3
Aproximador de Função para Simulador de Reservatório Petrolífero

3.1.
Introdução

O desenvolvimento de um campo petrolífero pode ser entendido como um conjunto de ações necessárias para colocar em produção um campo delimitado e conhecido. Estas ações consistem de perfurações, sistemas de injeção, projeto de plataforma, entre outras. A forma como será feito esse desenvolvimento é uma das tarefas mais importantes na área de reservatório, dado que esta determinação afeta o comportamento do reservatório, as decisões futuras, as análises econômicas e, conseqüentemente, a atividade resultante do projeto em sua totalidade. Isto envolve diversas variáveis, tais como locação, número e tipos de poços, as condições de operação dos poços, uso ou não de poços inteligentes, as características do reservatório e, inclusive, o cenário econômico entre outros aspectos.

Para que se chegue a um projeto de explotação otimizado na atividade de gerenciamento da engenharia de reservatório, faz-se uso de simuladores de reservatório, que normalmente são os responsáveis pelo alto custo computacional das otimizações realizadas nessas áreas. Uma forma de minimizar esse problema é através do uso de aproximadores de função, que visam aprender o comportamento do simulador de reservatórios para problemas específicos, substituindo-os parcialmente ou integralmente nos processos de otimização.

Na indústria de petróleo, alguns trabalhos abordaram a utilização de aproximadores de função em problemas de otimização que demandam simuladores. Em Artus (2006), utiliza-se aproximadores estatísticos dentro do processo de otimização de tipo e de localização de um poço multilateral sob incerteza geológica. Em Túpac (2005), também se utilizou aproximadores de função para a determinação da localização de poços. Diversos autores utilizam modelos de inferência para diferentes objetivos, como em Mohaghegh (1996; 1998), onde se utilizam modelos de inteligência computacional para abordar

PUC-Rio - Certificação Digital Nº 0521364/CA

problemas relacionados a campos de gás. Já em Almeida (2007), se demonstrou a viabilidade da construção de aproximadores utilizando o modelo ANFIS para poços inteligentes.

Diversos trabalhos de otimização na área de explotação de petróleo indicam a necessidade de construção de aproximadores de reservatórios para tornar o processo de otimização viável (Faletti, 2007) (Oliveira, 2006) e (Aitokhuehi, 2004) (Aitokhuehi, 2005).

A partir disto, este trabalho dedica-se à construção de um aproximador de função para a substituição parcial ou integral do simulador de reservatório IMEX (CMG, 2000) em sistemas de otimizações de campos inteligentes, utilizando um modelo formado por técnicas de inteligência computacional – Redes Neurais Artificiais MLP e ANFIS.

Apesar da comprovada eficiência dos modelos de inteligência computacional na tarefa de representar um sistema, deve-se sempre levar em consideração o custo para obtenção das amostras para construção destes modelos, que muitas vezes desmotiva a sua utilização. Por isso, neste trabalho, avalia-se o desempenho dos principais modelos de Inteligência Computacional em conjunto com Projeto de Experimentos Fatoriais Fracionado para determinação das amostras que serão necessárias para a construção do aproximador de função do reservatório.

Neste capítulo são abordadas as decisões pertinentes à modelagem do aproximador de função para o simulador em campos inteligentes. O aproximador resultante deste trabalho é avaliado no Sistema Híbrido de Otimização de Estratégia de Controle de Válvulas de Poços Inteligentes sob Incertezas (Faletti, 2007), onde se utiliza o simulador IMEX (CMG, 2000).

PUC-Rio - Certificação Digital Nº 0521364/CA

3.2. Otimização de Estratégia de Controle de Válvulas de Poços Inteligentes

Em Faletti (2007) desenvolveu-se um sistema de otimização que visa obter uma metodologia para o cálculo do benefício do uso de poços inteligentes, apoiando as atividades de desenvolvimento e gerenciamento de campos de petróleo inteligentes. O sistema é capaz de: avaliar a viabilidade do uso de completação inteligente na presença de falhas de válvulas; otimizar uma configuração de estratégia de controle de válvulas (*on/off* ou abertura contínua), quando for considerado vantajoso o uso de poços inteligentes; e determinar a

melhor configuração de estratégia de controle de válvulas mesmo na presença de incertezas técnicas geológicas.

Os módulos que compõem o sistema são: Módulo de Otimização do Controle de Válvulas; Módulo de Tratamento de Incertezas Técnicas; e o Módulo Função Objetivo. O simulador de reservatório (IMEX) é utilizado para apoiar no cálculo do valor presente líquido (VPL), dado que ele fornece as curvas de produção diária de óleo, gás e água. Esse sistema pode ser visualizado na Figura 8.

O Módulo de Otimização de Controle de Válvulas consiste em encontrar a melhor configuração de um conjunto particular de válvulas, existentes em poços inteligentes, para cada intervalo de tempo ao longo de um período total de simulação, que ofereça o maior VPL. Essa otimização é realizada através da filosofia de estratégia de controle pró-ativo (Faletti, 2007).

PUC-Rio - Certificação Digital Nº 0521364/CA

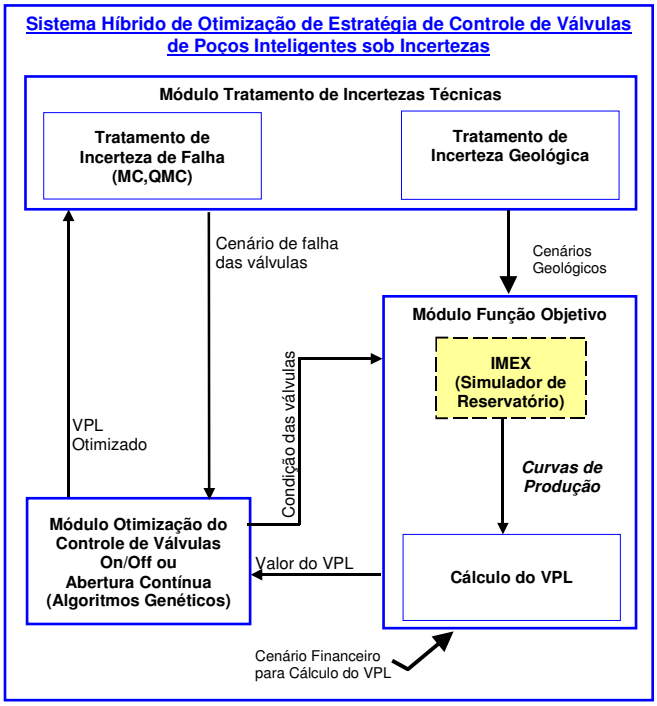

Figura 8 – Principais módulos do sistema otimizador.

A Figura 9 mostra as entradas fornecidas pelo módulo otimizador para o simulador de reservatórios, para o caso de válvulas *on/off*. Essas entradas representam uma alternativa para o controle de quatro válvulas, que podem ser alteradas a cada dois anos, durante 20 anos de simulação.

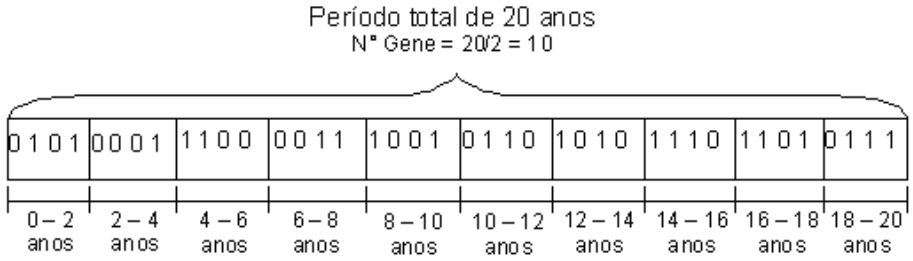

Figura 9 – Entradas fornecidas pelo processo de otimização de válvulas para o simulador (exemplo para válvulas on/off).

Na Figura 10 mostra-se as entradas fornecidas pelo módulo otimizador para o simulador de reservatórios, para o caso de válvulas de abertura contínua. Essas entradas representam uma alternativa contendo três válvulas, que também podem ser alteradas a cada dois anos, durante 20 anos de simulação.

PUC-Rio - Certificação Digital Nº 0521364/CA

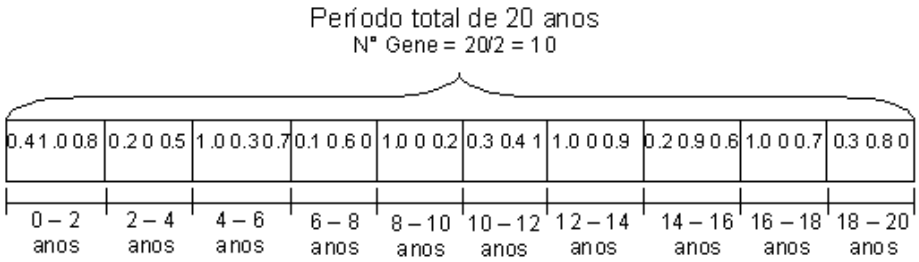

Figura 10 – Entradas fornecidas pelo processo de otimização de válvulas para o simulador (exemplo para válvulas de abertura contínua).

O simulador de reservatório IMEX recebe as entradas do módulo otimizador e realiza a simulação para um período de 20 anos de exploração. Em seguida, o simulador fornece o perfil de produção de óleo, gás e água da alternativa simulada para o módulo Cálculo do VPL, que realiza o cálculo do valor presente líquido com essas as informações.

Para o problema em questão o VPL foi determinado pela diferença entre o Valor Presente da alternativa (VP) (fluxo de caixa descontado) menos o custo de desenvolvimento das válvulas (D_V) existentes na alternativa (Faletti, 2007) (Eq. 11).

$$VPL = VP - D_V \qquad (11)$$

O custo de desenvolvimento das válvulas (D_V) é calculado considerando o custo do *Packer*[1] (C_P) por válvula, o custo do *Flat-pack*[2] (C_{FP}) por poço inteligente, o custo de cada válvula (C_V) e o custo do HPU (*Hydraulic Power Unit*)[3] (C_{HPU}) por reservatório. Deste modo, o custo de desenvolvimento das válvulas é dado pela equação 12, a seguir.

$$D_V = C_P n_v + C_{FP} n_p + C_V n_v + C_{HPU} \quad (12)$$

onde n_v é o número de válvulas existentes na alternativa e n_p é o número de poços inteligentes da alternativa.

O Valor Presente da alternativa (VP) é composto pela diferença entre o Valor Presente da Receita (VP_R) e o Valor Presente do Custo de Operação (VP_{COP}), com aplicação da alíquota de imposto I , geralmente em torno de 34%, como mostra a equação 13.

$$VP = (VP_R - VP_{COP})(1 - I) \quad (13)$$

O Valor da Receita $R(t_i)$ depende da produção de óleo $Q(t_i)$ e do preço do petróleo $P_{oil}(t_i)$ durante o tempo de produção. Para esta análise, consideram-se condições de mercado sem incertezas. Assim, o preço do petróleo no tempo t_i pode ser expresso como uma função $P_{oil}(t_i)$ determinística, nesse estudo considerada constante. Para cada instante de tempo, o valor da receita pode ser obtido conforme a equação 14. Para o valor presente da receita, aplica-se o desconto exponencial com a taxa de desconto ρ = 0.1, conforme a equação 15.

$$R(t_i) = Q(t_i).P_{oil}(t_i) \quad (14)$$

[1] Packer: normalmente isola o espaço anular do poço
[2] Flat-Pack: é um cabo chato que fica dentro do poço (no espaço anular) usado para transmitir (ou receber) informações das completações inteligentes.
[3] HPU: Unidade que leva potência (no caso hidráulica) para o acionamento das válvulas de completação inteligente.

PUC-Rio - Certificação Digital Nº 0521364/CA

$$VP_R = \sum_{i=1}^{T} R(t_i).e^{-\rho t_i} \quad (15)$$

onde o valor T representa o tempo de produção da alternativa.

Para o cálculo do valor do custo operacional $C_{OP}(t_i)$, neste projeto, considera-se apenas o custo de retirada da água C_w (por unidade de volume) multiplicado pela afluência de água $W(t_i)$ ocorrida em cada tempo t_i, mais o custo da válvula C_V, se houver substituição de válvula no tempo t_i. Desta forma, o custo operacional para o tempo t é dado pela equação 16 a seguir.

$$C_{OP}(t_i) = C_w.W(t_i) + C_V \quad (16)$$

O valor presente para um custo operacional é obtido aplicando-se novamente o desconto exponencial com taxa ρ = 0.1, conforme equação 17 a seguir.

$$VP_{COP} = \sum_{i=1}^{T} C_{OP}(t_i).e^{-\rho t_i} \quad (17)$$

As próximas seções descrevem a modelagem do aproximador do simulador de reservatório identificando as entradas utilizadas para sua construção, as saídas fornecidas por ele e sua localização dentro do sistema de otimização.

3.3. Etapas para a construção do aproximador

O aproximador de função desenvolvido nesta dissertação visa a substituição de um simulador de reservatórios petrolíferos (Figura 11). O percentual de substituição é determinado por uma política que será abordada mais adiante.

PUC-Rio - Certificação Digital Nº 0521364/CA

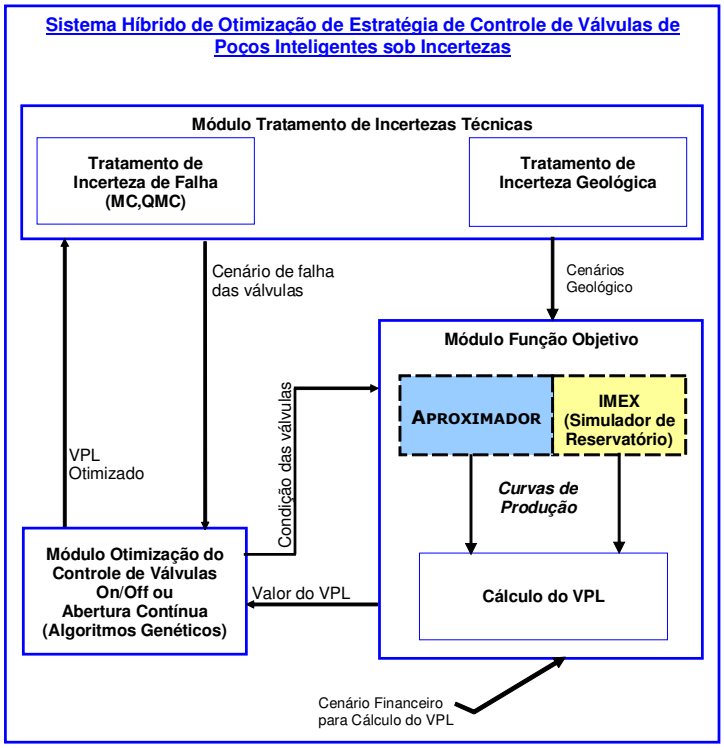

Figura 11 – Sistema de otimização com a utilização do aproximador.

Sendo assim, a partir das mesmas entradas fornecidas ao simulador, nesse caso as condições das válvulas, o aproximador fornece as curvas de produção diária de água, gás e óleo durante todo o período determinado (Figura 12), o que possibilita o cálculo do VPL, utilizado como instrumento de avaliação no sistema de otimização.

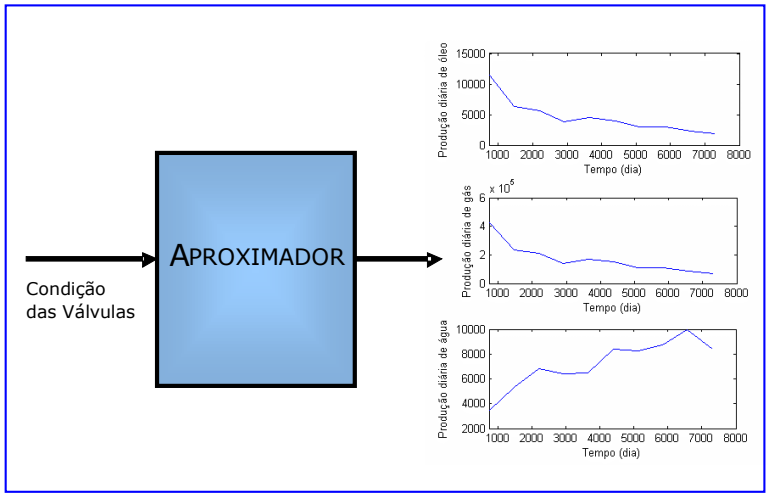

Figura 12 – Entradas e saídas do aproximador.

PUC-Rio - Certificação Digital Nº 0521364/CA

Como o aproximador deve fornecer as curvas para todo o período determinado, e como valores passados das próprias curvas são utilizados na entrada do modelo, o mesmo deve possuir a característica *multi-step*[4], onde os pontos previstos da série servem para prever pontos posteriores.

Para a construção do aproximador utilizando técnicas de inteligência computacional, os principais desafios estão relacionados ao planejamento para obtenção das amostras de treinamento dos modelos, onde o custo da utilização do simulador deve ser levado em consideração; ao pré-processamento destas amostras, com objetivo de fornecer aos modelos aproximadores as amostras no formato que os favoreçam; à modelagem da técnica que se deseja utilizar (ajuste dos parâmetros dos modelos); à determinação de uma política de substituição do simulador pelo aproximador, visto que esta é normalmente realizada de forma parcial. Na Figura 13, pode-se observar estas etapas.

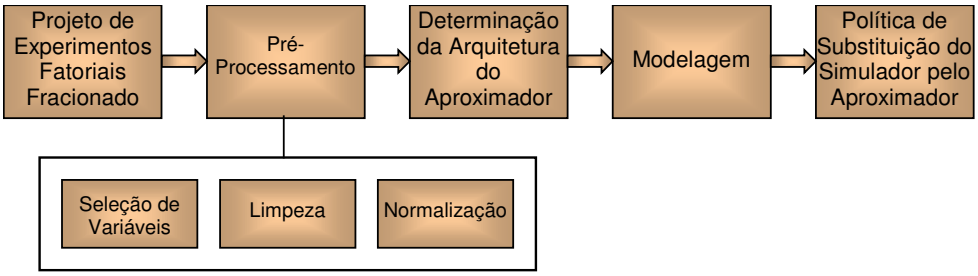

Figura 13 – Etapas para a construção do aproximador.

Nas próximas seções são detalhadas cada uma das etapas da Figura 13.

3.4. Aquisição e Pré-processamento dos Dados de Treinamento

O primeiro desafio na construção do aproximador está na aquisição e preparação dos dados que servirão para o treinamento dos modelos que irão compor o aproximador. Com isso, algumas etapas para obtenção dos dados devem ser cumpridas para melhorar a capacidade de aprendizado dos modelos:

a. Definir a forma como os dados serão obtidos;
b. Definir quais variáveis influenciam no comportamento do problema que se deseja modelar;

[4] Abordagem adotada para longos períodos de previsão. Inicialmente é feita a previsão um passo à frente, e esta previsão é introduzida entre as observações passadas, compondo um novo conjunto sobre o qual será obtida a previsão subseqüente (Ferreira, 2004)

PUC-Rio - Certificação Digital Nº 0521364/CA

c. Limpar os dados;
d. Transformar os dados.

3.4.1. Aquisição de Dados de Treinamento

Para a construção do aproximador, os dados foram obtidos usando o próprio simulador que se quer substituir. Como o custo computacional da utilização do simulador é alto, uma técnica que vise minimizar a quantidade de amostras é altamente recomendada. Deste modo, nesta dissertação utilizou-se projeto de experimentos fatoriais fracionado, conforme será abordado mais adiante.

3.4.2. Seleção de Variáveis de Treinamento

A seleção de variáveis é uma preocupação sempre presente na modelagem de sistemas quando a quantidade de variáveis de entrada é potencialmente grande. A diminuição da quantidade das variáveis que serão utilizadas para estimação dos modelos é realizada identificando e descartando aquelas variáveis que são redundantes ou que têm baixa relevância. A seleção de variáveis propicia melhoria na qualidade das inferências e a na capacidade generalização do modelo.

Neste trabalho, a seleção de variáveis se dá em função da disponibilidade de variáveis fornecida pelo simulador, pelo conhecimento de especialistas e pela análise da influência das variáveis de entrada sobre a saída.

Naturalmente, pela característica do sistema de otimização em questão, a condição das válvulas para o período de predição se apresenta como a principal variável de influência sobre a saída. Além disto, como o aproximador deverá inferir as curvas de produção de água, gás e óleo para todo o período determinado, as outras variáveis candidatas são os pontos conhecidos (anteriores) da série, os quais podem trazer informação para o próximo ponto que se deseja prever. A influência destas variáveis sobre a saída pode ser verificada através de alguma técnica matemática, como o estimador por mínimos quadrados (LSE - *Least Squares Estimator*).

O LSE é um método que busca expressar o comportamento das variações da saída (y) em função das variações das variáveis de entrada X, através da relação $\Delta y = b_1.\Delta x_1 + b_2.\Delta x_2 + b_3.\Delta x_3 + ... + b_n.\Delta x_n$. Desta relação pode-se dizer

PUC-Rio - Certificação Digital Nº 0521364/CA

que cada parâmetro b_i representa a importância da i-ésima variável de entrada com respeito à saída (Contreras, 2002; Contreras, 2005). O cálculo do coeficientes (b_i) é feito através de algoritmo de mínimos quadrados (Chung, 2000).

Na Figura 14, são exibidos os resultados obtidos a partir do LSE para se identificar as variáveis que mais influenciavam na predição de cada uma das curvas de produção. Apenas as variáveis com valores mais significativos foram exibidas.

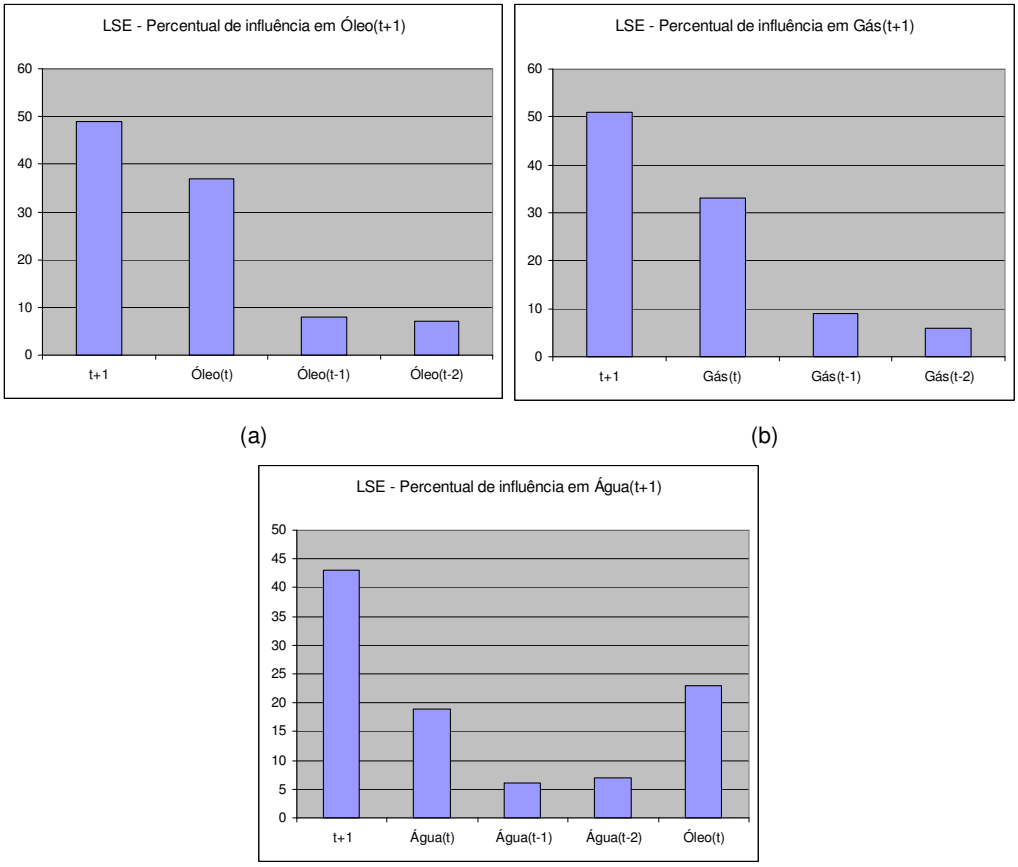

(a) (b)

(c)

Figura 14 – LSE. (a) óleo; (b) gás; (c) água.

Para a curva de óleo, percebe-se que além da variável $t+1$ (momento em que se deseja prever), a produção no período anterior aparece com significativo percentual de influência sobre a saída (produção de óleo em $t+1$). O mesmo pode-se observar para a curva de gás. A curva de água demonstra ser bastante influenciada pela produção de óleo no período anterior.

PUC-Rio - Certificação Digital Nº 0521364/CA

3.4.3.
Limpeza dos Dados de Treinamento

A limpeza dos dados que são utilizados para treinamento visa determinar e tratar as anomalias nos mesmos, objetivando melhorar a sua qualidade. A execução desta etapa é muito comum nos dados que servem para utilização de modelos de inferência.

Normalmente o processo de limpeza de dados é executado com o envolvimento de algum especialista, uma vez que a detecção e correção de anomalias requerem conhecimento especializado. Além disto, diversas técnicas estatísticas podem ser utilizadas para apoiar esta etapa.

Como a obtenção dos dados foi realizada de maneira controlada e através do simulador de reservatórios, evitando simulações duplicadas e produzindo dados confiáveis, a execução desta etapa não foi necessária neste trabalho.

PUC-Rio - Certificação Digital Nº 0521364/CA

3.4.4.
Transformação dos Dados de Treinamento

De modo geral, a transformação de dados envolve a aplicação de alguma técnica de transformação aos valores das variáveis selecionadas, buscando obter os dados em forma mais apropriada para sua utilização na modelagem, maximizando a informação. Entre as transformações mais comuns, está a normalização, que objetiva homogeneizar a variabilidade das variáveis que fazem parte do modelo.

Neste trabalho as variáveis foram normalizadas pela faixa de variação, como segue:

$$X_n = \frac{X_R - \min}{\max - \min} \qquad (18)$$

onde:

X_R é o valor original para a variável,

X_n é o valor normalizado para a variável e

max é o maior valor e min o menor valor para a variável

3.5.
Arquitetura do Aproximador de Simulador de Reservatório

O aproximador de simulador de reservatório, na realidade, é composto por três aproximadores, cada um deles dedicado a aproximar cada uma das curvas de produção.

Na Figura 15 são apresentados os detalhes da modelagem obtida de cada um dos módulos do aproximador. Como a informação da produção de óleo apareceu de forma relevante no LSE, o modelo aproximador de água foi avaliado também com esta variável.

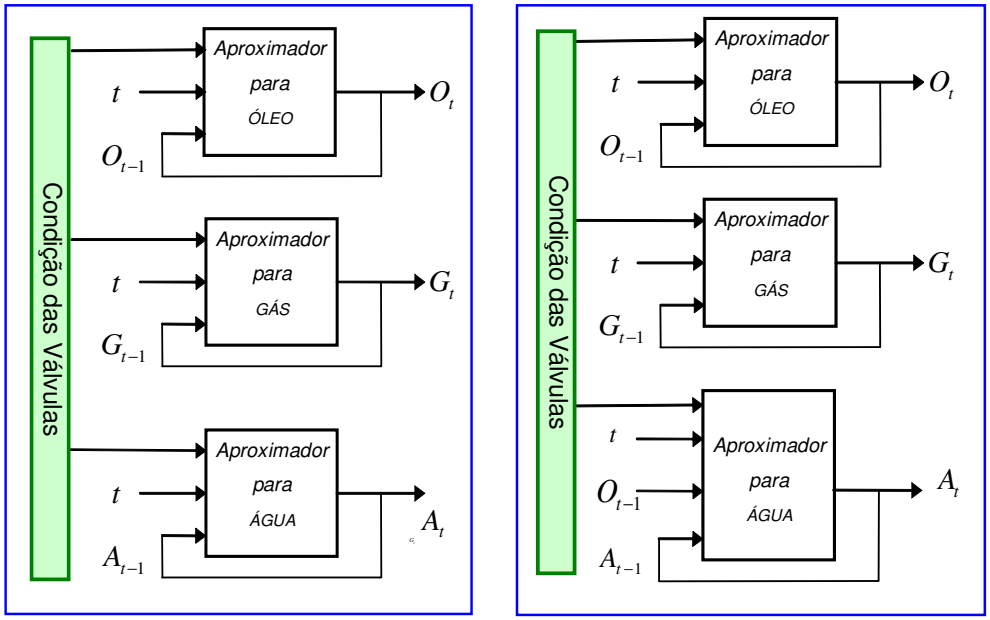

Figura 15 – Detalhe da modelagem do aproximador. (a) Predição da curva de água sem óleo. (b) Predição da curva de água com óleo.

A diferença da figura da esquerda para a da direita está simplesmente na utilização do óleo para o módulo de predição de água.

3.5.1. Determinação do Modelo para Construção do Aproximador

Conforme mencionada anteriormente, a escolha de redes neurais artificiais e o modelo neuro-fuzzy ANFIS para a construção dos aproximadores se deu pelo conjunto de características inerentes a esses modelos: ambos se caracterizam por serem aproximadores universais de funções, podendo resolver, com precisão arbitrária, qualquer problema de aproximação de funções contínuas (Hornik, 1989) (Haykin, 2001) (Cybenko, 1989) (Azevedo, 2000).

Além disso, esses modelos se destacam pela habilidade de aprendizado e capacidade de generalização, tendo mostrado serem capazes de identificar e assimilar as características mais marcantes das séries, como sazonalidade,

PUC-Rio - Certificação Digital Nº 0521364/CA

periodicidade, tendências, entre outras, sem necessitar do laborioso processo da formulação teórica, imprescindível em processos estatísticos (Rumelhart, 1986).

Acrescenta-se às redes neurais artificiais o atributo do modelo ser não-paramétrico dirigido aos dados que não necessitam suposição prévia de como foram gerados (Haykin, 2001). As redes neurais artificiais aprendem dos exemplos e capturam as características das séries, tanto as desconhecidas quanto as difíceis de serem descritas. Característica extensível ao modelo ANFIS.

Um problema relacionado ao ANFIS em particular está na sua escalabilidade. A quantidade de entradas, associada à quantidade de funções de pertinência, em um modelo ANFIS, determina a quantidade de regras e de parâmetros que o modelo deve ajustar para tratar o problema. Para exemplificar, no estudo de caso do próximo capítulo com o campo sintético de apenas 3 válvulas, o modelo do aproximador da produção de óleo tem 5 entradas (3 sobre as condições das válvulas, o tempo t e a produção de óleo no tempo anterior O_{t-1}). Neste caso, o modelo ANFIS é composto de 243 regras (3^5). Para cenários mais complexos, o problema, conhecido como *curse of dimensionality* ou explosão combinatória da base de regras, toma proporções que podem inviabilizar a utilização do ANFIS.

Para tratar esta questão, nos estudos de casos que envolveram um número grande de variáveis de entrada, procedeu-se o agrupamento ("clusterização") do conjunto de dados de entrada, reduzindo o particionamento do espaço de entrada e, conseqüentemente, o número de regras a serem geradas. O próprio *Fuzzy Logic Toolbox™* do *Matlab®*, utilizado para o desenvolvimento dos modelos ANFIS, disponibiliza diferentes funções para o agrupamento dos dados de treinamento. O método utilizado foi o *Subtractive Clustering* (Chiu, 1994), que possibilita determinar, a partir do conjunto de dados de treinamento, a quantidade de clusters e seus centros.

3.6. Aquisição dos Dados de Treinamento Utilizando Projeto de Experimentos Fatoriais Fracionado

As amostras utilizadas para a construção dos aproximadores, neste caso particular, precisam ser obtidas através do uso do próprio simulador. Isto remete à dificuldade já observada, relacionada ao custo computacional do uso do simulador. Assim, se faz necessária a utilização de alguma técnica que vise

PUC-Rio - Certificação Digital Nº 0521364/CA

minimizar a quantidade de amostras para a construção dos aproximadores, sem que se perca qualidade, ou seja, as amostras selecionadas deve ser representativas do espaço amostral. Diante desta necessidade, utilizou-se neste trabalho a técnica de Projeto de Experimentos Fatoriais Fracionado, descrito no Capitulo 2 desta dissertação.

O primeiro passo na determinação do projeto de experimentos é identificar os fatores que serão estudados e em quais níveis. No problema de otimização, onde este trabalho está inserido, os fatores críticos são representados pelas válvulas, e os níveis desses fatores são representados pelos possíveis estágios de abertura das mesmas.

Entretanto, a quantidade de níveis de cada fator influencia diretamente na quantidade de amostras necessárias determinadas pela técnica, como pode-se observar na equação 1.

Como a definição ótima dos níveis de abertura das válvulas não é conhecida (por isso a necessidade de um processo de otimização), adotou-se quatro níveis de aberturas distanciados uniformemente, independente do reservatório estudado. A escolha da quantidade de níveis se dá em função do compromisso entre obter maior precisão na predição, determinada pela qualidade das amostras, e o custo da amostragem. Assim, para cada uma das válvulas existentes no problema, assumiu-se a necessidade dos níveis de tratamento indicados na Tabela 5.

Valor submetido ao simulador	Condição representada
0	Válvula totalmente fechada
0,3	Válvula 30% aberta
0,7	Válvula 70% aberta
1	Válvula totalmente aberta

Tabela 5 – Níveis de abertura das válvulas para o projeto de experimentos.

Como descrito no Capítulo 2 desta dissertação, a determinação da quantidade de níveis amostrados, a quantidade de fatores e a taxa de fracionamento determinam a quantidade de observações mínimas demandadas pela técnica de Projeto de Experimentos Fatoriais Fracionado.

Deste modo, utilizando-se os quatro níveis descritos, obtém-se a quantidade de observações determinada pela equação 19.

PUC-Rio - Certificação Digital Nº 0521364/CA

$$q = 4^{k-p} \quad (19)$$

onde:

q é a quantidade de execuções (observações) a realizar,

k é a quantidade de fatores e

p é o fator de fracionamento

De acordo com objetivo da obtenção das amostras, pode-se proceder o fracionamento máximo, de forma que se possa perceber apenas a influência dos fatores principais, abrindo mão do entendimento da diferenciação da influência dos fatores principais e das interações entre fatores.

Desta forma, baseando-se na técnica do confundimento foi possível realizar o fracionamento máximo, ou seja, no mínimo $q > k$.

3.6.1. Determinação da Quantidade de Simulações Necessárias para Treinamento

A partir da definição de quais fatores são importantes para o modelo, de seus níveis de amostragem e das concessões que serão realizadas relacionadas à técnica de confundimento, é possível determinar a quantidade de simulações necessárias para o treinamento do modelo.

Três cenários de quantidade de válvulas foram estudados. O primeiro em um reservatório sintético com três válvulas. Os demais em um reservatório real, com cenário de seis válvulas e outro com nove válvulas.

Em todos os casos, de acordo com os estudos de caso apresentados em Faletti (2007), a reprogramação das válvulas é bienal. Assim, as variáveis (fatores) de entrada para o simulador, que serão as mesmas para o aproximador, são definidas pela quantidade de válvulas multiplicada pela quantidade de reprogramações das mesmas. Ou seja, a cada período de dois anos, tem-se uma nova condição para o conjunto de válvulas.

Na Tabela 6, tem-se a comparação da quantidade de experimentos exigidos em um projeto de experimentos fatoriais completo e em um projeto de experimentos fatoriais fracionado, ambos com quatro níveis para cada fator, para cada um dos cenários de quantidade de válvulas utilizados. A última coluna, com a quantidade de experimentos fatoriais fracionados necessários para os quatro níveis determinados, foi construída a partir da equação 19 procedendo-se o fracionamento máximo com a técnica de confundimento apresentada no capítulo

PUC-Rio - Certificação Digital Nº 0521364/CA

2. Para exemplificar, no terceiro cenário tem-se $4^{90-86} = 4^4 = 256$ simulações necessárias.

Cenário	Quantidade de Válvulas	Quantidade de Fatores	Projeto de Experimentos Fatoriais Completo	Projeto de Experimentos Fatoriais Fracionado
1	3	30	$4^{30} \cong 10^{18}$	64
2	6	60	$4^{60} \cong 10^{36}$	128
3	9	90	$4^{90} \cong 10^{54}$	256

Tabela 6 – Quantidade de simulações necessárias para treinamento dos cenários utilizando projeto de experimentos fatoriais completo e fracionado.

3.7. Política de Substituição do Simulador

Normalmente, a substituição do simulador pelo aproximador é feita de forma parcial. Logo, uma importante decisão a se tomar durante a utilização do aproximador no processo de otimização é a política de substituição do simulador pelo aproximador. Em Tupac (2005) é proposta a utilização do simulador em taxa constante, determinada em todas as gerações. Pode-se definir outras abordagens variantes desta, como, por exemplo, determinando uma chance adaptativa de escolha entre o simulador e o aproximador.

Neste trabalho, adotou-se a estratégia de substituir o simulador pelo aproximador como em Tupac (2005), com a determinação de uma taxa constante de substituição do simulador para cada geração do processo de otimização. A decisão entre utilizar o simulador ou o aproximador se dá de forma aleatória (Figura 16).

PUC-Rio - Certificação Digital Nº 0521364/CA

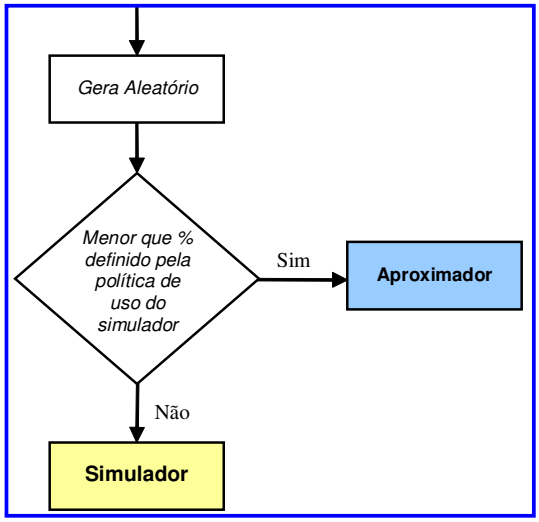

Figura 16 – Fluxograma do mecanismo da decisão de utilização do simulador ou aproximador.

Além disso, avaliou-se empiricamente o percentual de substituição do simulador de forma que se possa determinar uma política de substituição adequada. Assim, foram realizadas simulações em cenários onde, privilegiando o uso do aproximador, diminuiu-se gradativamente o fator de utilização do mesmo. A Tabela 7 mostra os cenários utilizados neste trabalho com os objetivos que se deseja alcançar para cada um dos cenários de substituição do simulador.

Substituição do simulador	Objetivos
0%	○ Obter VPL de referência ○ Custo computacional de referência.
100%	○ Erro do aproximador em relação ao VPL ○ Custo computacional do aproximador
10% 25% 50%	○ Obter melhor relação custo/ benefício

Tabela 7 – Cenários de substituição do simulador no processo de otimização.

PUC-Rio - Certificação Digital Nº 0521364/CA