

AJUSTE DE HISTÓRICO DE PRODUÇÃO USANDO REDES NEURAIS ARTIFICIAIS

Tiago Pitchon Sampaio

**PROJETO FINAL SUBMETIDO AO CORPO DOCENTE DO CURSO DE
ENGENHARIA DO PETRÓLEO DA ESCOLA POLITÉCNICA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE
INTEGRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO
GRAU DE ENGENHEIRO DO PETRÓLEO.**

Aprovado por:

Virgílio José Martins Ferreira Filho
(Orientador)

Abelardo de Sá Neto
(Co-orientador)

Flávio Dickstein

RIO DE JANEIRO, RJ – BRASIL

JANEIRO, 2009

Dedicatória

(Opcional)

Agradecimientos

(Opcional)

Sumário

Nomenclatura	vi
Lista de Figuras	ix
Lista de Tabelas	xii
Resumo	xiii
Abstract	xv
1. Introdução	1
2. Reservatórios de Petróleo	3
2.1. Principais Propriedades do Reservatório.....	4
2.1.1. Propriedades da Rocha	4
2.1.1.1. Porosidade (ϕ).....	4
2.1.1.2. Compressibilidade Efetiva (c_f)	4
2.1.1.3. Saturação de Fluidos (S).....	5
2.1.1.4. Permeabilidade (k).....	6
2.1.2. Propriedades dos Fluidos.....	6
2.1.2.1. Viscosidade (μ_i).....	6
2.1.2.2. Compressibilidade (c).....	7
2.1.2.3. Fator Volume Formação (B).....	7
2.2. Descrevendo as Propriedades do Reservatório.....	7
2.3. Simulação de Reservatórios.....	9
2.3.1. Formulação Matemática	10
2.3.1.1. Equação de Fluxo para o Escoamento Monofásico.....	10
2.3.1.2. Equação de Fluxo para o Escoamento Multifásico	14

3. Redes Neurais Artificiais.....	19
3.1. Redes <i>Feed-Forward</i>	21
3.2. Algoritmos de Treinamento <i>Back-propagation</i>	22
3.2.1. Regra de Delta	23
3.2.2. Treinando Redes <i>Feed-forward</i>	24
3.2.2.1. Gradiente Descendente	25
3.2.2.2. Levenberg-Marquardt.....	25
3.3. Considerações.....	26
4. Reservatório Estudado	30
5. Metodologia Proposta	35
5.1. Ajuste de Histórico	35
5.2. O Problema do Ajuste de Histórico e a Metodologia Proposta.....	38
6. Aplicação da Rede Neural no Ajuste de Histórico	41
7. Conclusão	58
8. Referências Bibliográficas	59

Nomenclatura

A	Área	$[m^2]$
B	Fator volume formação	$[(m^3 / m^3)_{std}]$
c	Compressibilidade	$[(kgf/cm^2)^{-1}]$
c_f	Compressibilidade efetiva	$[(kgf/cm^2)^{-1}]$
k	Permeabilidade	$[mD]$
k_r	Permeabilidade relativa	$[-]$
m	Massa	$[kg]$
p	Pressão	$[kgf/cm^2]$
q	Vazão volumétrica	$[m^3/d]$
q_m	Vazão mássica	$[kg/d]$
R_s	Razão de solubilidade do gás no óleo	$[J/kg.K]$
S	Saturação de fluido	$[-]$
S_{gr}	Saturação de gás residual	$[-]$
S_{or}	Saturação de óleo residual	$[-]$
S_{wr}	Saturação de água irreduzível	$[-]$
t	Tempo	$[s]$
u_x	velocidade de escoamento do fluido na direção x	$[m/s]$
u_y	velocidade de escoamento do fluido na direção y	$[m/s]$
u_z	velocidade de escoamento do fluido na direção z	$[m/s]$
V	Volume	$[m^3]$
V_P	Volume de poros	$[m^3]$
V_T	Volume total da rocha reservatório	$[m^3]$

x	Coordenada axial	[m]
y	Coordenada axial	[m]
Z	Altura do volume de controle em relação ao datum	[m]
z	Coordenada axial	[m]

Símbolos Gregos:

β	Coeficiente de expansão térmica	[°F ⁻¹]
Δp	Diferença de pressão	[psi]
Δx	Diferença ao longo da direção x	[m]
Δt	Variação de tempo	[s]
Δy	Diferença ao longo da direção y	[m]
Δz	Diferença ao longo da direção z	[m]
γ	Peso específico	[N/m ³]
ϕ	Porosidade	[-]
ϕ_{eff}	Porosidade efetiva	[-]
μ	Viscosidade	[cp]
ρ	Massa específica	[kg/m ³]

Subscritos:

$()_0$	Condições Iniciais
$()_b$	Volume de controle
$()_g$	Fase gás
$()_{gl}$	Fase gás livre
$()_{gs}$	Fase gás solubilizado
$()_o$	Fase óleo

$()_{res}$ Condições de reservatório

$()_{std}$ Condições de superfície

$()_w$ Fase água

Lista de Figuras

Figura 2-1: Desenho de uma seção transversal de uma amostra de rocha.	3
Figura 2-2: Rocha-reservatório contendo os fluidos: água, óleo e gás (gotas pequenas). 5	
Figura 2-3: Distribuições de uma propriedade de reservatório.	8
Figura 2-4: Exemplo de mapa de porosidade.	9
Figura 2-5: Volume de Controle para o escoamento unidimensional.	11
Figura 2-6: Representação da discretização de uma rocha-reservatório em blocos.	17
Figura 2-7: Fluxograma de uma simulação de reservatórios.	18
Figura 3-1: Esquema de um neurônio.	19
Figura 3-2: Gráfico da função logsig.	20
Figura 3-3: Gráfico da função tansig.	20
Figura 3-4: Gráfico da função purelin.	20
Figura 3-5: Desenho esquemático de uma rede neural do tipo <i>Feed-forward</i>	22
Figura 3-6: Exemplo de <i>overtraining</i> com o aumento do número de neurônios na camada escondida. Treinamento com 12 pares: (a) 5 neurônios e (b) 20 neurônios. Os círculos representam os pares, a linha pontilhada, a função e a linha contínua, a rede neural.	27
Figura 3-7: Exemplo da influência do número de pares no treinamento da rede neural. Os círculos representam os pares, a linha pontilhada, a função e a linha contínua, a rede neural. Em (a) foram usados 4 pares para treinamento e em (b) 20.	28
Figura 3-8: Exemplo de parada prematura.	29
Figura 4-1: Mapa estrutural e de isopacas do reservatório em pés.	31
Figura 4-2: Distribuição da porosidade.	31
Figura 4-3: Distribuição da permeabilidade na direção i em mD.	32
Figura 4-4: Gráfico com as curvas de produção de água do poço Well-005. A curva de produção observada refere-se ao caso real e a produção prevista, caso simulado. 34	
Figura 5-1: Fluxograma generalizado do ajuste de histórico.	36
Figura 5-2: Representação esquemática do algoritmo de busca. A região mais clara indica os pontos onde o erro quadrático médio é menor.	37
Figura 5-3: Variação da curva de razão água-óleo prevista de um poço com o ajuste de histórico.	38

Figura 5-4: Fluxograma do treinamento da rede neural.	39
Figura 5-5: Fluxograma genérico do ajuste de histórico usando uma rede neural artificial.....	40
Figura 6-1: Representação esquemática da rede neural utilizada contendo 5 neurônios na camada de entrada, que são os 4 parâmetros que se deseja ajustar mais o tempo, e 1 neurônio na camada de saída, o valor da razão água óleo no tempo t.....	41
Figura 6-2: Fluxograma da rotina de treinamento de redes.....	44
Figura 6-3: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo gradiente descendente com um conjunto de 100 simulações.	45
Figura 6-4: Função performance com 5 neurônios na camada escondida e treinamento com o algoritmo gradiente descendente com um conjunto de 100 simulações.....	45
Figura 6-5: Função performance com 40 neurônios na camada escondida e treinamento com o algoritmo gradiente descendente com um conjunto de 100 simulações.....	46
Figura 6-6: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo de Levenberg-Marquardt com um conjunto de 100 simulações.....	47
Figura 6-7: Função performance com 5 neurônios na camada escondida e treinamento com o algoritmo de Levenberg-Marquardt com um conjunto de 100 simulações. 48	
Figura 6-8: Função performance com 40 neurônios na camada escondida e treinamento com o algoritmo de Levenberg-Marquardt com um conjunto de 100 simulações. 48	
Figura 6-9: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo Levenberg-Marquardt com um conjunto de 50 simulações.	49
Figura 6-10: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo Levenberg-Marquardt com um conjunto de 25 simulações.	50
Figura 6-11: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.	51
Figura 6-12: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.	52

Figura 6-13: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.	53
Figura 6-14: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.	53
Figura 6-15: Histograma de frequência dos coeficientes de determinação para redes neurais treinadas com diferentes tamanhos do conjunto de pares.	54
Figura 6-16: Histograma de frequência dos coeficientes de determinação para redes neurais treinadas com diferentes números de neurônios na camada escondida.	55
Figura 6-17: Comparação das curvas antes do ajuste.....	56
Figura 6-18: comparação das curvas após o ajuste.....	57

Lista de Tabelas

Tabela 4-1: Parâmetros das distribuições das propriedades do caso simulado.	32
Tabela 4-2: Valores escolhidos para a simulação inicial.....	33
Tabela 6-1: Pontos utilizados no ajuste de histórico.	55

Resumo

A simulação de reservatórios é uma importante ferramenta usada pela indústria do petróleo para o gerenciamento de reservatórios. Durante o desenvolvimento do campo, o modelo de simulação do reservatório é usado como uma ferramenta de decisão para selecionar o melhor projeto de desenvolvimento e, também, prever a produção de óleo, gás e água do campo. As incertezas são muito altas nas fases iniciais e, na maioria dos casos, o modelo inicial de simulação do reservatório deve ser revisado uma vez que os dados de produção observados no campo durante a fase de desenvolvimento não são os mesmos daqueles previstos pela simulação. Algumas destas incertezas dos parâmetros de entrada do modelo de simulação de reservatórios estão relacionadas com as heterogeneidades da rocha reservatório e a imprecisão das técnicas de exploração.

Técnicas de ajuste de histórico são usadas por engenheiros de reservatório para mitigar/minimizar as diferenças entre os dados observados no campo e os previstos pela simulação, avaliando as incertezas. Quando um modelo de reservatório torna-se muito grande em termos de número de células e detalhes, o tempo de processamento da simulação aumenta muito, o que pode fazer com que o processo de ajuste de histórico fique pesado e, em alguns casos, impossível de ser realizado em um tempo aceitável. Técnicas de processamento paralelo de alguns simuladores comerciais podem realizar múltiplas simulações ao mesmo tempo, mas não resolvem o problema de uma forma apropriada.

Este trabalho apresenta uma alternativa para acelerar o processo de ajuste de histórico: a aplicação de redes neurais artificiais do tipo *Feed-forward* como metamodelos não-lineares para a simulação de reservatório. As redes neurais podem mapear uma superfície de resposta no espaço multidimensional do modelo do reservatório (*i.e.* produção de água, pressão no fundo do poço *etc.*), ou da função objetivo, com apenas algumas simulações e, então, ser usada como um substituto às rodadas de simulação durante o processo de ajuste de histórico. O foco deste trabalho é apresentar os passos para a escolha do melhor número de camadas escondidas, de

neurônios e do método de treinamento. Um estudo de caso usando o método de trabalho proposto é apresentado para validá-lo.

Palavras-chave: Simulação de Reservatórios, Ajuste de Histórico, Redes Neurais *Feed-forward*.

Abstract

Reservoir simulation is an important tool used in the industry for reservoir management. While developing a field, a reservoir simulation model is used as a decision tool to select the best development scheme and also to forecast the oil, gas and water production for the field. Uncertainties are much higher at the early phases and when production data are gathered during the field development phase most of the time the initial reservoir simulation model needs to be reviewed once the field observed data is not as the same as the predicted by the model. Some of these uncertainties of input parameters of the model simulation of reservoirs are related to the heterogeneities of the reservoir rock and imprecision of the techniques of exploitation.

History matching techniques are used by reservoir engineers to mitigate/minimize the difference about the observed field data and the predicted and thus assessing the uncertainties. When reservoir models become too big in terms of number of cells and features, the elapsed simulation time increases very much what it makes the history matching process very cumbersome and in some cases very difficult to achieve in an acceptable time. Parallel processing features of some commercial simulators can perform lots of simulation runs at the same time but cannot address and cannot solve the problem in a proper way.

This work presents an alternative proposition to speed up the history matching process: the application of feed-forward neural networks as nonlinear proxies of reservoir simulation. Neural networks can map the response surface in multidimensional spaces of a reservoir model (i.e. water production, bottom hole pressure *etc.*) or of an objective function with few number of simulations and then used it as a substitute of reservoir simulation runs during the history matching process. The focus of this work is to shown the steps of choosing the best number of hidden layers, the neurons and the training method. An study case is presented using the workflow presented is this work and showing the validity of the proposed methodology for this nonlinear problem.

Keywords: Reservoir Simulation, History Matching, Feed-Forward Neural Networks.

1. Introdução

Após as fases iniciais da exploração de um campo de petróleo, a empresa operadora deve elaborar um plano de desenvolvimento onde informa como pretende gerenciar a produção. Para tal, é necessário que se realize estudos de viabilidade técnica e econômica das diversas alternativas de produção e selecione aquela mais viável. Isto significa comparar os custos de implementação e manutenção da alternativa em estudo com o retorno esperado por ela, ou seja, a produção esperada de óleo e gás multiplicados pelo preço de venda de cada um deduzidos os impostos e participações governamentais. Portanto, uma importante tarefa a ser realizada é prever como será a produção deste campo.

A ferramenta mais utilizada para realizar esta previsão de produção de óleo, gás e água é a simulação de reservatórios. Nela, o reservatório é representado em um modelo de simulação, desenvolvido a partir das seguintes informações: a profundidade da formação e suas características geométricas, a temperatura e pressão a qual está submetido, as propriedades de rocha e fluidos (óleo, gás e água), a presença ou não de um aquífero e de fraturas, a disposição dos poços de produção e injeção e as condições de operação de cada poço.

Porém, os dados obtidos sobre o campo com a geologia, geofísica e geoquímica geralmente são bastante imprecisos e podem não representar corretamente a realidade, resultando em incertezas nas propriedades do reservatório. Ao longo do período de exploração do campo, essas incertezas se tornam evidentes através da discrepância entre a produção observada no campo e a prevista pela simulação, podendo até inutilizar o plano de desenvolvimento. Para minimizar as diferenças entre as curvas de produção é necessário revisar o modelo numérico, reavaliando as propriedades do reservatório, que são os parâmetros de entrada, com o objetivo de descobrir quais conjuntos de propriedades são capazes de aproximar as curvas de produção prevista e observada.

O processo de utilizar dados dinâmicos de produção à caracterização de reservatórios com o objetivo de reduzir as incertezas descritas chama-se ajuste de histórico de produção e é bastante comum nas empresas operadoras. Nele, realizam-se

perturbações nas propriedades de rocha e fluido do modelo numérico, sempre dentro de um valor plausível definido pela exploração, e a saída do simulador (produção prevista) é comparada com a produção observada no campo. O processo é iterativo e seu critério de parada, ou de convergência, pode ser tanto a média quadrática do erro da produção prevista quanto o número de iterações.

O problema do uso do ajuste de histórico está no tempo de processamento computacional demandado pela simulação de reservatórios quando os modelos são muito refinados, bem heterogêneos, ou com muitos detalhes. Um exemplo na literatura cita um tempo de processamento de 10 horas em um *cluster* de 12 processadores de 3,2 GHz para um campo de petróleo com 165 poços no Oriente Médio (Mohaghegh, 2006). O ajuste de histórico pode se tornar, portanto, inviável se o número de iterações for alto, visto que cada uma necessita realizar uma simulação.

As redes neurais artificiais têm sido apresentadas como uma importante ferramenta na solução deste problema (Cullick *et al.*, 2006; Silva *et al.*, 2006). Por serem aproximadores universais de funções (Kröse e Smagt, 1996), podem, com um conjunto pequeno de simulações, mapear a superfície de resposta do simulador de reservatórios dado um modelo numérico substituindo-o no processo de ajuste de histórico.

Neste trabalho, apresenta-se uma metodologia de aplicação das redes neurais artificiais para acelerar o ajuste de histórico tornando-o viável para qualquer reservatório. Para isso, realiza-se uma breve revisão dos conceitos em reservatórios e em simulação no capítulo 2 e de redes neurais no capítulo 3. O caso estudado é apresentado no capítulo 4. A metodologia proposta é apresentada no capítulo 5 aplicada no capítulo 6.

2. Reservatórios de Petróleo

Um reservatório de petróleo é uma rocha sedimentar, geralmente arenito ou carbonato, portadora de hidrocarbonetos (óleo e gás) e água. Esta rocha é composta de grãos unidos por um material chamado cimento e espaços vazios, chamados de poros. Pode conter, ainda, partículas muito finas formando a matriz. A figura 2-1 ilustra uma seção transversal de uma rocha-reservatório com os seus principais componentes.




Figura 2-1: Desenho de uma seção transversal de uma amostra de rocha (Rosa *et al.*, 2006).

Os fluidos contidos na rocha reservatório (água, óleo e gás) ficam armazenados sob pressão nos poros da rocha. Quando um poço é aberto, devido à diferença de pressões, esses fluidos fluem da rocha-reservatório para o poço e, em seguida, para a unidade de produção na superfície onde são tratados.

Realizar um ajuste de histórico em um reservatório de petróleo significa calibrar o modelo usado na simulação variando as suas propriedades de rocha e fluido com o objetivo de aproximar as curvas de produção prevista e observada. Portanto, para obter sucesso na calibração, é necessário entender como funciona um reservatório, quais são as suas propriedades e como elas interferem no fluxo dos fluidos.

2.1. Principais Propriedades do Reservatório

2.1.1. Propriedades da Rocha

As propriedades da rocha irão variar bastante em função do histórico de deposição e compactação dos seus sedimentos (*i.e.* tamanho e seleção dos grãos, grau de cimentação, presença de finos, histórico de pressão e temperatura *etc.*). Raramente, uma rocha reservatório é homogênea ao longo de toda sua extensão, sendo necessário realizar estudos sobre a variação de suas propriedades.

2.1.1.1. Porosidade (ϕ)

A porosidade é a razão entre o volume de poros (ou volume de vazios) e o volume total da rocha-reservatório. Ela é representada pela letra grega ϕ .

$$\phi = \frac{V_P}{V_T} \quad (2.1.1)$$

onde V_P é o volume de poros e V_T é o volume total da rocha. A porosidade é expressa, geralmente, em porcentagem.

A porosidade efetiva (ϕ_{eff}) é a razão entre o volume de poros conectados e o volume total do reservatório. Essa porosidade é a mais importante para o estudo de reservatórios, pois indica quanto dos fluidos pode ser produzido.

2.1.1.2. Compressibilidade Efetiva (c_f)

A compressibilidade efetiva de uma formação expressa a variação do volume de poros em função da variação de pressão ao qual a rocha está submetida.

$$c_f = \frac{1}{V_p} \frac{\partial V_p}{\partial p} \quad (2.1.2)$$

onde p é a pressão. A compressibilidade é medida, geralmente, em $(\text{kg}/\text{cm}^2)^{-1}$.

Considerando o volume total constante e substituindo a equação (2.1.1) na (2.1.2):

$$c_f = \frac{1}{\phi} \frac{\partial \phi}{\partial p} \quad (2.1.3)$$

2.1.1.3. Saturação de Fluidos (S)

A saturação de fluidos indica como os poros estão preenchidos. A figura 2-2 apresenta um corte transversal de uma rocha-reservatório com presença de fluidos, água (fluido contínuo da figura), óleo (gotas largas) e gás (gotas pequenas), nos poros.

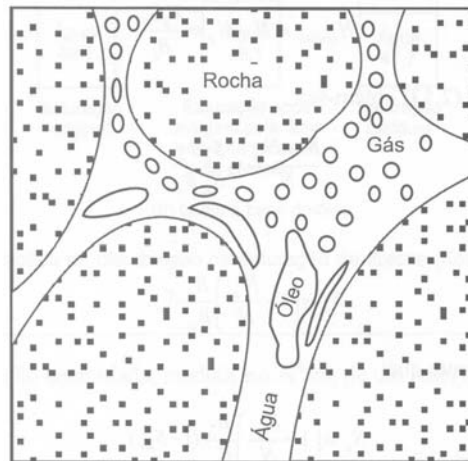


Figura 2-2: Rocha-reservatório contendo os fluidos: água, óleo e gás (gotas pequenas) (Rosa *et al.*, 2006).

$$S_i = \frac{V_i}{V_p} \quad (2.1.4)$$

onde i indica o fluido no qual está sendo calculado a saturação. A saturação é expressa, geralmente, em porcentagem.

Originalmente, toda rocha reservatório é saturada apenas de água. Durante a fase conhecida como migração secundária, os hidrocarbonetos formados pela rocha geradora se acumulam no reservatório expulsando parte da água nele contida.

Existe um limite mínimo para a saturação de cada tipo de fluido na qual, para valores menores que ele, não há deslocamento do fluido. Para a água, este limite é chamado de saturação de água irreduzível (S_{wr}). Para o óleo e o gás, é chamado de saturação residual (S_{or} e S_{gr}). Estes limites variam conforme o tipo de rocha, o volume de poros isolados, a molhabilidade da rocha e outros.

2.1.1.4. Permeabilidade (k)

Para que os fluidos possam se movimentar é necessário que os poros estejam interconectados (ver figura 1). A permeabilidade absoluta é uma medida que indica o quão fácil é a passagem deles pelo meio poroso. Quanto maior for o seu valor, maior será a vazão dos fluidos. A permeabilidade é medida na direção do fluxo que está sendo aplicado à rocha. Geralmente, é expressa em miliDarcy (mD).

Em fluxos multifásicos, a permeabilidade pode ser calculada em relação a cada fase, sendo chamada de permeabilidade efetiva (k_o , k_g e k_w). A razão entre a permeabilidade efetiva de cada fluido e a permeabilidade absoluta do reservatório é chamada de permeabilidade relativa (k_{ro} , k_{rg} e k_{rw}).

2.1.2. Propriedades dos Fluidos

As propriedades dos fluidos irão variar conforme a sua composição, pressão e temperatura ao qual estão submetidas e a composição da própria rocha, devido às interações rocha-fluido. Elas são medidas através de amostras coletadas em testes específicos (viscosidade, PVT *etc.*). O índice i dos símbolos de cada propriedade indica que esta propriedade é calculada para cada tipo de fluido presente na rocha reservatório.

2.1.2.1. Viscosidade (μ_i)

A viscosidade de um fluido é a propriedade que indica a resistência dele ao fluxo. Sua medida é em centipoise (cp).

2.1.2.2. Compressibilidade (*c*)

Como na rocha-reservatório, é importante conhecer a variação de volume de cada fluido em função da variação de pressão. A determinação é similar ao da rocha e usa a mesma unidade.

2.1.2.3. Fator Volume Formação (*B*)

O fator volume formação é a razão entre a massa específica de um fluido nas condições de superfície (1,033 kg/cm² e 20°C) e nas condições de temperatura e pressão do reservatório.

$$B = \frac{\rho_{std}}{\rho_{res}} \quad (2.1.5)$$

onde ρ_{std} é a massa específica em condições de superfície e ρ_{res} é a massa específica em condições de reservatório.

2.2. Descrevendo as Propriedades do Reservatório

Como discutido anteriormente, raramente as propriedades do reservatório são homogêneas ao longo de toda a sua extensão. Logo, deve-se utilizar uma metodologia para representar estas propriedades e as suas variações, permitindo uma correta modelagem do reservatório e previsões mais precisas da produção do campo. Além disso, a heterogeneidade da rocha reservatório deve ser corretamente caracterizada visto que interfere na forma como os fluidos são deslocados.

Jensen *et al* (2000) discutem, em seu terceiro capítulo, a importância do uso da estatística na caracterização de reservatórios de petróleo. Como as propriedades do reservatório são desconhecidas, acredita-se que cada ponto da região definida pelo reservatório esteja associado a uma série de funções de densidade de probabilidade, sendo uma variável aleatória para cada propriedade. Duas funções de densidade de probabilidade merecem destaque:

- Distribuição uniforme: é a mais simples, sendo usada quando não existe nenhuma informação sobre a variação da propriedade, mas existem razões fortes para de que estes valores não ultrapassem os limites da distribuição.
- Distribuição triangular: bastante utilizada na engenharia de reservatórios quando não há certeza sobre a verdadeira distribuição da propriedade. Ela é capaz de carregar a experiência dos profissionais de exploração (geólogos, geofísicos,...) ao estudo de reservatórios, limitando o domínio a um intervalo no qual se possui uma segurança sobre a pertinência do valor da propriedade, além de permitir colocar um peso maior nos valores em torno daquele com maior grau de confiança (Jensen *et al.*, 2000).

Quando se realiza uma medição em uma determinada região usando uma análise de testemunho, de perfis, ou avaliação de formações *etc.*, a propriedade deixa de ser representada por uma variável aleatória. No lugar, o valor específico medido é considerado, sendo este a média da variável aleatória cuja função de distribuição é definida dentro volume onde houve a medição. Ou seja, ele não pode ser considerado a média da variável aleatória para outros pontos do reservatório, embora possa ser usada para estimá-las. A figura 2-3 ilustra a questão da representação das propriedades do reservatório em pontos onde houve a medição e em pontos onde não houve.

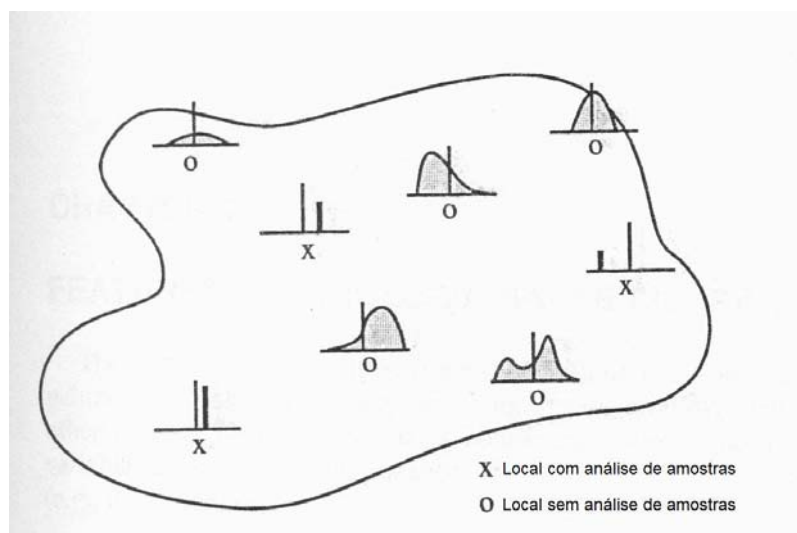


Figura 2-3: Distribuições de uma propriedade de reservatório (Jensen *et al.*, 2000, adaptado).

Existem duas formas, portanto, para modelar um reservatório de petróleo: definindo as funções de densidade de probabilidade ou interpolando os valores medidos para estimar as médias das variáveis aleatórias das propriedades em cada ponto. A interpolação dos valores medidos permite o desenho de mapas cujas linhas representam regiões com propriedades de mesmo valor. A figura mostra um mapa de porosidade para um campo.

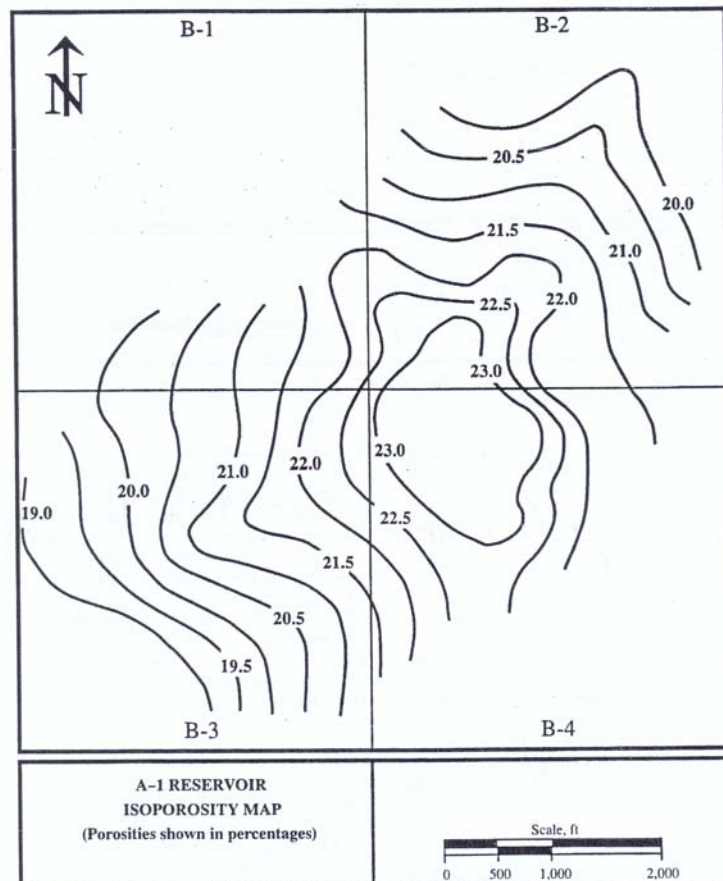


Figura 2-4: Exemplo de mapa de porosidade (Ertekin *et al.*, 2001).

No desenvolvimento do modelo de reservatório estudado no capítulo 3, serão utilizados mapas das propriedades gerados através da análise de amostras de testemunhos e de perfilagem. Já no ajuste de histórico no capítulo 5, as funções de distribuição de probabilidade definirão a forma como as propriedades variam.

2.3. Simulação de Reservatórios

Nos itens anteriores, foram apresentadas as propriedades do reservatório e como elas são descritas. Neste, será apresentada a formulação matemática que embasa o modelo numérico utilizado na simulação de reservatórios com a finalidade de mostrar a mecânica que envolve o escoamento. Dentre os modelos aplicados na indústria, o *Black Oil* é adotado neste trabalho devido a sua simplicidade no tratamento do problema. Neste modelo, é considerado um escoamento trifásico (água, óleo e gás) onde:

1. A água e o óleo são imiscíveis;
2. O gás pode existir na forma livre ou dissolvida no óleo. A solubilidade do gás na água é desprezada;
3. A temperatura do reservatório é assumida constante ao longo do tempo e
4. Os fluidos estão em equilíbrio termodinâmico dentro do reservatório (Ertekin *et al.*, 2001).

2.3.1. Formulação Matemática

Para o desenvolvimento de um simulador numérico, o primeiro passo é o estudo da física do problema e desenvolvimento das equações que a governam. Será formulado o modelo analítico para um escoamento monofásico unidimensional. O escoamento trifásico tridimensional pode ser obtido através da expansão do primeiro. São usadas as coordenadas cartesianas, porém pode-se modelar com qualquer outro plano de coordenadas (ex.: cilíndrica, esférica *etc*).

2.3.1.1. Equação de Fluxo para o Escoamento Monofásico

Considere o volume de controle retangular da figura 2-5. Este volume é um pedaço do reservatório e a variação de massa nele pode ser escrita como:

$$(m_i - m_o)_b + (m_s)_b = m_{a_b} \quad (2.3.1)$$

onde: m_i é a massa que entra no volume de controle vindo de uma parte adjacente do reservatório, m_o é a massa que sai do volume de controle, m_s é a massa que entra ou sai do volume de controle de forma externa através poços e m_a é a massa acumulada.

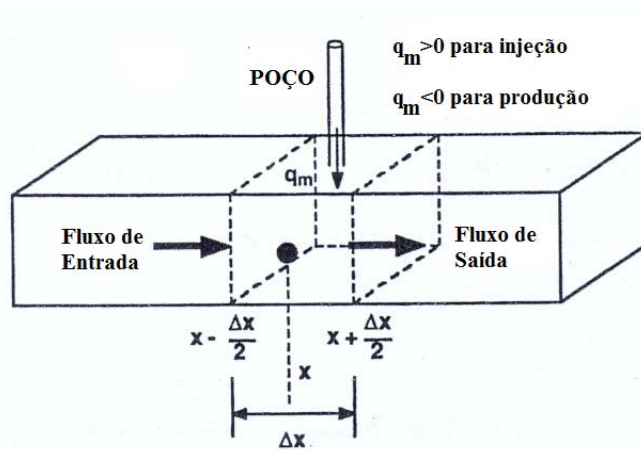


Figura 2-5: Volume de Controle para o escoamento unidimensional (Ertekin *et al.*, 2001).

A variação de massa ($m_i - m_o$) pode ser definida em função da densidade (ρ), da vazão volumétrica (q) e da variação de tempo (Δt). A massa da fonte externa pode ser expressa em função da vazão mássica do poço (q_m) e da variação de tempo (Δt) e a massa acumulada, em função da porosidade da rocha (ϕ), de densidade do fluido (ρ) e do volume de controle (V_b). Todas estas variáveis são medidas nas condições do reservatório.

$$m_i - m_o = [(\rho q)_{x-\Delta x/2} - (\rho q)_{x+\Delta x/2}] \Delta t \quad (2.3.2)$$

$$m_s = q_m \Delta t \quad (2.3.3)$$

$$m_a = V_b [(\rho \phi)_{t+\Delta t} - (\rho \phi)_t] \quad (2.3.4)$$

$$V_b = A_x \Delta x \quad (2.3.5)$$

$$q = A_x u_x \quad (2.3.6)$$

Aplicando as equações (2.3.2), (2.3.3), (2.3.4), (2.3.5), (2.3.6) na equação (2.3.1) e reordenando os termos:

$$-\frac{[(\rho u)_{x+\Delta x/2} - (\rho u)_{x-\Delta x/2}]}{\Delta x} = \frac{[(\rho \phi)_{t+\Delta t} - (\rho \phi)_t]}{\Delta t} - \frac{q_m}{V_b} \quad (2.3.7)$$

Aplicando o limite quando Δt e Δx tendem a zero, temos a definição de derivada parcial no tempo e no espaço e a equação (2.3.7) pode ser reescrita como:

$$-\frac{\partial}{\partial x}(\rho u_x) = \frac{\partial}{\partial t}(\rho \phi) - \frac{q_m}{V_b} \quad (2.3.8)$$

A equação (2.3.8) é conhecida como equação da conservação de massa. Uma vantagem de trabalhar com o volume de controle infinitesimal é poder considerar as propriedades, dentro deste volume, constantes. Aplicando a Lei de Darcy, equação (2.3.9), com as considerações supracitadas na equação da conservação de massa:

$$u_x = -\frac{k_x}{\mu} \frac{\partial \Phi}{\partial x} = -\frac{k_x}{\mu} \left(\frac{\partial p}{\partial x} + \gamma \frac{\partial Z}{\partial x} \right) \quad (2.3.9)$$

onde Φ é conhecido como potencial de fluido, p é a pressão no volume de controle, Z é a altura em que o fluido está em relação ao datum e γ é o peso específico do fluido.

$$-\frac{\partial}{\partial x} \left(\rho \left(-\frac{k_x}{\mu} \frac{\partial \Phi}{\partial x} \right) \right) = \frac{\partial}{\partial t}(\rho \phi) - \frac{q_m}{V_b} \quad (2.3.10)$$

$$\frac{\partial}{\partial x} \left(\frac{\rho k_x}{\mu} \frac{\partial \Phi}{\partial x} \right) = \frac{\partial}{\partial t}(\rho \phi) - \frac{q_m}{V_b} \quad (2.3.11)$$

A densidade dos fluidos e a vazão dos poços podem ser aplicadas nas condições padrão (ou de superfície) ao invés de usar as condições do reservatório. Para isso, considera-se o fator volume formação (B) e a conversão da vazão mássica do poço (q_m) para vazão volumétrica:

$$B = \frac{\rho_{std}}{\rho} \quad (2.3.12)$$

$$q_m = q_{std} \rho_{std} \quad (2.3.13)$$

onde q_{std} é a vazão volumétrica medida nas condições padrão (ou de superfície).

Substituindo (2.3.12) e (2.3.13) em (2.3.11) e dividindo por ρ_{std} :

$$\frac{\partial}{\partial x} \left(\frac{k_x}{B \mu} \frac{\partial \Phi}{\partial x} \right) = \frac{\partial}{\partial t} \left(\frac{\phi}{B} \right) - \frac{q_{std}}{V_b} \quad (2.3.14)$$

Multiplicando V_b e substituindo a equação (2.3.15) na (2.3.14):

$$V_b = A_x \Delta x \quad (2.3.15)$$

$$\frac{\partial}{\partial x} \left(\frac{A_x k_x}{B \mu} \frac{\partial \Phi}{\partial x} \right) \Delta x + q_{std} = V_b \frac{\partial}{\partial t} \left(\frac{\phi}{B} \right) \quad (2.3.16)$$

A equação (2.3.16) é a forma genérica da equação de fluxo monofásico unidimensional e pode ser utilizada para qualquer tipo de fluido (compressível ou incompressível) além de não levar em consideração a dependência da pressão em relação às propriedades da rocha e dos fluidos (Ertekin *et al.*, 2001).

Na formulação da equação de fluxo tridimensional monofásico, deve-se considerar o fluxo mássico nas três direções do volume de controle. Assim a equação (2.3.2) passa a ser:

$$m_i - m_o = \sum_{i=x,y,z} [(\rho q)_{i-\Delta i/2} - (\rho q)_{i+\Delta i/2}] \Delta t \quad (2.3.17)$$

Resolvendo a equação (2.3.1) de modo análogo e considerando a equação (2.3.17), ao invés da equação (2.3.2), obtém-se a equação (2.3.18) para o escoamento monofásico tridimensional. Observa-se que esta equação é uma função do espaço no lado esquerdo e uma função do tempo no lado direito.

$$\frac{\partial}{\partial x} \left(\frac{A_x k_x}{B \mu} \frac{\partial \Phi}{\partial x} \right) \Delta x + \frac{\partial}{\partial y} \left(\frac{A_y k_y}{B \mu} \frac{\partial \Phi}{\partial y} \right) \Delta y + \frac{\partial}{\partial z} \left(\frac{A_z k_z}{B \mu} \frac{\partial \Phi}{\partial z} \right) \Delta z + q_{std} = V_b \frac{\partial}{\partial t} \left(\frac{\phi}{B} \right) \quad (2.3.18)$$

2.3.1.2. Equação de Fluxo para o Escoamento Multifásico

Como a formulação da equação de fluxo é baseada na conservação de massa e o modelo *Black Oil* considera as fases imiscíveis (com exceção do gás que se encontra em duas formas: uma livre e a outra solubilizada no óleo), analisar-se-á o comportamento delas separadamente. A equação de Darcy pode ser adaptada para o escoamento multifásico através das permeabilidades relativas de cada fase.

$$u_{i,l} = -\frac{k_i k_{rl}}{\mu} \frac{\partial \Phi}{\partial i} = -\frac{k_i k_{rl}}{\mu} \left(\frac{\partial p}{\partial i} + \gamma_l \frac{\partial Z}{\partial i} \right) \quad (2.3.19)$$

onde i é a direção do fluxo (x, y ou z) e l é a fase do fluxo (água, óleo ou gás livre).

O volume ocupado por cada fase pode é definido pela saturação do fluido. Assim, a equação da massa acumulada (2.3.4) é reescrita como:

$$m_{a,l} = V_b [(\rho_l \phi S_l)_{t+\Delta t} - (\rho_l \phi S_l)_t] \quad (2.3.20)$$

onde l é a fase do fluxo (água, óleo ou gás livre).

Utilizando as equações (2.3.19) e (2.3.20) na equação de conservação de massa e considerando a vazão volumétrica de cada fase no poço ($q_{o,std}$ para o óleo, $q_{w,std}$ para a água e $q_{gl,std}$ para o gás livre), obtêm-se as seguintes equações de fluxo:

$$\begin{aligned} \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{ro}}{B_o \mu_o} \frac{\partial \Phi}{\partial x} \right) \Delta x + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{ro}}{B_o \mu_o} \frac{\partial \Phi}{\partial y} \right) \Delta y + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{ro}}{B_o \mu_o} \frac{\partial \Phi}{\partial z} \right) \Delta z \\ + q_{o,std} = V_b \frac{\partial}{\partial t} \left(\frac{\phi S_o}{B_o} \right) \end{aligned} \quad (2.3.21)$$

$$\begin{aligned} \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{rw}}{B_w \mu_w} \frac{\partial \Phi}{\partial x} \right) \Delta x + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{rw}}{B_w \mu_w} \frac{\partial \Phi}{\partial y} \right) \Delta y + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{rw}}{B_w \mu_w} \frac{\partial \Phi}{\partial z} \right) \Delta z \\ + q_{w,std} = V_b \frac{\partial}{\partial t} \left(\frac{\phi S_w}{B_w} \right) \end{aligned} \quad (2.3.22)$$

$$\begin{aligned} & \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{rg}}{B_g \mu_g} \frac{\partial \Phi}{\partial x} \right) \Delta x + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{rg}}{B_g \mu_g} \frac{\partial \Phi}{\partial y} \right) \Delta y + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{rg}}{B_g \mu_g} \frac{\partial \Phi}{\partial z} \right) \Delta z \\ & + q_{gl,std} = \frac{\partial}{\partial t} \left(\frac{\phi S_g}{B_g} \right) \end{aligned} \quad (2.3.23)$$

No tratamento do gás solubilizado no óleo, a equação de fluxo pode ser deduzida a partir da equação de fluxo do óleo considerando que a razão de solubilidade, R_s , é constante dentro do volume de controle.

$$\begin{aligned} & \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{ro} R_s}{B_o \mu_o} \frac{\partial \Phi}{\partial x} \right) \Delta x + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{ro} R_s}{B_o \mu_o} \frac{\partial \Phi}{\partial y} \right) \Delta y + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{ro} R_s}{B_o \mu_o} \frac{\partial \Phi}{\partial z} \right) \Delta z \\ & + q_{gs,std} = \frac{\partial}{\partial t} \left(\frac{\phi R_s S_o}{B_o} \right) \end{aligned} \quad (2.3.24)$$

onde $q_{gs,std}$ é a vazão volumétrica de gás solubilizado produzido.

Somando as equações (2.3.23) e (2.3.24) e substituindo a equação (2.3.25), encontra-se a equação de fluxo do gás.

$$q_{gs,std} + q_{gl,std} = q_{g,std} \quad (2.3.25)$$

onde $q_{g,std}$ é a vazão volumétrica total do gás produzido nas condições da superfície.

$$\begin{aligned} & \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{rg}}{B_g \mu_g} \frac{\partial \Phi}{\partial x} + A_x k_x \frac{k_{ro} R_s}{B_o \mu_o} \frac{\partial \Phi}{\partial x} \right) \Delta x \\ & + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{rg}}{B_g \mu_g} \frac{\partial \Phi}{\partial y} + A_y k_y \frac{k_{ro} R_s}{B_o \mu_o} \frac{\partial \Phi}{\partial y} \right) \Delta y \\ & + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{rg}}{B_g \mu_g} \frac{\partial \Phi}{\partial z} + A_z k_z \frac{k_{ro} R_s}{B_o \mu_o} \frac{\partial \Phi}{\partial z} \right) \Delta z \\ & + q_{g,std} = \frac{\partial}{\partial t} \left(\frac{\phi S_g}{B_g} + \frac{\phi R_s S_o}{B_o} \right) \end{aligned} \quad (2.3.26)$$

Substituindo a equação (2.3.9) nas equações (2.3.21), (2.3.22) e (2.3.26), retiramos o potencial de fluxo das equações:

$$\begin{aligned} & \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{ro}}{B_o \mu_o} \left(\frac{\partial p_o}{\partial x} - \gamma_o \frac{\partial Z}{\partial x} \right) \right) \Delta x + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{ro}}{B_o \mu_o} \left(\frac{\partial p_o}{\partial y} - \gamma_o \frac{\partial Z}{\partial y} \right) \right) \Delta y \\ & + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{ro}}{B_o \mu_o} \left(\frac{\partial p_o}{\partial z} - \gamma_o \frac{\partial Z}{\partial z} \right) \right) \Delta z + q_{o,std} = V_b \frac{\partial}{\partial t} \left(\frac{\phi S_o}{B_o} \right) \end{aligned} \quad (2.3.27)$$

$$\begin{aligned} & \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{rw}}{B_w \mu_w} \left(\frac{\partial p_w}{\partial x} - \gamma_w \frac{\partial Z}{\partial x} \right) \right) \Delta x + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{rw}}{B_w \mu_w} \left(\frac{\partial p_w}{\partial y} - \gamma_w \frac{\partial Z}{\partial y} \right) \right) \Delta y \\ & + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{rw}}{B_w \mu_w} \left(\frac{\partial p_w}{\partial z} - \gamma_w \frac{\partial Z}{\partial z} \right) \right) \Delta z + q_{w,std} = V_b \frac{\partial}{\partial t} \left(\frac{\phi S_w}{B_w} \right) \end{aligned} \quad (2.3.28)$$

$$\begin{aligned} & \frac{\partial}{\partial x} \left(A_x k_x \frac{k_{rg}}{B_g \mu_g} \left(\frac{\partial p_g}{\partial x} - \gamma_g \frac{\partial Z}{\partial x} \right) + A_x k_x \frac{k_{ro} R_s}{B_o \mu_o} \left(\frac{\partial p_o}{\partial x} - \gamma_o \frac{\partial Z}{\partial x} \right) \right) \Delta x \\ & + \frac{\partial}{\partial y} \left(A_y k_y \frac{k_{rg}}{B_g \mu_g} \left(\frac{\partial p_g}{\partial y} - \gamma_g \frac{\partial Z}{\partial y} \right) + A_y k_y \frac{k_{ro} R_s}{B_o \mu_o} \left(\frac{\partial p_o}{\partial y} - \gamma_o \frac{\partial Z}{\partial y} \right) \right) \Delta y \\ & + \frac{\partial}{\partial z} \left(A_z k_z \frac{k_{rg}}{B_g \mu_g} \left(\frac{\partial p_g}{\partial z} - \gamma_g \frac{\partial Z}{\partial z} \right) + A_z k_z \frac{k_{ro} R_s}{B_o \mu_o} \left(\frac{\partial p_o}{\partial z} - \gamma_o \frac{\partial Z}{\partial z} \right) \right) \Delta z \\ & + q_{g,std} = \frac{\partial}{\partial t} \left(\frac{\phi S_g}{B_g} + \frac{\phi R_s S_o}{B_o} \right) \end{aligned} \quad (2.3.29)$$

Essas são as equações de fluxo para todos os fluidos que compõe o reservatório. Elas foram obtidas através da combinação das equações de conservação de massa, de estado e da lei de Darcy, porém não são suficientes para completar a descrição do fluido em um meio poroso. Para isso são necessárias relações adicionais de restrição de saturação de cada fase pressões capilares como funções da saturação de fases (Ertekin *et al.*, 2001). As equações que representam estas restrições estão escritas abaixo:

$$S_o + S_g + S_w = 1 \quad (2.3.30)$$

$$p_{cow} = p_o - p_w = f(S_w) \quad (2.3.31)$$

$$p_{cgo} = p_g - p_o = f(S_g) \quad (2.3.32)$$

As seis equações apresentadas acima junto com as condições de contorno do reservatório descrevem a formulação *Black Oil*. Observe que o número de incógnitas (p_o , p_w , p_g , S_o , S_w e S_g) coincide com o de equações, garantindo a unicidade da solução, quando houver. Todas as outras variáveis são medidas ou estimadas, ou seja, são parâmetros de entrada na simulação de reservatórios e compõe o domínio do espaço de busca no ajuste de histórico.

Para transformar o modelo matemática em um modelo de simulador, eliminam-se as derivadas parciais através da aplicação da técnica de Diferenças Finitas. A técnica discretiza o reservatório em uma malha de blocos com propriedades constantes, conforme mostrado na figura 2-6, e define a função de transmissibilidade. Porém isto está além da proposta deste trabalho e não será deduzido.

A figura 2-7 exemplifica o fluxograma da simulação. O modelo de simulação do reservatório está representado pelos símbolos das propriedades à esquerda, o simulador está no centro e o gráfico a direita representa a produção genérica de óleo (amarelo) e água (azul) de um campo de petróleo.




Figura 2-6: Representação da discretização de uma rocha-reservatório em blocos (Ertekin *et al.*, 2001).

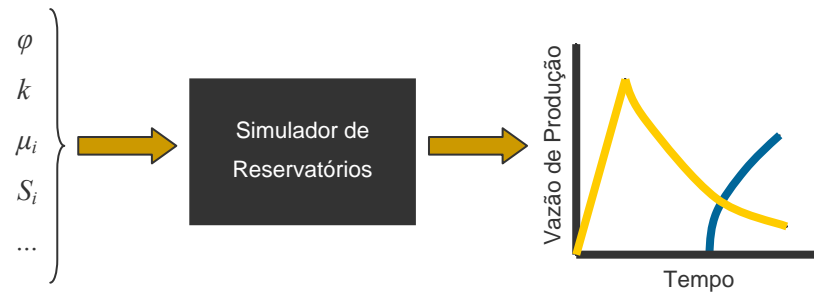


Figura 2-7: Fluxograma de uma simulação de reservatórios.

3. Redes Neurais Artificiais

Redes neurais artificiais fazem parte de um conjunto de ferramentas analíticas criadas com o objetivo de imitar a vida (Mohagheh, 2000). Neste caso, são algoritmos inspirados na mecânica do cérebro animal e que, embora sejam bastante simples, possuem a capacidade de executar uma série de tarefas como aproximar funções, controle, reconhecimento de padrões, filtragem não linear e outros.

O mecanismo de funcionamento dos neurônios reais e a forma como inspiraram a criação das redes neurais artificiais é amplamente discutido em livros e artigos, sendo recomendada a leitura de Mohagheh (2000) e Barreto (2002) para maiores informações sobre este assunto. O foco deste capítulo, porém, é a apresentação do funcionamento de uma rede neural artificial.

A figura 3-1 apresenta o desenho esquemático de um neurônio artificial. Este neurônio tem como entrada o vetor $[x_1, x_2, \dots, x_n]$ e, como saída, a variável \hat{Y} . O vetor de entrada é multiplicado pelo vetor de pesos $[w_1, w_2, \dots, w_n]$ e somado ao peso independente b segundo a equação (3.1.1), resultando na variável u . A esta variável é aplicada a função de ativação $f(u)$, gerando a variável de saída \hat{Y} .




Figura 3-1: Esquema de um neurônio.

$$u = \sum_{i=1}^n x_i \cdot w_i + b \quad (3.1.1)$$

Existem três tipos de funções de ativação que merecem destaque em redes neurais artificiais: a logarítmica sigmóide (logsig), cujo valor de saída está

compreendido no intervalo $[0; 1]$ e seu gráfico é apresentado na figura 3-2, tangente sigmóide (tansig), cujo valor de saída está compreendido entre $[-1; 1]$ e seu gráfico é apresentado na figura 3-3, e puramente linear (purelin), em que o valor de saída é igual ao de entrada, figura 3-4.




Figura 3-2: Gráfico da função logsig (Demuth *et al.*, 2008).




Figura 3-3: Gráfico da função tansig (Demuth *et al.*, 2008).




Figura 3-4: Gráfico da função purelin (Demuth *et al.*, 2008).

Os neurônios podem ser associados formando diversas estruturas. É a associação dos neurônios que permite que sejam capazes de realizar uma série de tarefas. Para a

aplicação proposta, redes do tipo Feed-forward são utilizadas. Este tipo de arquitetura de redes neurais é apresentado no item seguinte.

3.1. Redes *Feed-Forward*

Redes *Feed-forward*, ou de alimentação direta, são redes em que os neurônios estão estruturados em camadas. A informação chega à entrada de um neurônio proveniente da camada anterior e a saída deste neurônio é enviada para os neurônios da camada posterior. Não há troca de informações entre neurônios da mesma camada e não há realimentação na rede. A figura 3-5 apresenta o desenho esquemático de uma rede *Feed-forward*, sendo o número de neurônios contidos apenas ilustrativo. Podem-se observar três grupos de camadas:

- Camada de entrada: é a camada com neurônios na cor azul, marcados pela letra “E”. Nela, cada neurônio só pode receber um valor do vetor de entrada e não possui função de ativação, ou seja, o valor do vetor de entrada passa direto para camada seguinte onde será multiplicado pelos pesos. O número de neurônios desta camada é igual à dimensão do vetor de entrada, havendo um neurônio para cada variável de entrada.
- Camada escondida (ou intermediária ou oculta): é a camada com neurônios na cor verde, marcados pela letra “O”. Nela, os neurônios recebem as saídas da camada anterior multiplicados pelos seus pesos e somados ao peso independente. A função de ativação e o número de neurônios desta camada são definidos pelo programador conforme a necessidade. Pode haver mais do que uma camada deste tipo na rede.
- Camada de saída: é a camada com neurônios na cor vermelha da figura, marcados pela letra “S”. Nesta camada, os neurônios recebem as saídas da última camada escondida e sua função de ativação é, geralmente, purelin. O número de neurônios desta camada é igual à dimensão do vetor de saída, havendo um neurônio para cada variável de saída.




Figura 3-5: Desenho esquemático de uma rede neural do tipo *Feed-forward*.

Observe que, a exceção dos neurônios da camada de entrada, todos eles obedecem à mesma estrutura neural apresentada pela figura 3-1. Cada grafo possui um peso associado que multiplica a variável que passa por ele, sendo que o grafo com valor 1 na ponta está associado ao peso independente. Os grafos de entrada e saída da rede não possuem pesos associados.

Neste item, as redes neurais do tipo *Feed-forward* foram definidas. Porém, ainda devem ser decididas quantas camadas escondidas devem ser usadas e quantos neurônios deve haver em cada camada escondida. As respostas virão através do estudo sobre treinamento da rede, expondo a influência dessas decisões.

3.2. Algoritmos de Treinamento *Back-propagation*

Uma rede neural só funcionará corretamente se os pesos dela estiverem bem selecionados. O processo de busca pelos melhores pesos chama-se treinamento, ou aprendizado, da rede neural. Dentre os métodos existentes, o *Back-propagation*, ou propagação para trás, é um dos mais populares. Este é o método aplicado neste trabalho.

Seleciona-se um conjunto de pontos da superfície de resposta da função a aproximar. Cada ponto desta superfície é chamado de par para treinamento, pois contém as variáveis de entrada da função (*input*), que serão utilizadas na entrada da rede, e as variáveis de saída da função (*output*), que serão comparadas com a saída da rede. A comparação é feita através de uma função performance definida, neste trabalho, como o erro quadrático médio segundo equação (3.2.1). Os pesos da rede neural são atualizados da camada de saída para a camada de entrada, minimizando a função performance. Por isso que o método é chamado de propagação para trás.

$$E = \sum_{p=1}^m E^p = \frac{1}{m} \sum_{p=1}^m \left(Y^p - \hat{Y}^p \right)^2 \quad (3.2.1)$$

onde E é a função erro da rede neural, \hat{Y} é o valor da rede neural, Y é o valor do par para treinamento e m é o número de pares para treinamento.

Diversos algoritmos foram criados para realizar esta busca, inspirados na regra de delta para *perceprons* (uma rede neural com apenas uma camada). A análise deste algoritmo é interessante, pois permite a compreensão da lógica da técnica de aprendizado sem entrar em cálculos avançados.

3.2.1. Regra de Delta

A regra de delta é apresentada por Kröse e Smagt (1996). Considere a rede neural com apenas um neurônio e pesos selecionados aleatoriamente. O valor da saída \hat{Y} pode ser descrito pela equação (3.2.2):

$$\hat{Y} = \sum_{i=1}^n w_i x_i + b \quad (3.2.2)$$

O treinamento da rede é feito calculando a variação do valor de cada pesos. A atualização deles é dada por:

$$w_i^{t+1} = w_i^t + \Delta_p w_i \quad (3.2.3)$$

onde t é a iteração atual.

A mecânica do processo está em definir $\Delta_p w_i$ como proporcional ao inverso da derivada parcial do erro em relação ao peso. Assim, os pesos irão em direção ao mínimo local/global da função performance mais próximo.

$$\Delta_p w_i = -\gamma \frac{\partial E^p}{\partial w_i} \quad (3.2.4)$$

onde γ é uma constante de proporcionalidade. A derivada pode ser reescrita como:

$$\frac{\partial E^p}{\partial w_i} = \frac{\partial E^p}{\partial \bar{Y}^p} \frac{\partial \bar{Y}^p}{\partial w_i} \quad (3.2.5)$$

Da equação (3.2.2), sabemos que:

$$\frac{\partial \bar{Y}^p}{\partial w_i} = x_i \quad (3.2.6)$$

Como:

$$\frac{\partial E^p}{\partial \bar{Y}^p} = -(Y^p - \bar{Y}^p) \quad (3.2.7)$$

O valor da atualização de cada peso será:

$$\Delta_p w_i = \gamma (Y^p - \bar{Y}^p) x_i \quad (3.2.8)$$

que é dependente apenas de uma constante e dos pares para treinamento.

3.2.2. Treinando Redes *Feed-forward*

As equações (3.2.3) e (3.2.4) são o princípio da dedução de qualquer algoritmo de treinamento para Redes *Feed-forward*. A diferença está no cálculo das derivadas parciais dos pesos, que passam a ser atualizados por camadas, e no aumento do número

destes. Dois algoritmos, utilizados no trabalho, são apresentados: o gradiente descendente e o Levenberg-Marquardt.

3.2.2.1. Gradiente Descendente

O algoritmo de gradiente descendente é a evolução da regra de delta para redes *Feed-forward*. O cálculo da atualização de cada peso é feito com o mesmo princípio, proporcional ao inverso da derivada parcial do erro em relação ao peso. O valor da constante de proporcionalidade é uma variável a ser otimizada, pois, se este valor for baixo, a rede neural pode demorar a convergir. Porém, sendo alto, a rede neural pode se tornar instável.

3.2.2.2. Levenberg-Marquardt

Segundo Demuth *et al.* (2008), a convergência do algoritmo de gradiente descendente pode ser muito lenta, pois a faixa de valores que garantiriam a estabilidade é baixa. Existe um grupo de algoritmos que utiliza técnicas de otimização numérica para convergir rapidamente. O algoritmo base deste grupo é o de Newton, no qual a constante de proporcionalidade é substituída pela matriz Hessiana, formada pelas derivadas segunda da função performance em relação aos pesos. A equação (3.2.3) passa a ser:

$$w_{ik}^{t+1} = w_{ik}^t - H_t^{-1} \frac{\partial E^p}{\partial w_{ik}^t} \quad (3.2.9)$$

onde H_t é a matriz Hessiana para a iteração t e k é a camada onde está o neurônio i .

Ainda segundo Demuth *et al.* (2008), como o cálculo da matriz Hessiana é muito complicado, os demais algoritmos utilizam uma aproximação para ela. O algoritmo de Levenberg-Marquardt calcula a matriz Hessiana através da matriz Jacobiana, formada pelas derivadas primeira da função performance em relação aos pesos.

$$H = J^T J \quad (3.2.10)$$

As derivadas parciais podem ser reescritas como:

$$\frac{\partial E^p}{\partial w_{ik}^t} = J^T e \quad (3.2.11)$$

onde e é o vetor de erros.

A formulação completa da atualização dos pesos da rede neural para o algoritmo de Levenberg-Marquardt é:

$$w_{ik}^{t+1} = w_{ik}^t - [J^T J + \mu I]^{-1} J^T e \quad (3.2.12)$$

Observações:

- Se μ é zero, o processo se torna um método de Newton puro com uma aproximação para a matriz Hessiana;
- Se μ é grande, o processo se torna igual ao do gradiente descendente com um passo pequeno.

Portanto, o μ é reduzido a cada iteração bem sucedida e incrementado a quando uma iteração aumenta a função performance. Isso garante que esta função seja sempre ser reduzida.

3.3. Considerações

Ao longo dos anos, a experiência acumulada no treinamento de redes neurais artificiais permitiu que certas tendências pudessem ser observadas e guiassem as decisões a serem tomadas na aplicação desta ferramenta.

Kröse e Smagt (1996) apresentam o teorema universal da aproximação, no qual redes do tipo *Feed-forward* com treinamento *Back-propagation* e apenas uma única camada escondida são suficientes para aproximar qualquer função com um número finito de discontinuidades e uma precisão arbitrária, dado que as funções de ativação dos neurônios da escondida são não-lineares. Foi selecionado, então, que a rede neural

irá ter uma camada escondida, com função de ativação tansig, e função de ativação purelin para a camada de saída.

Quanto ao número ótimo de neurônios para a camada escondida: se este número for baixo, a rede não será capaz de aproximar a função desejada e, se for alto, a rede neural poderá “decorar” os pares usados no treinamento ao invés de aprendê-los. O problema da memorização dos pares se chama *overtraining*. A figura 3-6 apresenta um exemplo de treinamento de rede neural onde ocorre o *overtraining* quando o número de neurônios na camada escondida aumenta de 5 para 20 apresentado por Kröse e Smagt (1996).




Figura 3-6: Exemplo de *overtraining* com o aumento do número de neurônios na camada escondida. Treinamento com 12 pares: (a) 5 neurônios e (b) 20 neurônios. Os círculos representam os pares, a linha pontilhada, a função e a linha contínua, a rede neural. (Adaptado de Kröse e Smagt, 1996)

Outro aspecto importante a ser considerado no treinamento da rede é o número de pares para treinamento a serem usados. A comparação entre um número pequeno de pares para treinamento e um número ótimo está representado na figura 3-7. Observe que a rede neural não consegue representar a função se o número de pares for baixo. Em contrapartida, um número alto de pares pode prejudicar a capacidade de convergência do algoritmo mantendo o erro alto.




Figura 3-7: Exemplo da influência do número de pares no treinamento da rede neural. Os círculos representam os pares, a linha pontilhada, a função e a linha contínua, a rede neural. Em (a) foram usados 4 pares para treinamento e em (b) 20. (Adaptado de Kröse e Smagt, 1996)

Demuth *et al.* (2008) recomenda que os valores de cada par sejam normalizados no intervalo $[-1; 1]$ para garantir a eficiência do treinamento da rede neural.

O critério de parada mais comum do treinamento de redes neurais é o valor da função performance. A parada pode ocorrer quando ele atinge o valor desejado ou não sofre mais variações significativas. Porém, a atualização contínua dos pesos não significa necessariamente que a rede neural está aprendendo a função. Ela pode estar apenas memorizando os pares de treinamento, como ocorre quando o número de neurônios é alto. Assim, devem ser definidos critérios de parada prematura, evitando que o *overtraining* ocorra.

O número de iterações pode ser um critério de parada prematura, mas a decisão correta do seu valor depende da experiência do programador da rede neural. Outra forma de evitar este problema é separar alguns pares, criando um conjunto chamado validação. A função performance será avaliada para este conjunto e o treinamento irá parar quando este valor for incrementado. A figura 3-8 apresenta o gráfico da evolução dos erros do conjunto de pares para treinamento e para validação ao longo das iterações.

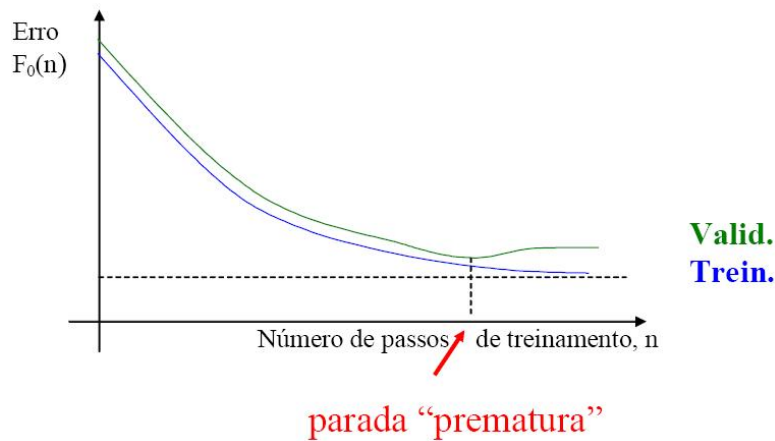


Figura 3-8: Exemplo de parada prematura (Calôba, 2005).

Um terceiro grupo de pares costuma ser separado também formando o conjunto para teste. A sua função é, ao final do treinamento, avaliar a capacidade de generalização da rede. Ou seja, avaliar o quão bem a rede neural consegue descrever os outros pontos da função. Para isso, este conjunto de dados não é utilizado em nenhum momento durante o treinamento. Demuth *et al.* (2008) recomenda que a divisão entre os três conjuntos seja: 60% dos pares para treinamento, 20% dos pares para validação e 20% dos pares para teste.

Infelizmente não existe uma fórmula ou um teorema definindo o número ótimo de neurônios na camada escondida, nem o número de pares para treinamento necessários para uma convergência. Esses valores serão determinados durante o treinamento da rede neural no capítulo 6.

4. Reservatório Estudado

Um campo hipotético foi desenvolvido para a aplicação do roteiro e análise de resultados utilizando a suíte de programas da Computer Modeling Group LTD., na versão 2008.10. O modelo é inspirado no campo exemplo apresentado ao longo do final de cada capítulo do livro “*Basic Applied Reservoir Simulation*” de Ertekin *et al* (2001).

Um modelo de reservatório heterogêneo foi criado com o objetivo de fornecer a curva de produção observada para o ajuste de histórico e será chamado de caso real. A figura 4-1, retirada do livro, apresenta o mapa estrutural do campo em unidades inglesas. Um sistema cartesiano (i, j, k) foi usado para gerar a malha de blocos. O eixo i está alinhado com o sentido da deposição dos sedimentos, direção sudoeste-nordeste no mapa. As figuras 4-2 e 4-3 apresentam o modelo tridimensional do reservatório com as distribuições de permeabilidade em i e de porosidade. O eixo Y destas figuras, vetor verde, indica a direção norte do mapa.

O reservatório está, inicialmente, completamente saturado de óleo e possui 5 poços, sendo 3 produtores (Well-001, Well-003, Well-005) e 2 injetores de água (Well-002-I, Well-004-I). O histórico de produção compreende os meses entre em janeiro de 2006 e janeiro de 2008. Todos os poços estão abertos desde o início da produção e possuem as seguintes restrições:

- Poços produtores:
 - Vazão máxima: 795 m³/d
 - Pressão mínima no fundo do poço: 70,3 kgf/cm²
 - Razão água-óleo máxima: 80%
- Poços Injetores:
 - Poço Well-002-I
 - Vazão máxima: 477 m³/d
 - Pressão máxima no fundo do poço: 352 kgf/cm²
 - Poço Well-004-I
 - Vazão máxima: 1113 m³/d
 - Pressão máxima no fundo do poço: 492 kgf/cm²

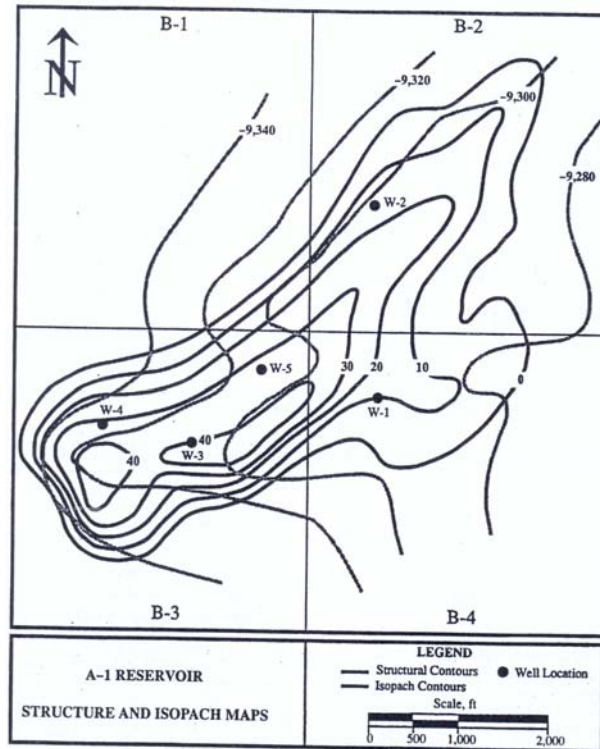


Figura 4-1: Mapa estrutural e de isopacas do reservatório em pés (Ertekin *et al.*, 2001).

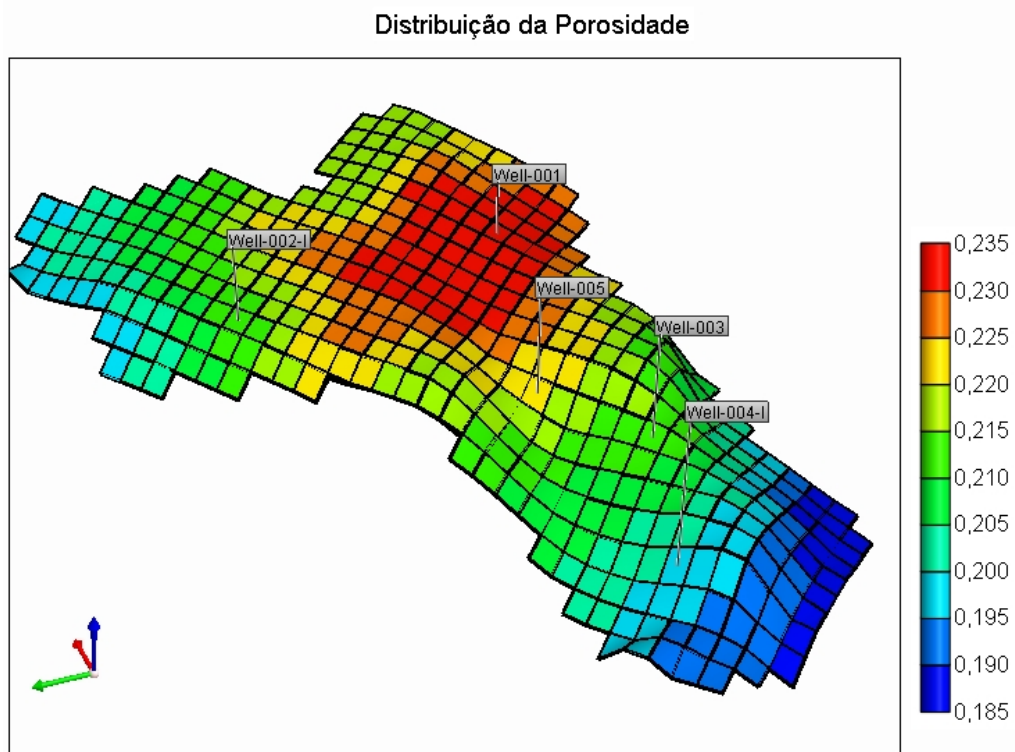


Figura 4-2: Distribuição da porosidade.




Figura 4-3: Distribuição da permeabilidade na direção i em mD.

Representando o resultado do estudo de exploração e modelagem do reservatório que seria utilizado por uma equipe de engenharia de reservatório para planejar o desenvolvimento do campo, gerou-se uma variação do modelo caso real, chamado de caso simulado. Este modelo possui as seguintes características:

- O modelo é homogêneo;
- Quatro propriedades tiveram seus valores modificados: porosidade, permeabilidade em i, permeabilidade em j e compressibilidade efetiva da rocha;
- A permeabilidade em j é uma função da permeabilidade em i, segundo a equação (4.1.1);
- Estas propriedades podem ser descritas segundo uma distribuição uniforme com os parâmetros informados pela tabela 4-1.
- Os valores escolhidos para a simulação inicial estão na tabela 4-2.

$$k_j = a k_i \quad (4.1.1)$$

onde a é uma constante.

Tabela 4-1: Parâmetros das distribuições das propriedades do caso simulado.

Propriedade	Mínimo	Máximo
Porosidade	0,17	0,25
Permeabilidade em i (mD)	168	443
Constante <i>a</i> da Permeabilidade em j	0,70	1,00
Compressibilidade da rocha (kg/cm ²) ⁻¹	2,32E-07	2,74E-07

Tabela 4-2: Valores escolhidos para a simulação inicial.

Propriedade	Valor
Porosidade	0,215
Permeabilidade em i (mD)	279,8
Constante <i>a</i> da Permeabilidade em j	0,90
Compressibilidade da rocha (kg/cm ²) ⁻¹	2,46E-07

Para realizar o ajuste de histórico, decidiu-se comparar as vazões de água produzida pelo poço Well-005. Assim, importou-se o histórico de injeção de água e produção de óleo do “campo real” para o “campo simulado” com o objetivo reduzir o número de variáveis do problema ao invés de aplicar as restrições de operações dos poços. A figura 4-4 mostra o gráfico gerado com as duas curvas.




Figura 4-4: Gráfico com as curvas de produção de água do poço Well-005. A curva de produção observada refere-se ao caso real e a produção prevista, caso simulado.

5. Metodologia Proposta

A essência da metodologia consiste em treinar uma rede neural capaz de substituir o simulador de reservatórios no processo de ajuste de histórico. Ao longo deste capítulo, será visto como o processo de ajuste de histórico e como a rede neural pode ser utilizada.

5.1. Ajuste de Histórico

O ajuste de histórico é uma técnica que visa mitigar/minimizar as incertezas relativas à caracterização da rocha-reservatório e de seus fluidos através da inclusão de dados dinâmicos da produção (histórico de produção e pressão). O aperfeiçoamento no modelo do reservatório permite reavaliar o plano de desenvolvimento, corrigir problemas na produção e planejar melhor métodos de recuperação secundária e avançada.

A necessidade de realizá-lo surge quando o engenheiro de reservatórios percebe uma discrepância entre os valores de produção observados no campo e previstos pela simulação em um poço, em um conjunto de poços ou no campo inteiro. Logo, é importante que haja um histórico de produção do campo de boa qualidade para ser comparado com o previsto pela simulação. Utiliza-se pelo menos um dos seguintes dados de produção para realizar o ajuste de histórico, podendo ser de apenas um poço ou conjunto de poços:

- Produção de água;
- Produção de óleo;
- Produção de gás;
- Injeção de água;
- Pressão no fundo do poço;
- Razão água-óleo ou;
- Razão gás-óleo.

O procedimento de ajuste de histórico está representado pelo fluxograma da figura 5-1. A comparação entre as curvas de produção prevista e observada é feita

através, neste trabalho, do erro quadrático médio que deve ser minimizado. Na primeira iteração, os dados do modelo podem ser as propriedades do modelo inicial do reservatório ou pontos aleatórios selecionados no domínio dos parâmetros de entrada do simulador visando auxiliar na busca pelo mínimo global. Existem diversos algoritmos de busca das propriedades que ajustam as curvas de produção (prevista e observada), sendo utilizado o algoritmo de busca direta de Maschio e Schiozer (2005) neste trabalho.

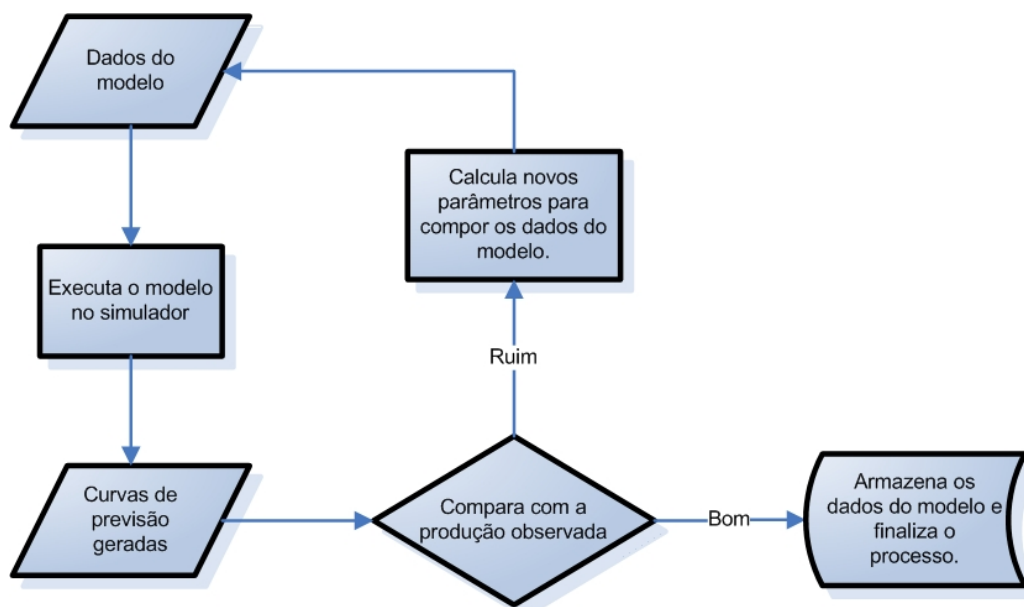


Figura 5-1: Fluxograma generalizado do ajuste de histórico.

O algoritmo de busca direta proposto por Maschio e Schiozer (2005) procura, no espaço do domínio, o conjunto de propriedades que resultem no menor erro em relação à curva observada. Neste algoritmo, o espaço de busca é formado pela discretização do espaço de busca das propriedades do reservatório que serão ajustados. O procedimento de ajuste pode ser resumido:

1. Seleciona-se, aleatoriamente, um ponto no espaço do domínio para ser o ponto central e calcula o erro quadrático médio com relação à curva a ser ajustada;
2. Calcula-se o erro quadrado médio dos pontos vizinhos;
3. O ponto vizinho que possuir um erro menor determinará a direção da busca;
4. Avaliam-se os pontos vizinhos na direção determinada até que o erro pare de reduzir;
5. O ponto com menor erro passa a ser o novo ponto central;

6. Volta ao passo 2 até que o ponto central seja aquele com o menor erro quadrático.

Esse procedimento é repetido várias vezes para aumentar as chances de se localizar um mínimo global. A figura 5-2 mostra uma representação esquemática do algoritmo de busca para duas propriedades.

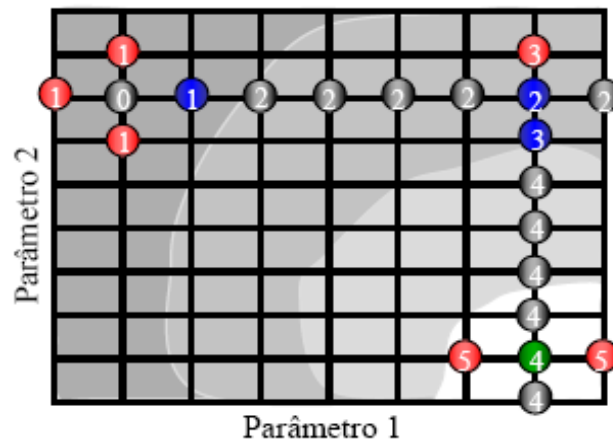


Figura 5-2: Representação esquemática do algoritmo de busca. A região mais clara indica os pontos onde o erro quadrático médio é menor (Maschio e Schiozer, 2005).

Um exemplo de resultado gráfico da aplicação de ajuste de histórico, extraída de Dickstein e Goldfeld (2006), é apresentada na figura 5-3. O ajuste realizado foi baseado na razão água-óleo (ou corte de água) de um poço. Esta figura é dividida em cinco partes:

- a) A razão água-óleo prevista inicialmente (linha verde);
- b) A razão água-óleo observada no campo no até o tempo presente t (pontos azuis);
- c) A razão água-óleo prevista após o ajuste de histórico até o tempo presente t (linha vermelha);
- d) Expansão da previsão da razão água-óleo para um tempo futuro $t+\Delta t$ (extensão da linha vermelha);
- e) Evolução real da razão água-óleo no tempo $t+\Delta t$ (extensão dos pontos azuis).

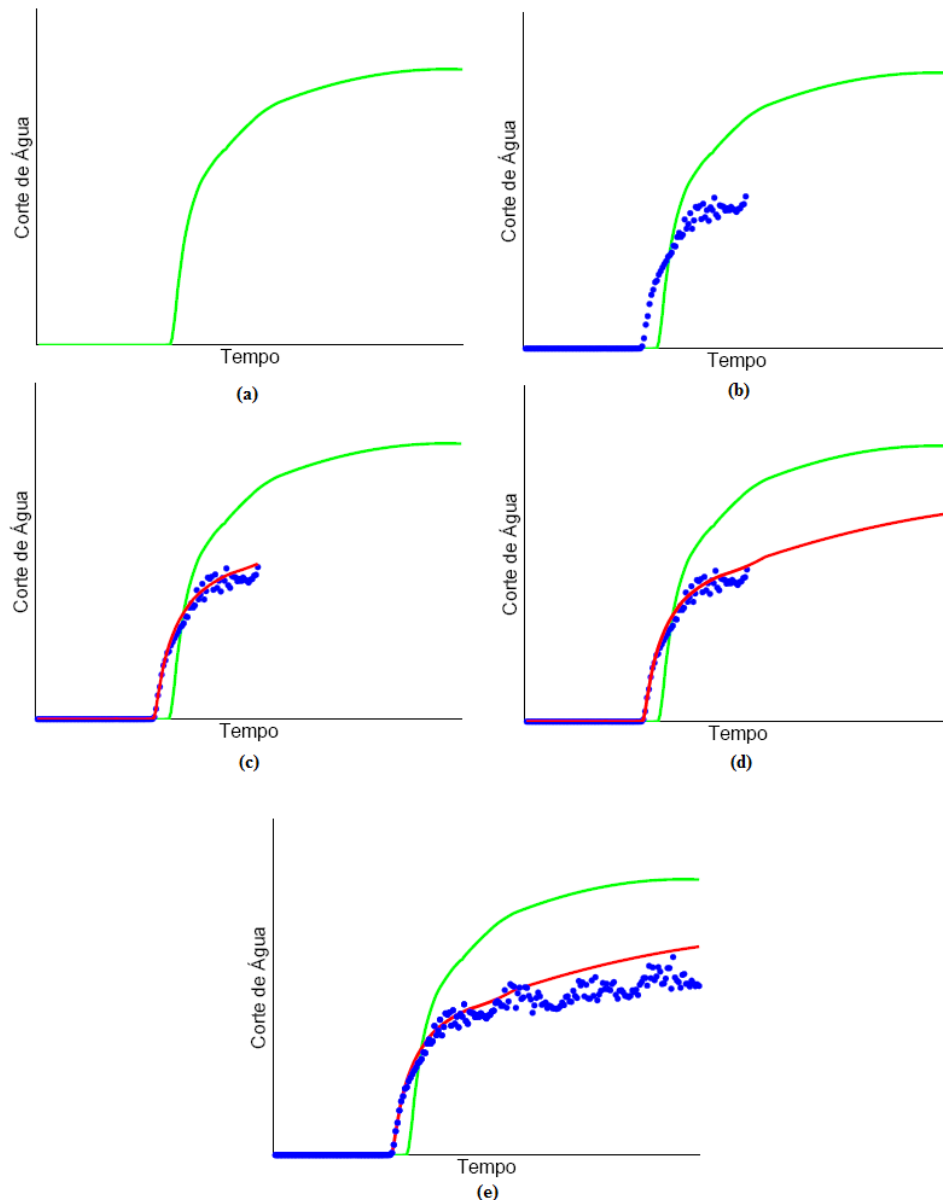


Figura 5-3: Variação da curva de razão água-óleo prevista de um poço com o ajuste de histórico (Dickstein e Goldfeld, 2006).

O aspecto importante a ser observado na figura acima é a comparação entre os modelos do reservatório antes e depois do ajuste de histórico. Observe que, além de ser mais próxima da razão água-óleo observada no campo até o tempo presente, o modelo do reservatório gerado após o ajuste permite realizar uma previsão de produção mais acurada para tempos futuros, facilitando as tomadas de decisão no campo.

5.2. O Problema do Ajuste de Histórico e a Metodologia Proposta

Como foi apresentado na figura 5-1, o ajuste de histórico é um processo iterativo e que depende da execução do simulador a cada passo. O número de iterações pode chegar facilmente à ordem de centenas e, em alguns algoritmos, há a necessidade de realizar múltiplas simulações em uma mesma iteração. Um exemplo são os algoritmos genéticos, a cada nova população simulam-se os modelos de reservatório de todos os filhos. Se a empresa operadora estiver gerenciando um reservatório complexo, com uma malha de blocos refinada, heterogênea e com muitos poços, cada simulação pode levar horas para ser executada, mesmo se realizada em processamento paralelo utilizando um *cluster*. O ajuste de histórico é, portanto, inviável para estes reservatórios.

Como medida de mitigação, propõe-se a utilização de redes neurais artificiais como um metamodelo do simulador de reservatórios substituindo-o no processo de ajuste de histórico. Para treinar esta rede, um conjunto de modelos de reservatório é simulado para obter as suas respectivas curvas de produção. Com as propriedades do reservatório de cada modelo (*input*) e as curvas de produção que se deseja ajustar (*output*) treina-se uma rede neural do tipo *Feed-forward* (ver figura 5-4).

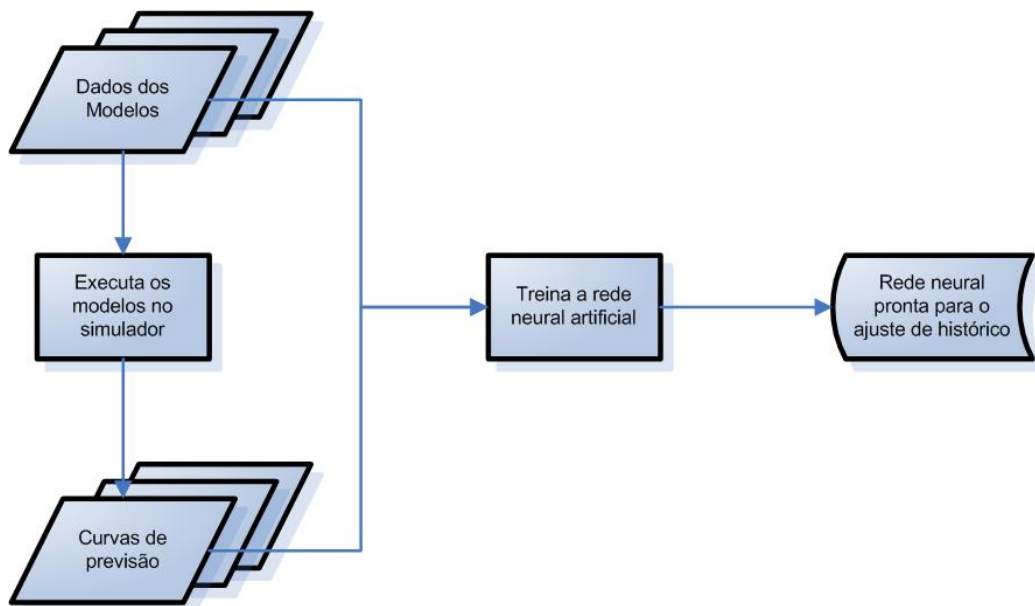


Figura 5-4: Fluxograma do treinamento da rede neural.

A figura 5-5 apresenta o mesmo fluxograma da figura 5-1 sobre as etapas do ajuste de histórico, sendo utilizada, porém, uma rede neural treinada no lugar do simulador.

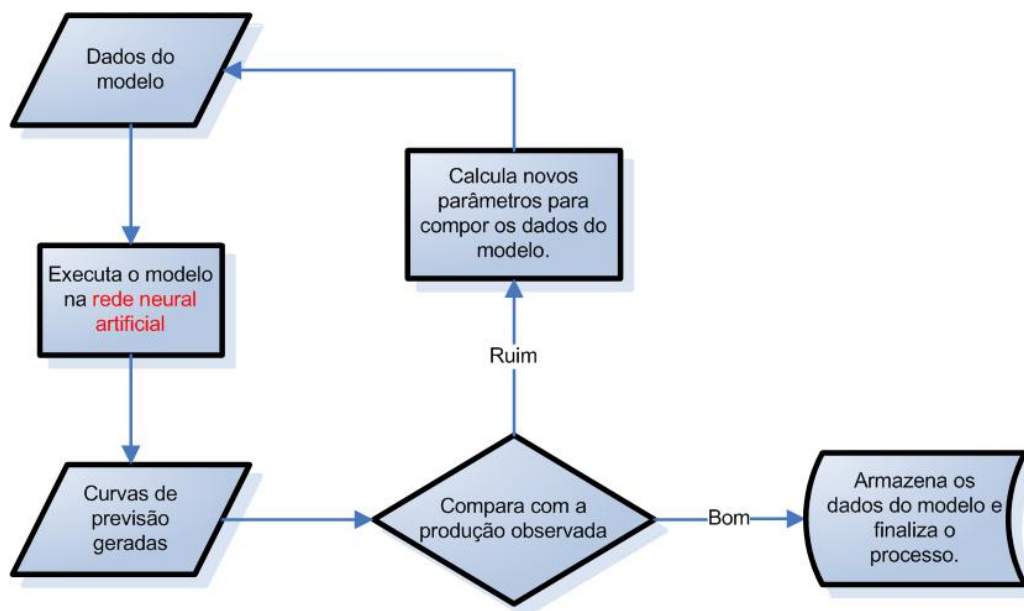


Figura 5-5: Fluxograma genérico do ajuste de histórico usando uma rede neural artificial.

A economia de tempo está na redução do número de simulações necessárias para executar todo o processo de ajuste de histórico. Considerando que o tempo gasto pela rede neural para fornecer as curvas de previsão é desprezível, a economia realizada pela metodologia pode ser estimada como:

$$\Delta t_{economizado} = \left(N_{simula\c{c}o\es,ajuste} - N_{simula\c{c}o\es,treino} \right) \cdot t_{simula\c{c}o\es} \quad (5.1.1)$$

onde $N_{simula\c{c}o\es,ajuste}$ é o número de simulações necessárias para realizar o ajuste de histórico pelo método convencional, $N_{simula\c{c}o\es,treino}$ é o número de simulações necessárias para treinar a rede e $t_{simula\c{c}o\es}$ é o tempo para executar cada simulação.

6. Aplicação da Rede Neural no Ajuste de Histórico

Ao longo dos capítulos anteriores, foi apresentada a motivação deste trabalho, viabilizar o ajuste de histórico de reservatórios cuja simulação requer um alto custo computacional, e a metodologia proposta para atingir este objetivo, treinar uma rede neural artificial capaz de substituir o simulador de reservatório usando um número pequeno de simulações. Neste capítulo, aplicaremos a metodologia através do campo apresentado no capítulo 4. Para treinar e manipular a rede neural artificial, bem como realizar o ajuste de histórico, foi utilizado o *toolbox* de redes neurais do programa MATLAB R2007b da empresa The Mathworks.

Antes de iniciar o treinamento da rede neural artificial, esta deve ser definida. No capítulo 3, optou-se por uma rede neural do tipo *Feed-forward* treinada através do método de *Back-propagation* e uma camada escondida, com o número de neurônios e o algoritmo de treinamento indefinidos ainda. No capítulo 4, os modelos de reservatório caso real e caso simulado foram apresentados. Determinou-se que o ajuste de histórico será através das propriedades porosidade, permeabilidade em i , permeabilidade em j e compressibilidade da rocha e o erro na curva de produção de água no poço Well-005 será a função a minimizar. Logo, essas 4 propriedades farão parte do vetor de entrada da rede neural e a produção de água, do vetor de saída. Uma quinta variável foi incluída no vetor de entrada: o tempo. Assim, o vetor de saída da rede neural é composto por apenas um valor: a vazão de água produzida pelo poço Well-005 para o tempo t . Essa medida simplifica a estrutura da rede neural e já foi utilizada com sucesso na literatura para prever a produção de poços (Salehi *et al.*, 2007). A representação esquemática da rede neural, com um número indefinido de neurônios na camada escondida, feita através do *toolbox* de redes neurais do MATLAB, aparece na figura 5.




Figura 6-1: Representação esquemática da rede neural utilizada contendo 5 neurônios na camada de entrada, que são os 4 parâmetros que se deseja ajustar mais o tempo, e 1 neurônio na camada de saída, o valor da razão água óleo no tempo t .

A primeira etapa para treinar corretamente uma rede neural é selecionar um conjunto de pares *input-output* que seja representativo da simulação de reservatórios. Duas perguntas surgem na busca por este conjunto: Como selecionar cada par? Qual é o número ideal de pares para treinamento?

No capítulo 2, o reservatório de petróleo foi apresentado como uma rocha sedimentar de propriedades heterogêneas e que a sua caracterização ocorria através de funções de densidade de probabilidade ou estimando os valores médios das variáveis aleatórias através da medição de alguns pontos. Para a geração dos pares para treinamento, é importante que haja uma função de densidade de probabilidade explicando cada propriedade a ajustar, pois elas serão selecionadas aleatoriamente segundo estas funções.

Se o conhecimento sobre uma propriedade é alto e ela está bem caracterizada pela sua função de densidade de probabilidade, recomenda-se a utilização desta, pois a rede neural treinada terá uma alta precisão nos valores em torno do resultado esperado, permitindo um ajuste de histórico com a mesma qualidade do método convencional, mas uma baixa precisão para valores mais afastados.

Se a propriedade não está bem caracterizada, recomenda-se utilizar uma função de densidade de probabilidade uniforme com os limites apresentados pela geologia. Isso garante que a rede neural cubra uniformemente o espaço de busca permitindo um ajuste de histórico de boa qualidade em qualquer direção. A saída da rede neural jamais será igual à saída do simulador de reservatórios. Nesta metodologia, perde-se um pouco da qualidade do ajuste de histórico para poupar muito tempo de processamento.

O processo de seleção dos pares pode ser resumido nas seguintes etapas:

1. Cada propriedade é selecionada aleatoriamente seguindo a função de densidade de probabilidade descrita na tabela 4-1;
2. O modelo do reservatório é gerado segundo os novos valores de cada propriedade e a simulação é executada;
3. A partir da curva da vazão de água produzida geram-se até 25 novos pares para treinamento com os valores de cada propriedade constantes e variando o tempo

de 1 a 25. Em algumas simulações não foi possível calcular a curva de razão água-óleo no período de 25 meses por problemas de convergência no método numérico.

4. Retorna ao passo 1 até completar o conjunto pares com o tamanho desejado.

Com todos os pares gerados, os valores foram normalizados através da função de normalização descrita segundo a equação:

$$x_{norm} = \frac{x - \bar{x}}{x - x_{\min}} \quad (5.1.2)$$

onde x_{norm} é o valor normalizado da propriedade, \bar{x} é a média da propriedade considerando todos os pares e x_{\min} é o menor valor da propriedade.

Três conjuntos de pares foram gerados simulando 25, 50 e 100 modelos de reservatórios. 60% dos pares foram separados para treinamento, 20% para validação e 20% para teste. Todos os parâmetros dos algoritmos de treinamento de gradiente descendente e Levenberg-Marquardt foram mantidos conforme o padrão do *toolbox* do MATLAB, a exceção do número máximo de iterações que mudou de 100 para 500.

Uma rotina foi escrita em MATLAB com o objetivo gerar dados estatísticos que permitissem avaliar o número ótimo de neurônios na camada escondida e o melhor algoritmo de treinamento. Dado um conjunto de simulações e definido um algoritmo de *Back-propagation*, ela treina grupos de redes neurais com tamanhos variados na camada escondida, salvando a melhor rede de cada grupo e os valores da função performance de todas. A figura 6-2 apresenta o fluxograma da rotina.

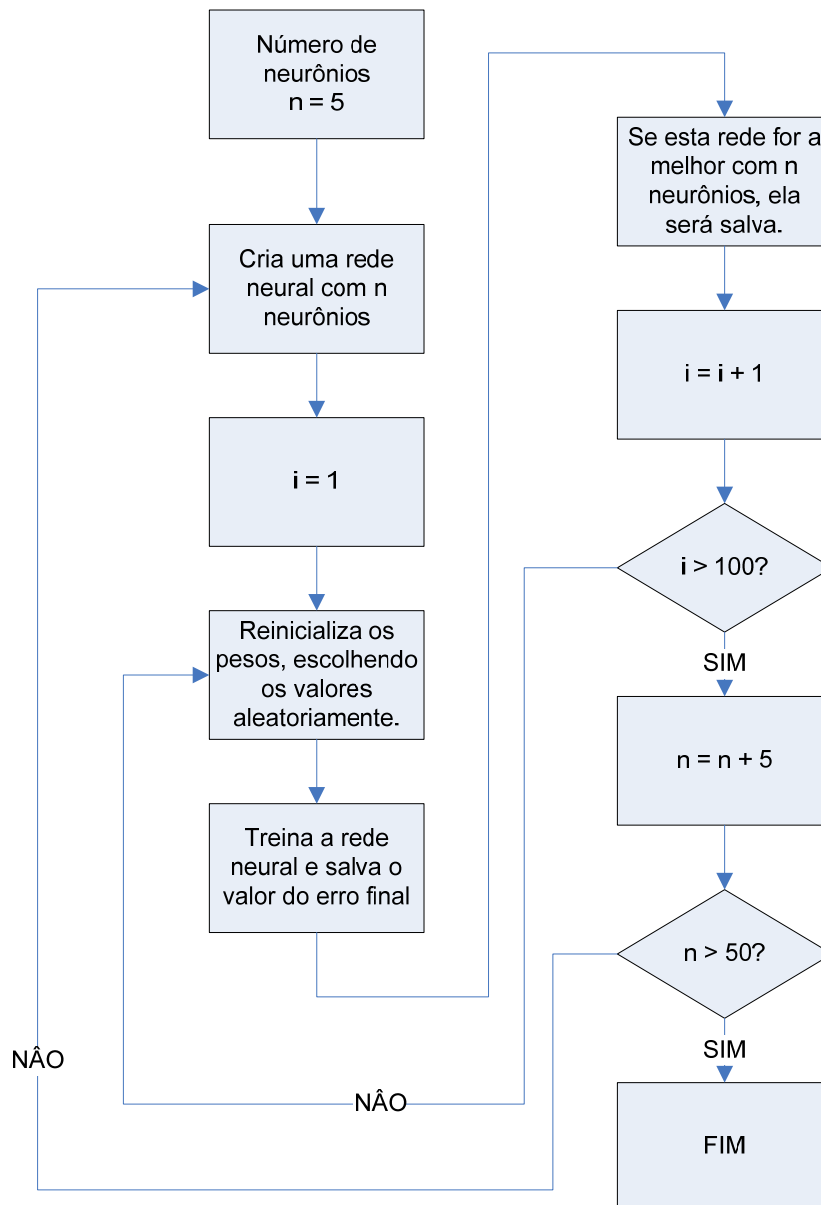


Figura 6-2: Fluxograma da rotina de treinamento de redes.

Os resultados do treinamento com o algoritmo gradiente descendente com um conjunto de 100 simulações podem ser observados nas figuras abaixo. Na figura 6-3, que apresenta a média e o desvio padrão da função performance das redes neurais e a melhor rede de cada grupo, observa-se que o erro quadrático médio é alto independente do número de neurônios na camada escondida. Nas figuras 6-4 e 6-5, são apresentadas as funções performance das melhores redes com 5 e 40 neurônios na camada escondida. Nestas, a função performance dos pares para teste e para validação acompanham a função dos pares para treinamento indicando que o número de iterações ainda não foi suficiente para causar o *overtraining*.




Figura 6-3: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo gradiente descendente com um conjunto de 100 simulações.




Figura 6-4: Função performance com 5 neurônios na camada escondida e treinamento com o algoritmo gradiente descendente com um conjunto de 100 simulações.




Figura 6-5: Função performance com 40 neurônios na camada escondida e treinamento com o algoritmo gradiente descendente com um conjunto de 100 simulações.

Os resultados da aplicação do algoritmo de Levenberg-Marquardt, para o mesmo conjunto de 100 pares para treinamento, podem ser observados nas figuras abaixo. Na figura 6-6, que apresenta a média e desvio padrão das funções performance de cada grupo de redes, além da função performance da melhor rede, observa-se uma melhora significativa em relação ao algoritmo anterior, porém ele ainda permanece alto.

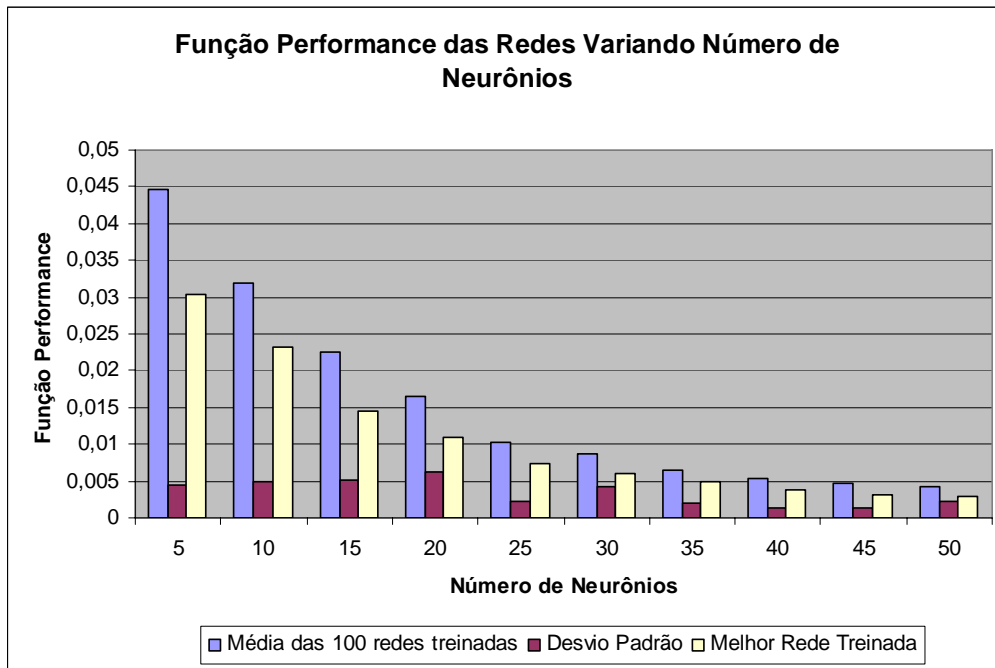


Figura 6-6: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo de Levenberg-Marquardt com um conjunto de 100 simulações.

Nas figuras 6-7 e 6-8 são apresentadas as funções performance das melhores redes neurais treinadas com 5 e 40 neurônios na camada escondida. O erro médio quadrático é de 10 a 100 vezes menor do que visto no algoritmo anterior. A parada no treinamento não foi causada pelo número de iterações, mas pelo incremento no valor da função performance do conjunto de dados de validação.




Figura 6-7: Função performance com 5 neurônios na camada escondida e treinamento com o algoritmo de Levenberg-Marquardt com um conjunto de 100 simulações.




Figura 6-8: Função performance com 40 neurônios na camada escondida e treinamento com o algoritmo de Levenberg-Marquardt com um conjunto de 100 simulações.

Acredita-se que o erro alto no conjunto de 100 simulações ocorra devido ao excesso de pares gerado. Para o conjunto de 100 simulações, foram gerados 2436 pares,

1219 pares para o conjunto de 50 simulações e 603 pares no conjunto de 25 simulações. Uma comprovação do que foi exposto pode ser observada nas figuras 6-9 e 6-10, que apresentam a média e desvio padrão da função performance de cada grupo e a melhor rede para aquelas treinadas com os conjuntos de 50 e 25 simulações. Observe que o erro é bem menor.




Figura 6-9: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo Levenberg-Marquardt com um conjunto de 50 simulações.




Figura 6-10: Média, desvio padrão das funções performance e melhor rede de cada grupo. Treinamento com o algoritmo Levenberg-Marquardt com um conjunto de 25 simulações.

Os testes realizados até agora auxiliaram na decisão do algoritmo de *Back-propagation* a ser utilizado no treinamento e a levantar dúvidas sobre o treinamento das redes com um conjunto de 100 simulações. Resta, ainda, avaliar o número ideal de neurônios na camada escondida e a influência do número de pares para treinamento, *i.e.* simulações a serem realizadas, na precisão dos resultados da rede.

Para determinar qual deve ser o número de simulações ideal para a aplicação, foram comparados os conjunto de 25, 50 e 100 simulações através da melhor rede neural com 5 neurônios na camada escondida de cada um. Sabe-se que, se o número de simulações for baixo, a rede não será capaz de substituir o simulador de reservatórios no ajuste de histórico. Porém, se for alto, o tempo computacional necessário para realizar todas as simulações para o treinamento pode inviabilizar a metodologia.

Essas redes foram testadas com um conjunto de 200 simulações independentes cujas propriedades dos modelos também foram selecionadas de forma aleatória segundo as suas distribuições e não tiveram participação no treinamento das redes. Ao invés de utilizar o erro quadrado médio, a comparação entre as redes foi feita através da medição

do erro ao longo de cada uma das 200 curvas criadas utilizando o coeficiente de determinação (R^2), descrito na equação . A vantagem do coeficiente de determinação é poder comparar as curvas através de um número adimensional, facilitando a sua compreensão.

$$R^2 = 1 - \frac{\sum (\hat{Y}_i - Y_i)^2}{\sum (Y_i - \bar{Y}_i)^2} \quad (5.1.3)$$

onde \hat{Y}_i é o valor da rede neural, Y_i é o valor da curva que está sendo comparada e \bar{Y}_i é a média dos valores da curva.

As figuras 6-11, 6-12, 6-13 e 6-14 apresentam quatro gráficos com o objetivo de ilustrar a relação entre o coeficiente de determinação e as curvas geradas pelo simulador e pela rede neural. Através destes gráficos e diversos outros analisados, conclui-se que 0,990 é um valor razoável para o coeficiente de determinação e 0,998 é o ideal.




Figura 6-11: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.




Figura 6-12: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.




Figura 6-13: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.




Figura 6-14: Análise do coeficiente de determinação comparando graficamente uma das 200 curvas de vazão de água geradas com a curva gerada pela rede neural treinada com 50 simulações.

A suspeita de que o treinamento das redes neurais com 100 simulações não foi bom se confirma com a análise coeficiente de determinação. Para algumas das curvas analisadas o coeficiente assumiu valores negativos. Quando ocorre deste coeficiente assumir valores muito diferentes de 1, significa que o modelo gerado, a rede neural, não possui o poder para explicar variação do fenômeno observado, vazão de água no poço Well-005 (Jensen *et al.*, 2000). Por isso, descartaram-se definitivamente as redes neurais treinadas com o conjunto de 100 simulações.

A partir da análise dos coeficientes de determinação, fica relativamente fácil comparar as redes neurais treinadas com diferentes números de simulações. A figura 6-15 apresenta um histograma de frequência dos valores do coeficiente de determinação

para cada rede neural. Nela podemos observar que um conjunto de pares para treinamento gerado a partir de 50 simulações é o ideal para o caso estudado.




Figura 6-15: Histograma de frequência dos coeficientes de determinação para redes neurais treinadas com diferentes tamanhos do conjunto de pares.

A figura 6-16 apresenta um histograma semelhante, porém variando o número de neurônios na camada escondida para redes neurais treinadas com 50 simulações. Observe que a rede neural treinada com 5 neurônios possui 19,5% das curvas acima do valor ideal ($R^2=0,998$) enquanto a rede treinada com 10 neurônios possui 44% e a de 15 neurônios, 48%. Devido a pequena diferença entre as redes de 10 e 15 neurônios, optou-se pela de 10 neurônios na camada escondida.




Figura 6-16: Histograma de freqüência dos coeficientes de determinação para redes neurais treinadas com diferentes números de neurônios na camada escondida.

A rede neural está completamente definida e treinada e o ajuste de histórico já pode ser realizado. Como todas as propriedades do reservatório estão normalizadas na rede neural no intervalo [-1; 1], decidiu-se que os vizinhos estão afastados de 0,1 para qualquer propriedade. Para evitar que a solução fique restrita a um mínimo local, 10 pontos foram escolhidos aleatoriamente no espaço do domínio para realizar a busca. Cada ponto é definido pelo vetor (porosidade; permeabilidade em i; constante a da permeabilidade em j; compressibilidade da rocha).

Comparando os mínimos locais encontrados através destes pontos, observou-se que todos eles convergiram para uma mesma região, gerando curvas de produção de água e erros quadráticos médios muito próximos. A tabela 6-1 apresenta os 10 pontos selecionados e os mínimos que foram encontrados através deles.

Tabela 6-1: Pontos utilizados no ajuste de histórico.

Pontos	Antes do Ajuste	Após o Ajuste
1	(0,193408; 219,023068; 1,101824; 2,34685E-07)	(0,205408; 282,923068; 1,424324; 2,32574E-07)
2	(0,180498; 184,671963; 1,405259; 2,55313E-07)	(0,204498; 291,171963; 1,405259; 2,34202E-07)
3	(0,238266; 287,508698; 1,056586; 2,66856E-07)	(0,202266; 308,808698; 1,379086; 2,56300E-07)
4	(0,246406; 184,194296; 1,201200; 2,54878E-07)	(0,202406; 304,894296; 1,373200; 2,54878E-07)
5	(0,193749; 194,752514; 1,077816; 2,73347E-07)	(0,201749; 308,352514; 1,378816; 2,60680E-07)
6	(0,239797; 294,123512; 1,428865; 2,67738E-07)	(0,203797; 301,223512; 1,407365; 2,38182E-07)
7	(0,229535; 273,691541; 1,105716; 2,51677E-07)	(0,201535; 309,191541; 1,342216; 2,60122E-07)
8	(0,171434; 200,449043; 1,332929; 2,49633E-07)	(0,203434; 306,949043; 1,397429; 2,41189E-07)
9	(0,227845; 261,469860; 1,069921; 2,68271E-07)	(0,203845; 296,969860; 1,392421; 2,36605E-07)

10	(0,230849; 186,715800; 1,419199; 2,65829E-07)	(0,202849; 307,415800; 1,376199; 2,48940E-07)
----	--	--

O ponto 8 foi o que resultou no melhor ajuste. Duas simulações foram rodadas: uma com os dados de propriedade anterior ao ajuste e outro com os dados do mínimo global. Através das figuras 6-17 e 6-18, observa-se que as curvas da rede neural foram fiéis as geradas pelo simulador, validando o ajuste de histórico realizado pela rede neural.

Para realizar este ajuste de histórico com os 10 pontos selecionados, seriam necessárias 902 simulações de reservatório. Utilizando a rede neural como metamodelo foram rodadas apenas 50 simulações, desconsiderando as simulações realizadas apenas para o estudo da precisão do método.




Figura 6-17: Comparação das curvas antes do ajuste.




Figura 6-18: comparação das curvas após o ajuste.

7. Conclusão

A metodologia proposta neste trabalho foi aplicada com sucesso no caso estudado. Reduziu-se sensivelmente o número de simulações necessárias para o ajuste de histórico economizando tempo e processamento sem haver perdas consideráveis na qualidade do ajuste.

Os três pontos abaixo apresentam experiências adquiridas ao longo do trabalho e merecem ser ressaltadas:

- A rede neural é utilizada, nesta metodologia, para interpolar funções. Ela não serve para prever a produção para tempos além daqueles usados no treinamento.
- Uma rede neural só pode ser utilizada para ajustar o reservatório para o qual foi treinada e, se o modelo variar drasticamente, um novo treinamento deve ser realizado.
- Ainda não é possível obter uma fórmula para determinar o número ótimo de neurônios na camada escondida e de simulações. A experiência e sentimentos do programador são as melhores armas no momento.

O sucesso na aplicação da rede neural como um substituto ao simulador de reservatórios para o ajuste de histórico demonstra o grande potencial que esta ferramenta ainda tem na indústria do petróleo.

8. Referências Bibliográficas

BARRETO, J. M. *Introdução às Redes Neurais Artificiais*. 2002. Disponível em: <<http://www.inf.ufsc.br/~barreto/tutoriais/Survey.pdf>>. Acesso em: 2 de janeiro de 2009.

CALÔBA, L. P. *Uma Pequena Introdução às Redes Neurais Artificiais e Aplicações. Um Curso Compacto - Informativo*. Rio de Janeiro: 2005. Disponível em: <http://www.lps.ufrj.br/~caloba/SBPO_2005_Minicurso_Redex_Neurais.pdf>. Acesso em: 2 de agosto de 2008.

CULLICK, A. S.; JOHNSON, D.; SHI, G. Improved and More-Rapid History Matching With a Nonlinear Proxy and Global Optimization. *SPE Annual Technical Conference and Exhibition*. San Antonio, Texas: Society of Petroleum Engineers, 2006.

DEMUTH, H.; BEALE, M.; HAGAN, M. *Neural Network Toolbox™ 6 User's Guide*. The MathWorks, 2008. Disponível em: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf>. Acesso em: 3 de dezembro de 2008.

DICKSTEIN, F.; GOLDFELD, P. Ajuste Automático de Histórico em Simulação de Reservatórios. *1ª Semana de Matemática Aplicada*. Rio de Janeiro: Laboratório de Matemática Aplicada - UFRJ, 2006.

ERTEKIN, T.; ABOU-KASSEM, J. H.; KING, G. R. *Basic Applied Reservoir Simulation*. 1. ed. Richardson, Texas: Society of Petroleum Engineers, 2001. (Textbook, 7).

JENSEN, J. L.; LAKE, L. W.; CORBETT, P. W. M.; GOGGIN, D. J. *Statistics for Petroleum Engineers and Geoscientists*. 2ª. ed. Amsterdam: Elsevier Science, 2000. (Handbook of Petroleum Exploration and Production, 2).

KRÖSE, B.; SMAGT, P. V. D. *An Introduction to Neural Networks*. University of Amsterdam, 1996. Disponível em: <www.avaye.com/files/articles/nnintro/nn_intro.pdf>. Acesso em: 11 de dezembro de 2008.

MASCHIO, C.; SCHIOZER, D. J. Comparação entre Metodologia de Otimização Global e o Método de Gradientes para Ajuste de Histórico Assistido. *3º Congresso Brasileiro de P&D em Petróleo e Gás*. Salvador, Bahia: Associação Brasileira de Pesquisa e Desenvolvimento em Petróleo e Gás, 2005.

MOHAGHEGH, S. Virtual-Intelligence Applications in Petroleum Engineering: Part 1—Artificial Neural Networks. *Journal of Petroleum Technology* [S.I.], v. 52, n. 9, p. 8, setembro 2000.

MOHAGHEGH, S. D. Quantifying Uncertainties Associated With Reservoir Simulation Studies Using Surrogate Reservoir Models. *2006 SPE Annual Technical Conference and Exhibition*. San Antonio, EUA: Society of Petroleum Engineers, 2006.

ROSA, A. J.; CARVALHO, R. D. S.; XAVIER, J. A. D. *Engenharia de Reservatórios de Petróleo*. 1. ed. Rio de Janeiro: Editora Interciência, 2006.

SALEHI, F.; AZIZI, R.; SALEHI, A. Oil Field Development Using Neural Network Model. *Advanced Intelligent Computing Theories and Applications [S.I.]*, v. 2, p. 10, 2007.

SILVA, P. C.; MASCHIO, C.; SCHIOZER, D. J. Evaluation of Neuro-Simulation Techniques as Proxies to Reservoir Simulator. *Rio Oil & Gas Expo and Conference 2006*. Rio de Janeiro, Brasil: Instituto Brasileiro de Petróleo, Gás e Biocombustíveis, 2006.