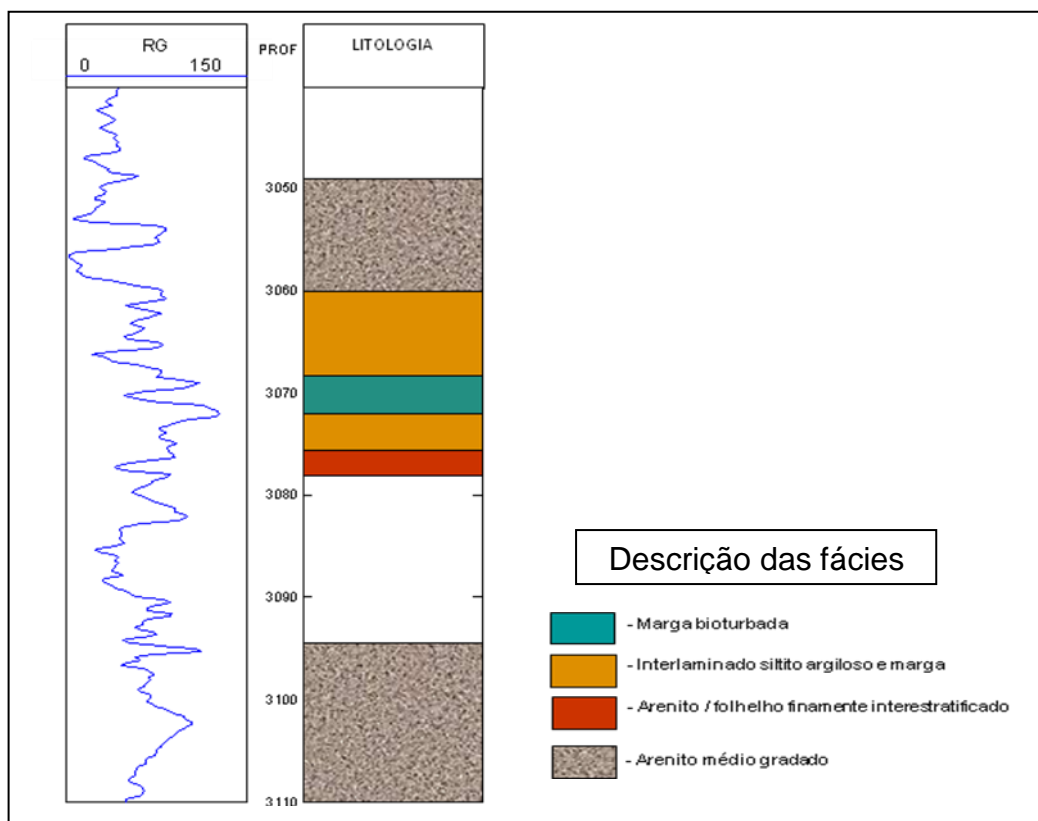


Figura 16 – Descrição das fácies do Poço-B.

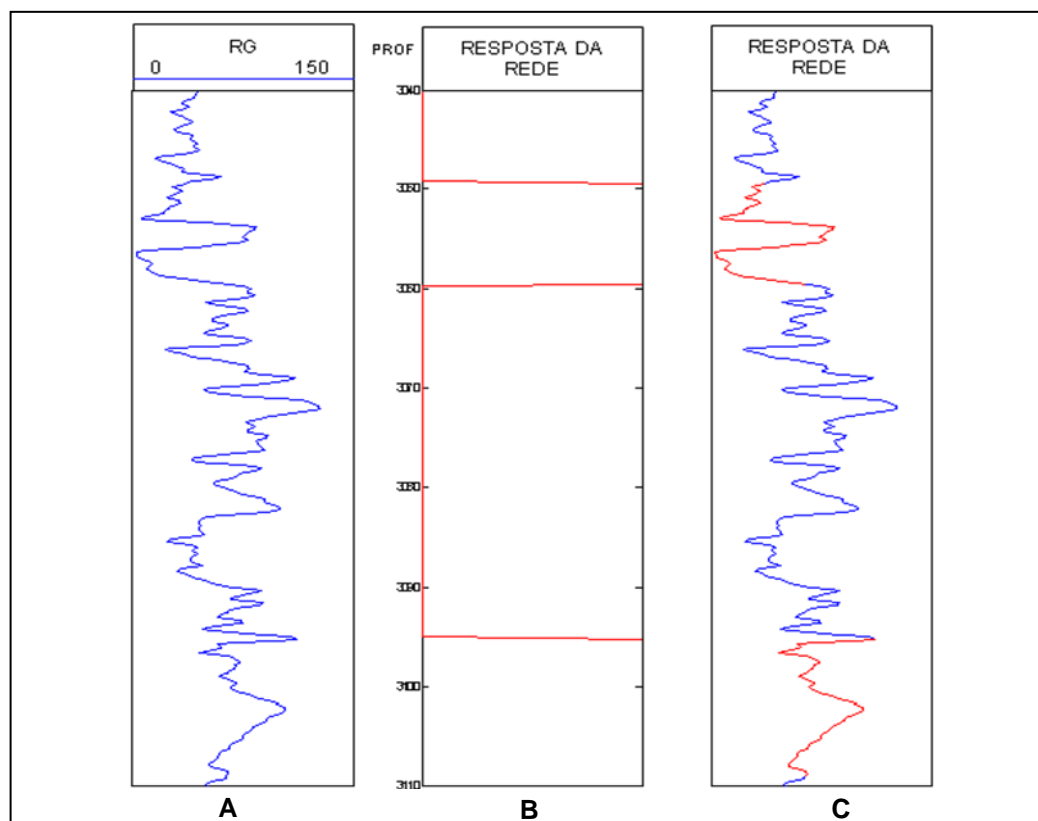


Figura 17 – Identificação da fácies de referência pela rede neural.

O resultado da aplicação da rede neural treinada com a informação geológica do poço A, que foi aplicada como entrada uma matriz de estímulos contendo a informação dos perfis mensurados no poço B é apresentada na Figura 17. A Figura 17-A mostra o perfil de raios gama natural mensurado em um trecho de profundidade do poço B. A Figura 17-B mostra o resultado da aplicação da rede neural aos dados de perfil do poço B. A Figura 17-C mostra o perfil de raios gama natural do poço B destacando em vermelho as ocorrências da fácies reservatório. Observa-se a coerência nas profundidades de ocorrência da fácies reservatório confrontando a Figura 17-C com a Figura 16.

Como uma terceira aplicação do mapeamento realizado pela rede neural da informação geológica e os dados de perfil do poço A mostra-se na Figura 18 um conjunto de perfis mensurados em um trecho do poço C, também localizado nas proximidades do poço A e cuja análise faciológica mostra a ocorrência da fácies reservatório de referência como mostrado na Figura 19, que também apresenta o perfil de raios gama natural do poço C como referência. A Figura 20 mostra o resultado da aplicação aos dados de perfil do poço C, como entrada para a rede neural. A Figura 20-A mostra o perfil de raios gama natural do poço C. A Figura 20-B mostra a saída da rede neural e na Figura 20-C destaca-se em vermelho a ocorrência da fácies reservatório definida pela rede neural. Observa-se a coerência da localização da fácies reservatório de referência determinada pela rede neural com a descrição de testemunho do poço C.

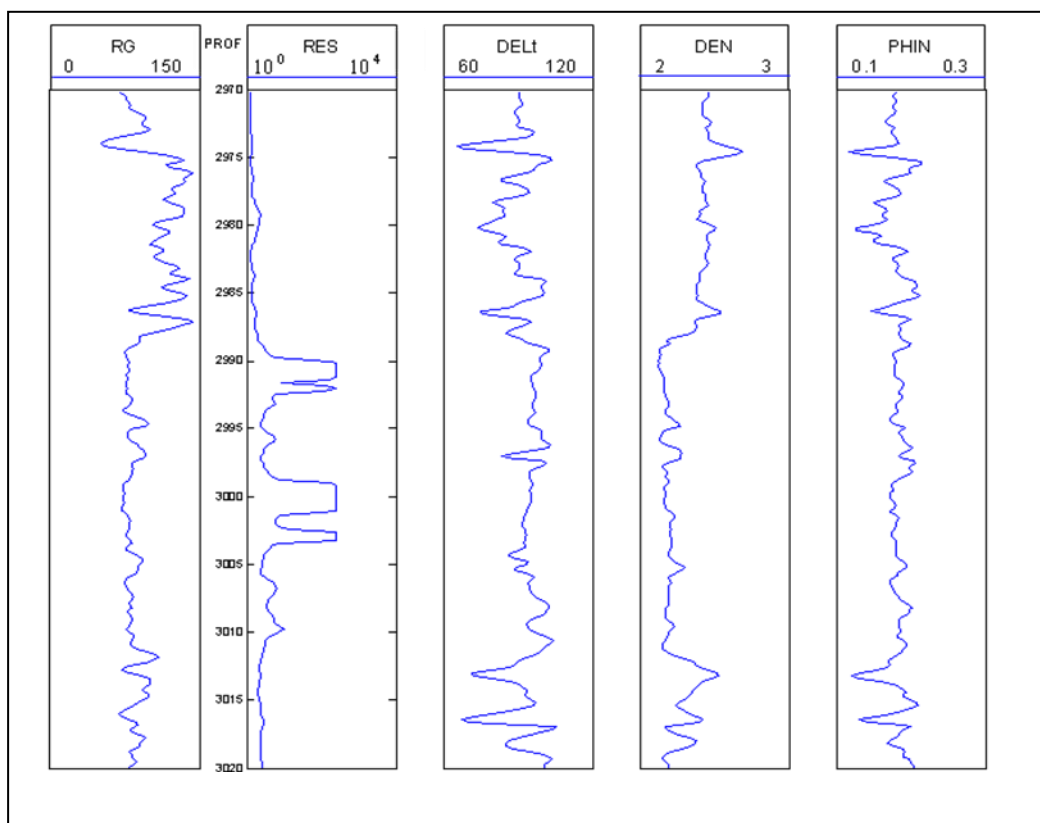


Figura 18 – Perfis convencionais do Poço-C.




Figura 19 – Descrição das fácies do Poço-C.

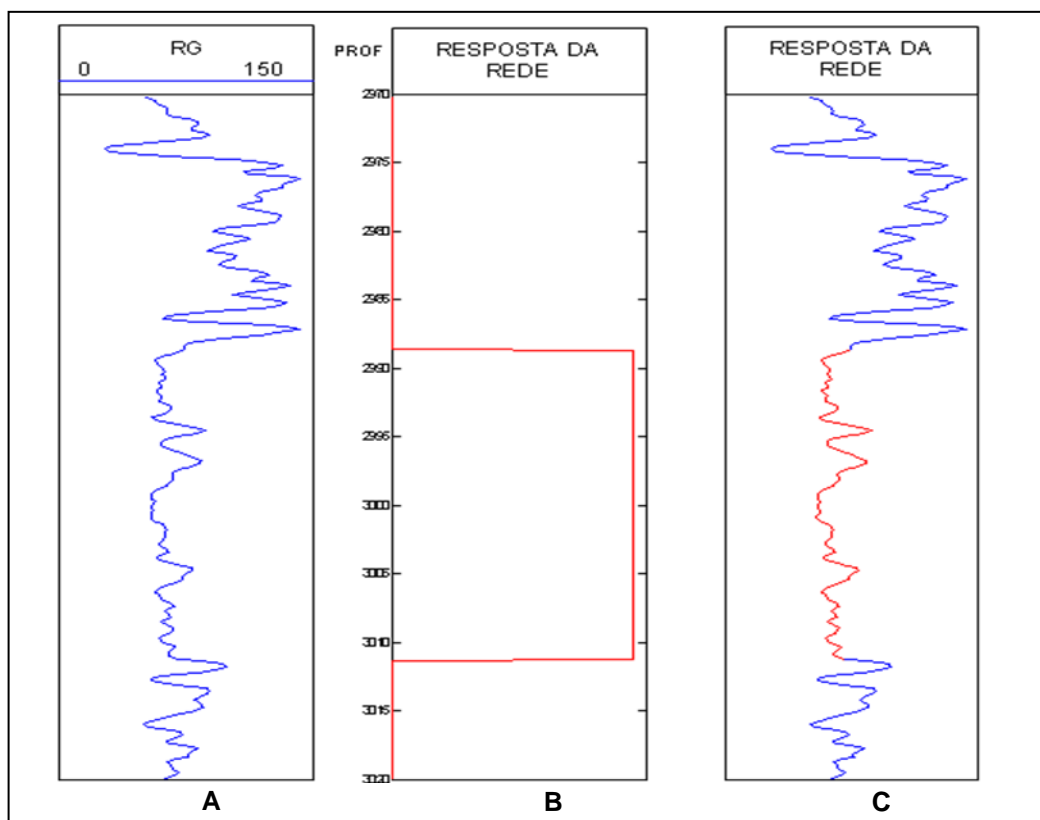


Figura 20 – Identificação da fácies de referência pela rede neural.

8 CONCLUSÕES

O principal produto da avaliação geológica dos testemunhos é a descrição de fácies, que é fundamental para a produção da carta estratigráfica de uma bacia sedimentar e para a produção do modelo geológico do sistema petrolífero. No entanto estas importantes atividades para a exploração do petróleo são restritas aos poços testemunhados. A ausência e ou a dispersão de poços testemunhados ao longo da área superficial de um reservatório implicam na impossibilidade da utilização direta das informações geológica produzidas nesses poços. A alternativa para contornar esta importante restrição é a utilização dos perfis geofísicos de poço aberto, e ainda, para a geofísica de poço, o conhecimento das fácies atravessadas pelo poço, cuja importância reside na dependência entre as fácies e as propriedades físicas registradas nos perfis conduzem conseqüentemente uma avaliação de formação e a um cálculo de reservas mais realista.

Mostrou-se aqui, a capacidade da rede neural treinada com o algoritmo da retropropagação do erro de produzir um mapeamento da informação geológica extraída dos testemunhos usando as medidas de propriedades físicas registradas nos perfis geofísicos de poço aberto. Mostrou-se também que a rede neural possibilita o transporte da informação geológica obtida em poço testemunhado para outros poços não testemunhados, perfurados nas vizinhanças do poço de referência.

A aplicabilidade desta metodologia foi verificada com a utilização de dois poços testemunhados cujos dados não foram utilizados no processo de aprendizagem da rede. Para os casos aqui avaliados a rede neural apresentou resultados compatíveis com a análise de testemunho e de forma completamente independente da dimensão do conjunto de treinamento.

Uma das extensões naturais desta metodologia é a produção de seções estratigráficas e seções estruturais através da correlação de perfis poço a poço, que pode auxiliar na prospecção de petróleo principalmente com a identificação de possíveis armadilhas do tipo estratigráficas.

REFERÊNCIAS

ELLIS, D. V. **Well logging for earth scientists**. USA, Elsevier. 1987.

HAYKIN, S. **Redes neurais: princípios e práticas**. São Paulo, Bookman. 2001.

HECHT-NIELSEN, R. Kolmogorov's mapping neural network existence theorem. In: IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1., 1987, New York. **Resumos**. V. 3, p. 11-14. 1987.

LUTHI, S. **Geological well logs: their use in reservoir modeling**. [S.l.]: Springer. 2001

QI, L.; CARR, T. R. **Neural network prediction of carbonate lithofacies from well logs, Big Bow and Sand Arroyo Creek fields, Southwest Kansas** [artigo científico]. Disponível em: <www.elsevier.com/locate/cageo> Acesso em 14 fev 2006.

SAGGAF, M.M.; NEBRIJA, E. L. Estimation of Missing Logs by Regularized Neural Networks. **APPG Bulletin**, 8. V.87, p.1377-1389. 2003.

SERRA, O. **Fundamentals of well log interpretation**. [S.l.]: Schlumberger. 1984. V. 1. The Acquisition of Logging Data.

SERRA, O. **Sedimentary environments from Wireline logs**. [S.l.]: Schlumberger. 1985.

SUGUIO, K. **Rochas sedimentares: propriedades, gênese e Importância econômica**. São Paulo, SP: Edgard Bucher, EDUSP. 1980.