

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
E INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM
CIÊNCIAS E ENGENHARIA DE PETRÓLEO

LUÍS AUGUSTO NAGASAKI COSTA

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NO PROCESSO DE AJUSTE DE HISTÓRICO

CAMPINAS

2012

Este exemplar corresponde à redação final da dissertação defendida por **Luís Augusto Nagasaki Costa** aprovada pela Comissão julgadora em 24/05/2012.



Pesquisador Dr. Célio Maschio

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
E INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM
CIÊNCIAS E ENGENHARIA DE PETRÓLEO

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NO PROCESSO DE AJUSTE DE HISTÓRICO

Autor: **Luís Augusto Nagasaki Costa**
Orientador: **Pesq. Dr. Célio Maschio**
Co-orientador: **Prof. Dr. Denis José Schiozer**

Curso: **Ciências e Engenharia de Petróleo**
Área de Concentração: **Reservatórios e Gestão**

Dissertação de mestrado acadêmico apresentada à Comissão de Pós Graduação em Ciências e Engenharia de Petróleo da Faculdade de Engenharia Mecânica e Instituto de Geociências, como requisito para a obtenção do título de Mestre em Ciências e Engenharia de Petróleo.

Campinas, 2012
SP – Brasil.

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

C823a Costa, Luís Augusto Nagasaki
Aplicação de redes neurais artificiais no processo de
ajuste de histórico / Luís Augusto Nagasaki Costa. --
Campinas, SP: [s.n.], 2012.

Orientador: Célio Maschio.
Coorientador: Denis José Schiozer.
Dissertação de Mestrado - Universidade Estadual de
Campinas, Faculdade de Engenharia Mecânica.

1. Inteligência artificial. 2. Redes neurais. 3.
Algoritmos genéticos. 4. Engenharia de reservatório. 5.
Amostragem. I. Maschio, Célio. II. Schiozer, Denis
José. III. Universidade Estadual de Campinas.
Faculdade de Engenharia Mecânica. IV. Título.

Título em Inglês: Application of artificial neural networks in the history
matching process

Palavras-chave em Inglês: Artificial intelligence, Artificial neural networks,
Genetic algorithms, Oil reservoir engineering,
Sampling

Área de concentração: Reservatórios e Gestão

Titulação: Mestre em Ciências e Engenharia de Petróleo

Banca examinadora: Dirceu Bampi, Alexandre Campana Vidal

Data da defesa: 24-05-2012

Programa de Pós Graduação: Engenharia Mecânica

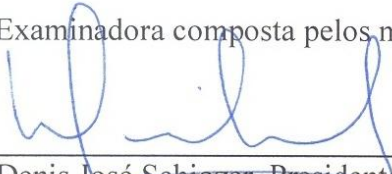
UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
E INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM
CIÊNCIAS E ENGENHARIA DE PETRÓLEO

DISSERTAÇÃO DE MESTRADO ACADÊMICO

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NO PROCESSO DE AJUSTE DE HISTÓRICO

Autor: **Luís Augusto Nagasaki Costa**
Orientador: **Pesq. Dr. Célio Maschio**
Co-orientador: **Prof. Dr. Denis José Schiozer**

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:



Prof. Dr. Denis José Schiozer, Presidente
DEP/FEM/UNICAMP



Prof. Dr. Alexandre Campana Vidal
IGE/UNICAMP



Engenheiro Dr. Dirceu Bampi
PETROBRAS

Campinas, 24 de maio de 2012.

DEDICATÓRIA

Dedico esse trabalho aos meus pais Gilvan e Eunice e a minha namorada Marcela, que me incentivaram a realizar o curso de mestrado e com seus exemplos de persistência e espírito batalhadores me serviram de modelo em toda a minha caminhada.

AGRADECIMENTOS

Ao meu orientador, Pesq. Dr. Célio Maschio e ao meu co-orientador Prof. Dr. Denis José Schiozer pela competência, paciência e generosidade e por acreditarem neste trabalho.

Aos meus colegas de trabalho aos quais convivi durante o mestrado e proporcionaram um bom ambiente para estudos e desenvolvimento.

Aos pesquisadores, colaboradores e funcionários do UNISIM, pelo suporte e colaboração.

Aos professores e funcionários do DEP pela ajuda direta ou indireta na realização deste trabalho.

À PETROBRAS pela concessão de bolsa de estudo, ao CEPETRO (Centro de estudos de Petróleo) e ao UNISIM pelo suporte financeiro.

Aos meus pais Gilvan e Eunice, e minha namorada Marcela, pelo constante incentivo e apoio.

A todos os meus amigos; os de Assis, os de Campinas e aos que conheci em Ilha Solteira, que direta ou indiretamente me proporcionaram bons momentos durante o mestrado.

“Ninguém pode fazer você se sentir inferior sem o seu consentimento.”
*“Faça o que o seu coração dizer que está certo – você será criticado pela sua atitude
seja ela qual for.”*
Eleanor Roosevelt

RESUMO

COSTA, Luís Augusto Nagasaki. *Aplicação de Redes Neurais Artificiais no Processo de Ajuste de Histórico*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2012. 145 p. Dissertação de Mestrado.

O processo de ajuste de histórico consiste em uma das etapas mais importantes envolvendo estudos de reservatórios, pois com o modelo de simulação ajustado pode-se realizar previsões de produção com maior confiabilidade e avaliar diferentes estratégias de produção de forma a obter maior recuperação final com menor custo. Porém, esse processo traz consigo diversas dificuldades, sendo uma delas a não unicidade das soluções, ou seja, vários modelos podem igualmente proporcionar resultados satisfatórios dependendo do objetivo de estudo. Além disso, o reservatório pode possuir diversas heterogeneidades e não linearidades entre atributos do reservatório e valores de produção e pressão, o que também contribui para aumentar a complexidade do problema. Através dos diversos trabalhos já publicados comprovou-se que cada caso possui diferentes características, de forma que uma metodologia aplicada com sucesso a um determinado caso pode não ser aplicável a outro e vice e versa. Dessa maneira, estudos nessa área devem ser realizados e atualizados constantemente.

O grande desafio em problemas envolvendo ajuste de histórico está relacionado à redução do número de simulações necessárias para alcançar ajustes satisfatórios de acordo com o objetivo proposto. Entre as diversas técnicas que podem ser encontradas na literatura para tal propósito, uma que chama atenção é a aplicação de metamodelos gerados através de Redes Neurais Artificiais. Os metamodelos, uma vez gerados, são capazes de fornecer os resultados muito mais rápido que o simulador, pois se tratam de modelos simplificados. As RNA, por sua vez, são estruturas capazes de captar com eficiência as não linearidades entre entradas e saídas de um dado problema. Assim, os metamodelos gerados por RNA possuem características que os tornam

promissores para serem utilizados como substitutos do simulador em etapas do ajuste que demandam maior esforço computacional.

Deste modo, nesse trabalho foi avaliada a aplicação de metamodelos gerados por RNA no processo de ajuste de histórico, principalmente no que se refere à influência que a qualidade do conjunto de entrada exerce sobre o desempenho do metamodelo gerado e com relação à confiabilidade da utilização do metamodelo como substituto do simulador para casos práticos, com características mais próximas da realidade. Os resultados mostraram que a ferramenta, apesar dos erros envolvidos, por se tratar de um modelo simplificado, pode ser utilizada como ferramenta auxiliar ao simulador de escoamento no processo de ajuste de histórico. Não é recomendada a sua utilização como substituta do simulador no processo inteiro, porém, pode contribuir em etapas do processo que não requerem grande precisão dos resultados. Para a confiabilidade dos resultados, é necessário validar a resposta (encontrada por meio do metamodelo) usando o simulador de reservatórios.

Palavras-Chave

Ajuste de histórico, inteligência artificial, redes neurais artificiais, simulação numérica de reservatórios, algoritmo genético, técnicas de amostragem, otimização.

ABSTRACT

COSTA, Luís Augusto Nagasaki. *Application of Artificial Neural Networks in the History Matching Process*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2012. 145 p. Dissertação de Mestrado.

The history matching process is one of the most important stages involving studies of reservoirs, because with the adjusted reservoir model, the production forecasts can be done with higher reliability and different production strategies can be evaluated to obtain greater final recovery associated with less costs. However, this process have several problems associated, one being the multiple solution, meaning that different models provide satisfactory results, depending on the objective of the study. Furthermore, the reservoir in study can have different heterogeneities and nonlinearities between reservoir attributes and values of production and pressure, which also contributes to increase the complexity. Various published work showed that each case has different characteristics, so that a methodology that was applied successfully in one case, may not be efficient in another and vice-versa. Thus, studies in this area should be developed and updated constantly.

The great challenge in problems involving history matching is related to reducing the number of simulations required to achieve satisfactory adjustments in accordance with the proposed objective. Among several procedures for this purpose, the application of proxy models generated through artificial neural networks (ANN) can be cited. The proxy models, once generated, are able to calculate the results much faster than the simulator due to the fact that they are simplified models. The ANN are structures capable of efficiently capture nonlinearities between inputs and outputs of a given problem. Thus, these proxy models have characteristics that make them promising for use as substitute of simulator in stages that require greater computational effort.

Thereby, in this work the application of proxy models generated through ANN in the history matching process was evaluated, primarily regarding to the influence of the input quality in the proxy performance and the reliability of the use of proxy models as substitutes of the

simulator in a realistic reservoir model. The results showed that the tool, despite the errors involved, because it is simplified model, can be used as auxiliary tool to the flow simulator in the process of history matching. It is not recommended to use as a substitute in the whole process, however, can contribute in the process stages that do not require great precision. For reliable results, it is necessary to validate the response (found through the proxy) using the reservoir simulator.

Key Words

History matching, artificial intelligence, artificial neural networks, reservoir numeric simulation, genetic algorithm, sampling techniques, optimization.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Motivação	5
1.2	Objetivos	5
1.3	Organização da Dissertação	6
2	CONCEITOS E FUNDAMENTAÇÃO TEÓRICA	9
2.1	Ajuste de histórico de produção.....	9
2.1.1	Etapas do ajuste	11
2.1.2	Complexidade do ajuste	12
2.1.3	Tipos de ajuste: manual, automático e assistido.....	14
2.1.4	Qualidade do ajuste	15
2.1.5	Otimização dos valores dos atributos do reservatório.....	17
2.1.6	Utilização de metamodelos gerados por redes neurais artificiais no processo de ajuste de histórico	18
2.2	Redes neurais artificiais	18
2.2.1	Redes neurais biológicas	19
2.2.2	Neurônio artificial.....	20
2.2.3	Função de transferência (de ativação)	21
2.2.4	Arquitetura.....	21
2.2.5	Escolha da arquitetura da rede.....	23
2.2.6	Treinamento de redes neurais artificiais.....	24
2.2.6.1	Algoritmo de retro propagação (<i>backpropagation</i>).....	25

2.2.6.2	Variações do algoritmo de Retro propagação	26
2.2.6.3	Capacidade de generalização de uma rede neural artificial.....	26
2.3	Algoritmo genético	27
2.4	Técnicas de amostragem	31
2.4.1	Box Behnken	32
2.4.2	Hipercubo Latino	35
2.4.3	Sequência de Sobol.....	36
2.5	Comentário sobre as técnicas de amostragem	37
3	REVISÃO BIBLIOGRÁFICA.....	39
3.1	Ajuste de histórico	39
3.2	Aplicação de redes neurais artificiais e metamodelos	41
3.3	Metamodelos gerados por redes neurais artificiais no processo de ajuste de histórico	42
4	METODOLOGIA	47
4.1	Metodologia geral do trabalho	47
4.2	Metodologia específica - procedimento de ajuste.....	49
4.2.1	Treinamento das redes neurais artificiais	50
4.2.2	Aplicação de metamodelos no processo de ajuste de histórico	51
5	APLICAÇÃO	53
5.1	Casos analíticos.....	53
5.1.1	Premissas e considerações	53
5.1.2	Caso 1A	54
5.1.3	Caso 1B	55
5.1.4	Caso 1C	56

5.1.5	Caso 1D	56
5.2	Casos de reservatório	57
5.2.1	Premissas e considerações	57
5.2.2	Reservatório utilizado	58
5.2.3	Caso 2A	59
5.2.4	Caso 2B	59
5.3	Geração dos conjuntos de entrada para treinamento	60
5.4	Treinamento das redes neurais artificiais	65
5.5	Otimização	66
6	RESULTADOS E DISCUSSÃO	69
6.1	Caso 1A	69
6.1.1	Passo 1: Definição do conjunto de treinamento	69
6.1.2	Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados	70
6.1.3	Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado	72
6.2	Caso 1B	73
6.2.1	Passo 1: Definição do conjunto de treinamento	73
6.2.2	Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados	75
6.2.3	Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado	78
6.2.4	Passo 4: Retreinamento	78
6.3	Caso 1C	81

6.3.1	Passo 1: Definição do conjunto de treinamento	81
6.3.2	Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados.....	83
6.3.3	Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado	87
6.4	Caso 1D.....	90
6.4.1	Passo 1: Definição do conjunto de treinamento	90
6.4.2	Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados.....	91
6.4.3	Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado	94
6.5	Comentários dos casos analíticos	96
6.6	Caso 2A.....	99
6.6.1	Passo 1: Definição do conjunto de treinamento	99
6.6.2	Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados.....	102
6.6.3	Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado	104
6.6.4	Passo 4: Retreinamento	106
6.7	Caso 2B.....	110
6.7.1	Análise de sensibilidade	110
6.7.2	Passo 1: Definição do conjunto de treinamento	112
6.7.3	Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados.....	114

6.7.4	Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado	119
6.7.5	Passo 4: Retreinamento	123
6.8	Comentários gerais dos casos de reservatório.	127
7	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS.....	131
	REFERÊNCIAS BIBLIOGRÁFICAS.....	137
	APÊNDICE.....	143
I.	Capacidade de extrapolação da rede neural artificial – Caso 2A.....	143
II.	Melhor configuração de rede neural artificial obtida – Caso 2B	144

LISTA DE FIGURAS

Figura 2.1 – Fluxograma básico a ser seguido para realização do ajuste de histórico. (ERTEKIN <i>et al.</i> , 2001, p.351).	11
Figura 2.2 – Exemplo da não unicidade (múltiplas soluções) no problema de ajuste.	14
Figura 2.3 – Comparação do corte de água simulado com o histórico (Modificação de ERTEKIN <i>et al.</i> , 2001, p.357).	16
Figura 2.4 – Esquema simplificado de um neurônio biológico.	19
Figura 2.5 – Esquema básico de neurônio artificial (HAGAN <i>et al.</i> , 1996, p.2-3).	20
Figura 2.6 – Função de transferência do tipo linear (a) e tangente hiperbólica (b).	21
Figura 2.7 – Ilustração de uma rede neural de 3 camadas (HAGAN <i>et al.</i> , 1996, p.2-11). ..	22
Figura 2.8 – Rede multicamadas na forma abreviada (HAGAN <i>et al.</i> , 1996, p.2-12).	23
Figura 2.9 – Fluxograma básico do algoritmo de RP.	25
Figura 2.10 – Estrutura básica de um AGC.	28
Figura 2.11 – Exemplo de um indivíduo formado por um vetor de bits (a), ilustração dos processos de recombinação (b) e mutação (c).	29
Figura 2.12 – Ilustração do algoritmo de Roleta Russa.	29
Figura 2.13 – Método de BB na forma gráfica para 3 fatores, discretizados em 3 níveis (FERREIRA <i>et al.</i> , 2007, p.183).	34
Figura 2.14 – Exemplo de discretização de uma distribuição normal em 7 intervalos. (MASCHIO <i>et al.</i> , 2009, p.3)	35
Figura 2.15 - Figura ilustrativa da amostragem por HL, para distribuição normal (a) e uniforme (b).	36
Figura 2.16 – Exemplo de amostragem pela Sequência de Sobol.	37
Figura 3.1 – Exemplo do indicador de qualidade de ajuste com relação ao Caso Base.	44

Figura 4.1 - Fluxograma descrevendo as etapas utilizadas para realização da metodologia geral do trabalho.	47
Figura 4.2 – Fluxograma que descreve os passos seguidos pelo procedimento de ajuste adotado nesse trabalho.	49
Figura 5.1 – Superfície de resposta para o Caso 1A.	54
Figura 5.2 – Superfície de resposta para o Caso 1B.	55
Figura 5.3 – Superfície de resposta para o Caso 1C.	56
Figura 5.4 – Superfície de resposta para o Caso 1D.	57
Figura 5.5 - Modelo de reservatório (permeabilidade horizontal – md).	58
Figura 6.1 – Amostragem no espaço do conjunto de treinamento de 25 pontos; HL (a) e SS (b) – Caso 1A.	70
Figura 6.2 – Superfícies de resposta e conjunto de teste, para os metamodelos gerados com HL25 (a) e HL50 (b) – Caso 1A. Pontos em azul: erro médio menor que 1% e pontos em vermelho: erro médio maior ou igual a 1%.	71
Figura 6.3 – Visualização dos erros ponto a ponto para os metamodelos gerados com HL25 (a) e HL50 (b) pontos – Caso 1A.	72
Figura 6.4 – Amostras de 25 pontos, do HL (a) e da SS (b) para treinamento – Caso 1B.	74
Figura 6.5 - Amostras de 50 pontos, do HL (a) e da SS (b) para treinamento – Caso 1B.	74
Figura 6.6 – Superfícies de resposta dos metamodelos gerados com 25 pontos do HL (a) e da SS (b) – Caso 1B.	75
Figura 6.7 - Superfícies de resposta dos metamodelos gerados com HL25 (a), HL50 (b), HL100 (c) pontos e da função analítica (d) – Caso 1B.	77
Figura 6.8 – Conjunto de treinamento e novos limites (a) e superfície de resposta do metamodelo gerado (b), relativos ao retreinamento – Caso 1B.	79
Figura 6.9 - Conjunto de treinamento para HL25 (a) e SS25 (b) - Caso 1C.	81

Figura 6.10 – Conjunto de treinamento para HL50 (a) e SS50 (b) - Caso 1C.	82
Figura 6.11 - Superfícies de resposta dos metamodelos gerados com HL25 (a) e SS25 (b) pontos - Caso 1C.	83
Figura 6.12 - Superfícies de resposta dos metamodelos gerados com HL50 (a) e SS50 (b) pontos - Caso 1C.	84
Figura 6.13 - Superfícies de resposta dos metamodelos gerados com HL100 (a) e SS100 (b) pontos - Caso 1C.	85
Figura 6.14 - Superfícies de resposta dos metamodelos gerados com HL25 (a), HL50 (b), HL100 (c) pontos e da função analítica (d) – Caso 1C.	86
Figura 6.15 - Mínimos globais, representados pelos pontos em azul (a); e critério de vizinhança adotado para identificação de mínimos de interesse (b) – Caso 1C.....	88
Figura 6.16 – Conjunto de treinamento para HL25 (a) e SS25 (b) pontos – Caso 1D.	91
Figura 6.17 - Superfícies de resposta dos metamodelos gerados com HL25 (a) e SS25 (b) pontos - Caso 1D.	92
Figura 6.18 - Superfícies de resposta dos metamodelos gerados com HL25 (a), HL50 (b), HL100 (c) pontos e da função analítica (d) – Caso 1D.	93
Figura 6.19 – Conjunto de treinamento de HL100 (a) e SS100 (b) pontos – Caso 1D.....	95
Figura 6.20 – Pontos de treinamento, relativos aos atributos porosidade da fácies 2 e transmissibilidade da falha 3 para os conjuntos HL25 (a) e HL50 (b) pontos - Caso 2A.....	100
Figura 6.21 – Histograma dos valores de saída para os conjuntos de treinamento HL25 e HL50 pontos – Caso 2A.	102
Figura 6.22 – Gráfico de dispersão (<i>crossplot</i>) entre saída do simulador e saída do metamodelo, gerado com HL25 (a), HL50 (b) e HL100 (c) – Caso 2A; pontos em azul: pontos de treinamento e pontos em vermelho: pontos de teste.....	103
Figura 6.23 – Curva de produção de água do campo do Caso base, histórico e metamodelos gerados com HL25, HL50 e HL100 pontos – Caso 2A.....	105

Figura 6.24 - Curva de produção de água do campo do Caso base, histórico e metamodelos gerados com HL50, HL100 pontos e HL50 após retreinamento – Caso 2A.	108
Figura 6.25 – Análise de sensibilidade para o afastamento da produção de água do poço PROD4 (a) e média aritmética (b) – Caso 2B.	110
Figura 6.26 – Gráfico de dispersão dos pontos de treinamento entre os atributos Kz2 e Kr2, relativo aos conjuntos HL100 (a) e HL250 (b) pontos – Caso 2B.	112
Figura 6.27 - Gráficos de dispersão dos pontos de treinamento entre os atributos Kz2 e Kr2, referente aos conjuntos HL396 (a) e BB396 (b) – Caso 2B.	113
Figura 6.28 - Gráficos de dispersão (<i>crossplot</i>) para o poço PROD2 – PROD_AS – Caso 2B.	116
Figura 6.29 - Gráficos de dispersão (<i>crossplot</i>) para o poço PROD3 – PROD_AS – Caso 2B.	117
Figura 6.30 – Coeficiente de correlação linear em gráfico de barras; grupo de barras da esquerda: resultados do treinamento; grupo de barras da direita: resultados do teste – Caso 2B.	118
Figura 6.31 – Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD1 (a), PROD2 (b), PROD3 (c) e PROD4 (d) – PROD_AS – Caso 2B.	121
Figura 6.32 - Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD5 (a), PROD6 (b), PROD7 (c) e PROD8 (d) – PROD_AS – Caso 2B.	122
Figura 6.33 – Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD1 (a), PROD2 (b), PROD3 (b) e PROD4 (b) – retreinamento – Caso 2B.	125
Figura 6.34 – Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD5 (a), PROD6 (b), PROD7 (b) e PROD8 (b) – retreinamento – Caso 2B.	126

LISTA DE TABELAS

Tabela 2.1 – Método de BB na forma matricial para 3 fatores, discretizados em 3 níveis..	33
Tabela 5.1 – Atributos incertos para o caso 2A.	59
Tabela 5.2 – Atributos incertos para Caso 2B.	60
Tabela 5.3 – Atributos que mais influenciam os poços.	62
Tabela 5.4 – Principais parâmetros utilizados pelo AG.	67
Tabela 6.1 – Coeficientes de correlação linear, erro médio e mínimos determinados através da otimização utilizando os metamodelos - Caso 1A.	73
Tabela 6.2 – Coeficientes de correlação linear, erro médio e mínimos determinados através da otimização utilizando os metamodelos - Caso 1B.	78
Tabela 6.3 – Definição dos novos limites para retreinamento – Caso 1B.	79
Tabela 6.4 - Resultados obtidos com o retreinamento – Caso 1B.	80
Tabela 6.5 - Coeficientes de correlação linear, erro médio e mínimos determinados através da otimização utilizando os metamodelos - Caso 1C.	87
Tabela 6.6 - Mínimos de interesse - Caso 1C.	89
Tabela 6.7 - Coeficientes de correlação linear, erro médio e mínimos determinados através da otimização utilizando os metamodelos - Caso 1D.	94
Tabela 6.8 – Frequência de ocorrência dos valores de saída para os conjuntos de treinamento, HL25, HL50 e HL100 pontos – Caso 2A.	101
Tabela 6.9 – Correlação linear entre saída do simulador e do metamodelo (afastamento da produção de água, do modelo de simulação com relação ao histórico), relativos aos conjuntos de treino e teste – Caso 2A.	104
Tabela 6.10 – Afastamento obtido com o mínimo encontrado na otimização, quando simulado com o metamodelo e com o simulador – Caso 2A.	104

Tabela 6.11 – Definição dos atributos para novo treinamento – Caso 2A.....	107
Tabela 6.12 – Coeficientes de correlação linear do retreinamento; mínimo obtido com a otimização e simulação do mínimo com o simulador – Caso 2A.	107
Tabela 6.13 - Relação da distância relativa dos atributos de treinamento com o histórico – Caso 2A	109
Tabela 6.14 – Análise de sensibilidade do poço PROD4 e da média dos oito poços.	111
Tabela 6.15 – Coeficientes de correlação linear dos metamodelos gerados – PROD_AS – Caso 2B.	115
Tabela 6.16 – Valores de afastamento e indicador de qualidade (%), obtidos com a simulação do mínimo ($\times 10^6$) – PROD_AS – Caso 2B.	120
Tabela 6.17 - Coeficientes de correlação linear – PROD_AS – Caso 2B – retreinamento.	123
Tabela 6.18 – Valores de afastamento gerados com a simulação dos mínimos obtidos com a otimização – PROD_AS – Retreinamento – Caso 2B.....	124

LISTA DE NOMENCLATURAS

Abreviações

AG – Algoritmo Genético

AGC – Algoritmo Genético Clássico

BB - Box Behnken

FO – Função Objetivo

HL – Hipercubo Latino

LMS - *Least Mean Square*

LM - *Levenberg-Marquardt*

RNA – Redes Neurais Artificiais

RP – Retro propagação

SS – Sequência de Sobol

1 INTRODUÇÃO

A simulação numérica de reservatórios é amplamente utilizada por profissionais ligados à área de gerenciamento de reservatórios, uma vez que permite realizar estudos sobre reservatórios complexos (com falhas, fraturas, geometrias complexas, heterogeneidades etc.) e aplicação de diferentes estratégias de produção (injeção de água, vapor, polímeros etc.), sendo fundamental no apoio à tomada de decisões. O objetivo principal do estudo de reservatórios é a previsão de comportamentos futuros, o que possibilita a realização de testes de diferentes estratégias de produção de modo a se obter o melhor desempenho possível do reservatório considerando aspectos econômicos e técnicos.

O modelo de simulação é construído a partir da caracterização geológica e de fluidos, realizando simplificações até que sua utilização com o simulador seja viável. Nessa etapa diversas informações do reservatório são perdidas. Além disso, são muitas as incertezas acerca dos parâmetros. Os procedimentos de obtenção dos dados do reservatório demandam custos elevados e são poucas as informações diretas obtidas (dados de poços), sendo a maioria estimada, correlacionada, ou não obtida.

Portanto, o modelo de simulação obtido nessa fase necessita de uma calibração para que represente de forma confiável o comportamento observado no reservatório real e possa ser utilizado para previsão de produção. Esse processo de calibração do modelo é chamado de ajuste de histórico.

O objetivo do ajuste de histórico é minimizar uma função objetivo (FO) que representa a qualidade do ajuste mediante cálculo da diferença entre dados observados no campo real e dados obtidos através do modelo de simulação. O procedimento consiste basicamente na variação dos valores dos atributos incertos do reservatório (permeabilidades, porosidade, transmissibilidade etc.) iterativamente, até que um valor de FO aceitável seja alcançado.

A importância desse processo reside no fato de que o modelo, uma vez ajustado, tem mais confiabilidade para ser utilizado na previsão de produção do reservatório. Porém, a obtenção de

um modelo aceitável não é uma tarefa fácil, devido a algumas características que o problema de ajuste de histórico possui, listadas abaixo:

- É do tipo inverso: a resposta (dados de produção) é conhecida, mas as variáveis de entrada (propriedades do reservatório) são desconhecidas;
- É, em geral, não linear: a resposta pode variar de forma não linear com as variáveis de entrada;
- Pode ocorrer inconsistência nos dados: devido a alguns métodos de medição serem realizados de forma indireta. Por exemplo, esquema de rateio para medição da produção dos poços de petróleo;
- Pode ocorrer insuficiência nos dados: principalmente para casos com pouco histórico de produção, em que os dados não são suficientes para calibrar o modelo;
- Pode envolver inúmeros parâmetros: quanto maior o número de parâmetros envolvidos maior é a complexidade do problema. Tipicamente estes parâmetros são a porosidade, a permeabilidade (horizontal, vertical ou relativa), a transmissibilidade de falhas, saturações iniciais etc. Se o reservatório for heterogêneo pode possuir várias fácies¹, o que também contribui para o aumento do número de parâmetros.
- Pode assumir múltiplas soluções: diferentes combinações de parâmetros podem resultar em ajustes aceitáveis.

Desse modo, o processo torna-se complexo e, dependendo do caso, o tempo demandado para realizar o ajuste pode ser grande. Na maioria dos casos tal processo é realizado de forma manual, pelo procedimento de tentativa e erro. Porém, com o aumento do número de parâmetros esse tipo de ajuste torna-se ineficaz, uma vez que a probabilidade de ocorrência de erros e a limitação da busca no espaço de soluções também aumentam. A vantagem é que a experiência do profissional pode levar a soluções de forma mais eficiente. Nesse contexto, foi desenvolvido o ajuste automático, que consiste na utilização de algoritmos para realizar todo o processo de ajuste. Porém, esse tipo de ajuste também se mostrou ineficiente, uma vez que, diversas

¹ Característica de um tipo de rocha que reflete sua origem e a diferencia de outros tipos ao seu redor. O termo fácies (em inglês, *facies*) é utilizado tanto para o singular quanto para o plural.

Fonte: <http://www.glossary.oilfield.slb.com/search.cfm>, acesso em 01/06/2012, às 22h21min.

particularidades existem para cada tipo de problema e a definição de um algoritmo capaz de realizar ajustes de forma independente torna-se complicado. Para aproveitar a grande capacidade de processamento dos algoritmos automáticos e, ao mesmo tempo, utilizar a experiência de um profissional para guiar o processo, surgiu o ajuste de histórico assistido. Com isso, partes do processo, que exigem grande esforço computacional, passam a ser automatizadas e a presença de um profissional especializado ajuda na escolha de algoritmos e metodologias.

A parte do processo que demanda maior esforço computacional é a etapa em que se realiza a varredura do espaço de soluções (etapa de otimização), necessitando normalmente de um grande número de simulações. Nessa área, a utilização de metamodelos (*proxies*) surge como opção interessante, uma vez que o metamodelo gerado pode ser utilizado no lugar do simulador em partes do processo, possibilitando a redução do número de simulações necessárias para alcançar ajustes aceitáveis. O metamodelo consiste, basicamente, em um modelo definido segundo funções matemáticas ou estatísticas que representam um dado padrão de saída para um dado padrão de entrada.

Existem diversas técnicas disponíveis para geração de metamodelos. Segundo Zubarev (2009), o modelo de regressão polinomial obtido por planejamento estatístico é bastante utilizado na indústria de petróleo devido a sua fácil compreensão, flexibilidade e eficiência computacional. Outra ferramenta que pode ser utilizada para geração de metamodelos é a Rede Neural Artificial (RNA), utilizada em diversas áreas e bastante difundida em análise de risco na área de petróleo. Segundo Maschio *et al.* (2008), as RNA são estruturas capazes de captar, de forma eficiente, as não linearidades em problemas tipicamente encontrados nos processos envolvendo simulação de reservatórios, o que constitui a maior motivação para utilização dessa técnica para o problema de ajuste de histórico.

Para geração de metamodelos utilizando RNA faz-se necessário treinar a rede para que ela seja capaz de reproduzir o comportamento do problema desejado. Para tanto, existem fatores importantes que devem ser considerados no processo de treinamento. A definição do conjunto de treinamento em específico é fundamental, pois a rede aprende através de exemplos e, por conta disso, não é capaz de representar com confiabilidade regiões do espaço de soluções para a qual não foi treinada.

Um fator importante na aplicação de metamodelos gerados por RNA no processo de ajuste de histórico, é que o procedimento de amostragem deve ser realizado utilizando o menor número possível de simulações. Esse aspecto ganha maior importância com o aumento da complexidade do problema (aumento do número de variáveis), uma vez que o número de simulações necessárias para amostragem de todas as combinações possíveis dos parâmetros cresce exponencialmente e se torna inviável. Assim, para definição do conjunto de treinamento deve-se atentar primeiramente à distribuição eficaz das amostras de forma a cobrir todo o espaço de busca dos parâmetros e, em segundo lugar, o espaço deve ser coberto com eficiência, ou seja, uma região deve conter uma quantidade suficiente de amostras (exemplos), de forma que a rede possa aprender o padrão de comportamento da superfície de resposta da região.

Uma técnica bastante utilizada para este propósito é o planejamento estatístico, que segundo Risso *et al.* (2006) é o método mais adequado a ser aplicado para reduzir o número de simulações de reservatório e vem se mostrando uma boa técnica auxiliar em processos de desenvolvimento e gerenciamento de campos de petróleo, sendo sua principal aplicação voltada à geração de metamodelos.

A fim de analisar a influência dos pontos de treinamento no aprendizado da RNA, foram abordadas três técnicas com diferentes características para geração dos conjuntos de treinamento, sendo uma delas o planejamento Box Behnken (BB). Além dele foi utilizado o Hipercubo Latino (HL), que é um método estatístico para gerar distribuições de parâmetros de forma a honrar as características da distribuição original, e a Sequência de Sobol (SS), que consiste em uma sequência de baixa discrepância, construída com intuito de obter melhor distribuição dos parâmetros no espaço. Uma introdução básica a respeito das técnicas será apresentada no tópico de fundamentação teórica.

Uma vez treinada a RNA (chamada então de metamodelo), ela estará pronta para ser utilizada no processo de otimização. A ferramenta aplicada para realizar a otimização foi o Algoritmo Genético (AG), amplamente utilizado para determinação de mínimos globais, por ser eficiente na realização da varredura do espaço de busca dos parâmetros. Uma introdução básica sobre seus conceitos também será abordada no capítulo da fundamentação teórica.

Estudos já mostraram que metamodelos gerados por RNA podem ser utilizados como substitutos do simulador em casos mais simples de reservatório, porém, ainda não existem muitos estudos para casos mais complexos. Assim, o presente trabalho visa avaliar o desempenho dos metamodelos gerados por RNA no processo de ajuste de histórico, buscando analisar a influência dos dados de entrada na qualidade do modelo final e, desse modo, o potencial de aplicação da metodologia para casos com características reais.

1.1 Motivação

Para casos simples, as RNA são capazes de representar o problema proposto sem maiores dificuldades. Contudo, à medida que a complexidade do problema aumenta os erros envolvidos no processo de treinamento da rede também tendem a aumentar e critérios mais robustos para definição de confiabilidade para utilização da ferramenta tornam-se necessários. Caso contrário, o problema será mal representado e resultados equivocados podem ser gerados. Assim sendo, a avaliação da ferramenta faz-se necessária.

Há diversas aplicações de RNA na indústria de petróleo, em particular na área de análise de risco, e poucas aplicações na área de ajuste de histórico. Porém, devido à semelhança no modo de aplicação da ferramenta entre as duas áreas, acredita-se que esta possui características importantes que a tornam promissoras para serem utilizadas na área de ajuste de histórico.

Em adição aos fatores citados acima, a principal motivação para realização desse trabalho surgiu do trabalho de Maschio *et al.* (2008), que realizaram estudos para aplicação da técnica em casos de reservatórios sintéticos e ressaltaram a necessidade de aprimoramento do processo de treinamento de redes neurais e geração dos metamodelos.

1.2 Objetivos

O objetivo principal desse trabalho consiste em avaliar o potencial de aplicação de metamodelos gerados a partir de RNA no problema de ajuste de histórico em casos práticos. Através de casos analíticos de duas variáveis aos quais possibilitam uma análise visual, são avaliadas as características e limitações da ferramenta e, posteriormente, através de um caso

sintético de reservatório com características reais, o real potencial de aplicação da ferramenta em casos complexos será avaliado.

Os objetivos específicos são:

- 1) Avaliar a influência do conjunto de treinamento, variando o tipo de amostragem e o número de pontos amostrados, no desempenho dos metamodelos gerados.
- 2) Avaliar formas de utilização do metamodelo em conjunto com o simulador no processo de ajuste de histórico para identificar de que maneira pode-se aplicar a ferramenta para melhorar a eficiência do processo.

Para realizar o processo de ajuste de histórico e testar diferentes tipos de dados de entrada, foi necessário recorrer a diferentes técnicas de amostragem para gerar os conjuntos de entrada, e de uma ferramenta de otimização, para realizar a busca no espaço de soluções, sendo essas etapas necessárias para alcançar o objetivo final (são complementares ao estudo). Portanto, realizar um estudo aprofundado a respeito dessas técnicas não faz parte dos objetivos.

1.3 Organização da Dissertação

Esse trabalho foi estruturado em sete capítulos. No capítulo um fez-se uma breve introdução ao tema escolhido.

No capítulo dois é realizada a fundamentação teórica, em que são mostrados os conceitos básicos necessários ao entendimento da aplicação das ferramentas utilizadas nesse trabalho. São abordados os temas de ajuste de histórico, redes neurais artificiais, algoritmo genético e técnicas de amostragem.

No capítulo três é realizada uma breve revisão bibliográfica, expondo os principais trabalhos que serviram de base para montar a metodologia e aplicar a ferramenta. São abordados principalmente trabalhos relacionados aos temas de ajuste de histórico e redes neurais artificiais.

O capítulo quatro consiste na modelagem da metodologia. O presente trabalho foi realizado em duas etapas, primeiro seguindo uma metodologia geral, modelada com o intuito de deixar claro os objetivos do estudo e escolher os casos de acordo com esses objetivos, e posteriormente, seguindo uma metodologia específica descrevendo o procedimento de ajuste adotado.

O capítulo cinco mostra os casos de estudo escolhidos para buscar alcançar os objetivos propostos.

Os resultados da aplicação do procedimento de ajuste adotado aos casos escolhidos são mostrados no capítulo seis. Nesse capítulo observações e discussões acerca dos resultados são realizadas.

Para finalizar, no capítulo sete são listadas as conclusões que se pôde chegar com os experimentos e sugestões futuras para melhorar os resultados e análises.

2 CONCEITOS E FUNDAMENTAÇÃO TEÓRICA

O foco principal desse trabalho é estudar o desempenho de metamodelos gerados por redes neurais artificiais (RNA) no processo de ajuste de histórico, sendo que as técnicas de amostragem e otimização aparecem como ferramentas auxiliares, utilizadas para viabilizar a aplicação da metodologia e, portanto, complementares aos estudos realizados nesse trabalho. Logo, dar-se-á maior enfoque na fundamentação dos temas de ajuste de histórico e RNA e, a respeito das técnicas de amostragem e otimização, será feita apenas uma breve contextualização.

2.1 Ajuste de histórico de produção

Uma das áreas de maior importância na indústria de petróleo é a de estudo de reservatórios, pois influencia diretamente na definição de estratégias de produção e no planejamento econômico. Segundo Aziz e Settari (1979), o objetivo principal de um estudo de reservatórios é a previsão do comportamento futuro e a determinação de meios para aumentar a recuperação final. Grande parte do planejamento envolvido nessa fase de estudos é realizada segundo resultados obtidos através da simulação numérica, procedimento que permite realizar previsões e estudar diferentes estratégias, possibilitando encontrar o melhor custo benefício, que leva à maior recuperação final da jazida em estudo. Segundo Consentino (2001), a etapa mais importante, e que também demanda maior tempo dentro da simulação numérica de reservatórios, é a de ajuste de histórico.

O modelo de simulação utilizado para estudos de reservatórios é construído a partir da caracterização geológica e de fluidos e são realizadas simplificações para possibilitar sua aplicação através do simulador de escoamento. Nessas etapas de simplificação, diversas informações são perdidas. Além disso, devido ao alto custo para obtê-las, alguns processos de medição acabam sendo realizados de forma indireta, gerando incertezas. Dessa maneira, o modelo de simulação obtido na fase de caracterização necessita de ajuste para que represente o

mais próximo possível o comportamento observado no reservatório real e possa ser utilizado para previsão de produção. Segundo Aziz e Settari (1979) mesmo com o modelo ajustado, a confiabilidade para previsão decresce com o tempo, sendo assim, interessante ‘atualizar’ o estudo de simulação realizado após certo período, efetuando novos ajustes dos parâmetros com dados adicionais de histórico. A esse processo de ajuste e validação do modelo de simulação aos dados históricos dá-se o nome de ajuste de histórico.

Nesse processo, os atributos que descrevem o reservatório (permeabilidade, porosidade, transmissibilidade das falhas etc.) são modificados e os dados de produção e pressão são comparados com o histórico. Através de um processo iterativo, os valores desses atributos são alterados até que o valor de uma função objetivo (FO) aceitável seja obtido. Essa função, caracterizada pela diferença entre dados observados no campo real e dados obtidos através da simulação do modelo de simulação, geralmente possui a forma descrita na Equação 2.1 (Ertekin *et al.*, 2001, p.350).

$$F = \sum_{i=1}^N [w_i \cdot (d_{i,obs} - d_{i,sim})^2] \quad \text{Equação 2.1}$$

em que N representa o número total de amostras, w_i representa o peso atribuído, $d_{i,obs}$ representa o dado observado e $d_{i,sim}$ representa o dado simulado. A FO é calculada com base nos dados de produção e pressão. Porém, segundo Maschio (2006), outras informações podem ser adicionadas ao processo, como dados de sísmica (por exemplo, mapas de saturação e pressão) e dados provenientes de testes e de perfilagem de poços.

Segundo Consentino (2001), o ajuste de histórico é um procedimento de validação de um modelo, em que o desempenho passado do reservatório é simulado e comparado com os dados observados. Quando diferenças são encontradas realizam-se modificações nos parâmetros de entrada. O objetivo final, portanto, é minimizar as diferenças nos dados dinâmicos reduzindo as incertezas dos dados estáticos.

2.1.1 Etapas do ajuste

Em busca de um ajuste final aceitável, Ertekin *et al.* (2001) propôs um procedimento iterativo básico a ser seguido, ilustrado na Figura 2.1.

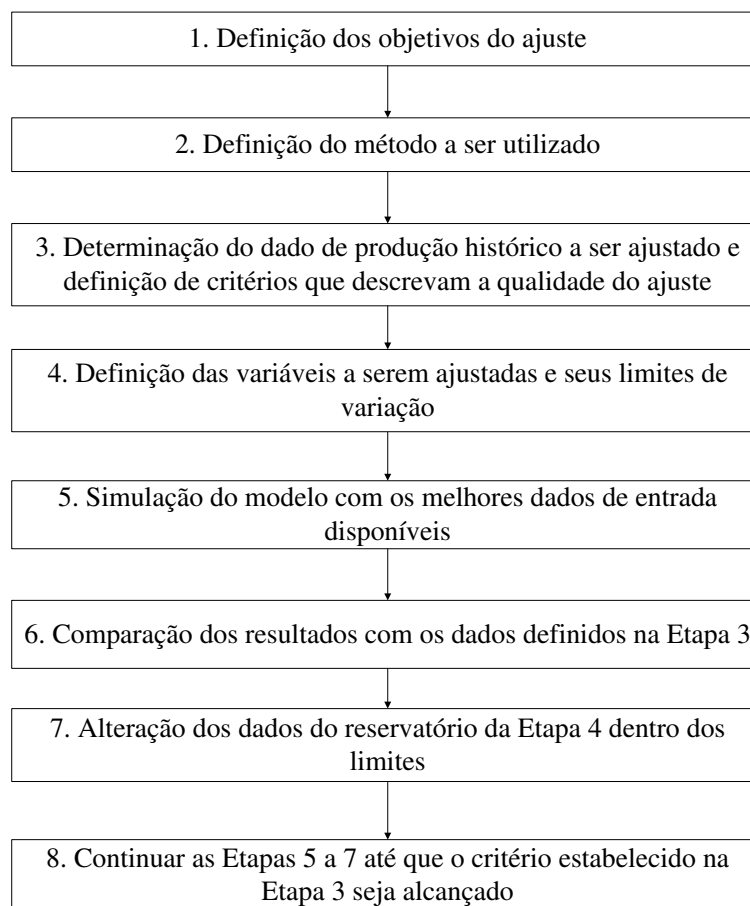


Figura 2.1 – Fluxograma básico a ser seguido para realização do ajuste de histórico. (ERTEKIN *et al.*, 2001, p.351).

Segundo fluxograma da Figura 2.1, a primeira etapa para se realizar um ajuste é definir os objetivos do ajuste. Essa etapa é importante, pois influencia nas próximas. Por exemplo, se o objetivo for um estudo preliminar sabe-se que não é necessário obter grandes precisões nos resultados e é possível chegar a respostas mais rapidamente.

A segunda etapa é dependente dos objetivos envolvidos no processo, recursos alocados pela companhia, prazos de entrega e disponibilidade dos dados.

A terceira etapa depende da disponibilidade, da qualidade dos dados de produção e do objetivo do estudo da simulação.

Na quarta etapa, os parâmetros escolhidos devem ser aqueles em que há maiores incertezas, porém, que influenciam mais sobre o desempenho do reservatório. Engenheiros de reservatório, geólogos e equipe de operadores, que conhecem bem o campo em estudo, devem trabalhar em conjunto para o sucesso desta etapa.

Na quinta etapa os dados disponíveis são simulados para posterior comparação do modelo com o histórico e medição de sua qualidade.

Na sexta etapa é realizada a comparação dos resultados obtidos com a simulação do modelo e o histórico. Os tipos de resultados a serem comparados dependem dos critérios definidos na Etapa 3.

Na sétima etapa, caso haja necessidade de ajuste, os atributos incertos do reservatório, definidos na Etapa 4, são alterados de forma a minimizar a diferença calculada na Etapa 6.

Por fim, a oitava etapa consiste em repetir as etapas cinco a sete até o modelo de simulação representar de forma aceitável o histórico. Uma vez ajustado o modelo com o histórico, ele pode ser utilizado com maior confiabilidade em previsões de comportamento.

2.1.2 Complexidade do ajuste

Esse procedimento de ajuste, no entanto, possui características intrínsecas a ele que o tornam complexo. Trata-se, segundo Consentino (2001), de um problema do tipo inverso, em que se conhecem os valores de saída (dados de produção), porém não se conhecem os parâmetros de entrada (atributos do reservatório) e depende, basicamente, da qualidade e da quantidade de dados disponíveis do reservatório em estudo, dos recursos alocados para o projeto e, eventualmente, da experiência e da atitude pessoal do engenheiro que trabalha no modelo.

O problema relacionado à qualidade e à quantidade dos dados disponíveis decorre do fato de que algumas medições são realizadas indiretamente (por exemplo, esquema de rateio para medição da produção dos poços de petróleo), consequência do alto custo para obtenção dessas

informações. Pode haver, também, casos com pouco histórico de produção disponível em que os dados não são suficientes para ajustar o modelo.

Dependendo do modelo, o número de parâmetros envolvidos pode ser alto (aumentam com a complexidade do problema). Tipicamente, estes parâmetros são a porosidade, permeabilidade (horizontal, vertical ou relativa), transmissibilidade de falhas, saturações residuais etc. Se o reservatório for heterogêneo pode possuir várias fácies, o que também contribui para o aumento do número de parâmetros.

Além dos fatores supracitados, outro aspecto a ser considerado na fase de ajuste de histórico, segundo Consentino (2001) é a não unicidade dos resultados, ou seja, o fato de ajustes igualmente satisfatórios poderem ser obtidos por diferentes descrições de reservatório. Isso provém do fato de que a simulação numérica é um sistema matemático complexo, tipicamente com apenas algumas variáveis conhecidas (propriedades dos fluidos, produções etc.) e, possivelmente, milhares de variáveis desconhecidas (porosidades, permeabilidade de todos os blocos do modelo, etc.). Do ponto de vista matemático esse fato gera infinitos números de soluções.

Um exemplo da não unicidade é mostrado na Figura 2.2, a qual mostra o gráfico da produção de água *versus* o tempo de uma jazida de petróleo. Os pontos em azul representam o histórico; a curva sólida em vermelho representa o Caso base (modelo desajustado); a curva tracejada em verde representa o Ajuste 1 e a curva tracejada em azul representa o Ajuste 2.




Figura 2.2 – Exemplo da não unicidade (múltiplas soluções) no problema de ajuste.

No gráfico da Figura 2.2 tanto o modelo resultante do Ajuste 1 quanto o modelo resultante do Ajuste 2 fornecem respostas com o mesmo grau de afastamento em relação ao histórico e, dependendo da precisão exigida no processo, ambos podem ser aceitos como resposta ao problema.

Segundo Ertekin *et al.* (2001) não há como fugir do problema da não unicidade dos resultados, porém, utilizar o máximo de dados de produção disponível e ajustar somente os dados menos conhecidos do reservatório dentro dos limites aceitáveis podem resultar em melhores ajustes.

2.1.3 Tipos de ajuste: manual, automático e assistido

Devido às características destacadas no Subitem 2.1.2, o processo pode se tornar complexo e, dependendo do caso, o tempo demandado para realizar o ajuste pode ser grande. Na maioria dos casos este processo é realizado de forma manual, pelo procedimento de tentativa e erro. Porém, uma grande desvantagem desse tipo de ajuste, segundo Schiozer *et al.* (2009), é o fato de ele exigir grande esforço do profissional envolvido, o que leva à limitação no número de simulações e consequente investigação insatisfatória do espaço de soluções (possibilidades e

combinações dos atributos incertos dos modelos de simulação). Em contrapartida, possui a vantagem de contar com a experiência do profissional, podendo levar a uma redução do número de simulações, identificando melhores soluções e maneiras de se chegar aos resultados (economizar excluindo análises desnecessárias) mais rapidamente. Segundo Aziz e Settari (1979), devido ao fato das equações de fluxo serem resolvidas de forma aproximada e diversas considerações serem realizadas durante o desenvolvimento do modelo, o julgamento de um profissional da área com experiência e conhecimento torna-se importante para interpretar os resultados e auxiliar no processo.

Com o intuito de diminuir as desvantagens do ajuste manual, foi desenvolvido o ajuste automático, que segundo Schiozer *et al.* (2009) consiste na utilização de algoritmos de otimização responsáveis por minimizar uma Função Objetivo (FO), representativa da qualidade do ajuste, sendo responsável por realizar todo o processo de forma independente. Contudo, esse tipo de ajuste não se mostrou eficiente devido à grande variedade de problemas com características distintas.

Nesse contexto surge o ajuste assistido, a fim de integrar as vantagens provenientes do ajuste manual e automático. Dessa forma, partes do processo passam a ser automatizadas, aumentando a confiabilidade (melhor avaliação do espaço de soluções), e partes são realizadas pelo profissional, identificando características importantes do problema (identificação dos parâmetros envolvidos no ajuste, divisão de um problema maior em problemas menores para solucionar o problema em etapas, identificação de melhores metodologias a serem aplicadas a cada caso etc.) para procurar simplificar e melhorar algumas etapas, tarefa que não é possível ser realizada em um processo automático.

2.1.4 Qualidade do ajuste

A questão da definição de critérios que indicam quando um modelo pode ser considerado ajustado é importante, pois influencia na determinação da metodologia e consequentemente no tempo dispendido para sua aplicação. Segundo Ertekin *et al.* (2001) não há um padrão para definição de quando um modelo está bem ajustado, pois este varia de empresa para empresa, de

pessoa para pessoa dentro da companhia ou de projeto para projeto pelo mesmo indivíduo. O importante é que o ajuste seja condizente com o objetivo do estudo.

Um exemplo desse aspecto é mostrado através do gráfico da Figura 2.3, que mostra a curva do corte de água (f_w) *versus* o tempo, em que são mostradas a curva do histórico de corte de água (curva tracejada) e a simulação do corte de água (curva sólida).




Figura 2.3 – Comparação do corte de água simulado com o histórico (Modificação de ERTEKIN *et al.*, 2001, p.357).

No gráfico da Figura 2.3, se o objetivo for realizar previsão de produção de água a fim de lidar com o avanço de água, então, o ajuste é aceitável, pois a tendência no final da curva está bem ajustada. Porém, se o objetivo é identificar localizações de poços ou futuras zonas a perfurar, então a qualidade não é boa, pois o modelo está subestimando o corte de água do poço.

Estudos de reservatórios têm mostrado que existem diversos mínimos locais nos modelos de simulação (desde reservatórios em fase inicial de produção a reservatórios maduros). Esse fator dificulta a definição de critérios, pois a presença de diversos mínimos locais pode fazer com que se encontrem diversos modelos parecidos.

Consentino (2001) atenta para o fato de que “o problema da não unicidade apenas nos permite concluir que a descrição do reservatório encontrado é apenas uma entre várias outras possibilidades que não contradizem os dados disponíveis” (CONSENTINO, 2001, p.273). Dessa maneira, o modelo de simulação ajustado deverá ser capaz de capturar os principais mecanismos que governam a produção do campo, porém, nunca será capaz de prever todas as possíveis

exceções para as regras gerais de depleção e deslocamento de fluidos no reservatório, devendo, portanto, ser considerado como um modelo probabilístico, o qual fornece uma estimativa confiável da produção futura do campo.

Devido à complexidade do problema, mesmo em posse de grande quantidade de dados de histórico pode-se fracassar no processo de ajuste e, nesse caso, segundo Aziz e Settari (1979), pode ser um indicativo de que alguma aproximação considerada no desenvolvimento do modelo deva ser revista (estrutura geológica, comportamento PVT, extensão do reservatório, presença de aquífero etc.), ou pode significar falta de precisão dos resultados (inconsistência nos dados).

2.1.5 Otimização dos valores dos atributos do reservatório

Dentro do processo de ajuste, a etapa que demanda maior esforço computacional e também em pesquisa e desenvolvimento, segundo Schiozer *et al.* (2009), é a de otimização dos valores dos atributos do reservatório, a fim de ajustar o modelo de simulação com o histórico. Isso ocorre, pois com o aumento do número de atributos incertos, o espaço de soluções torna-se cada vez maior, o que dificulta a varredura de todo o espaço. Além disso, por se tratar de um problema do tipo inverso, o número de múltiplas soluções também aumenta com o aumento do número de atributos.

Dessa maneira, ênfase maior tem sido dada para realização de estudos comparativos e desenvolvimento de novas metodologias para aplicação nessa área. Outro aspecto que leva à necessidade de melhorias constantes na área de otimização está relacionado ao fato de que cada caso possui particularidades, ou seja, uma ferramenta que serve para um determinado caso pode não servir para outro.

Dentre as alternativas, um procedimento interessante, difundido na área de análise de risco e que possui aplicação crescente na área de ajuste de histórico é a utilização de metamodelos (*proxies*).

2.1.6 Utilização de metamodelos gerados por redes neurais artificiais no processo de ajuste de histórico

Um metamodelo consiste basicamente em um modelo, definido segundo funções matemáticas ou estatísticas, o qual apresenta um dado padrão de saída para um dado padrão de entrada.

Uma característica importante dos metamodelos é que, uma vez gerados, eles simulam os resultados rapidamente e, por conta disso, são bastante promissores para serem utilizados como substitutos do simulador. Segundo Avansi (2008), os metamodelos, apesar de serem modelos simplificados e com menor confiabilidade nos resultados, podem substituir a simulação numérica em situações que demandam muitas simulações e não é necessária grande precisão.

Existem diferentes ferramentas disponíveis para geração de metamodelos. Segundo Zubarev (2009) o modelo de regressão polinomial é bastante utilizado na indústria de petróleo devido a sua fácil compreensão, flexibilidade e eficiência computacional. Outra ferramenta utilizada para geração de metamodelos é a Rede Neural Artificial (RNA), utilizada em diversas áreas, sendo bastante difundida em análise de risco na área de petróleo. Segundo Maschio *et al.* (2008), as RNA são estruturas capazes de captar de forma eficiente as não linearidades em problemas tipicamente encontrados nos processos envolvendo simulação de reservatórios, o que constitui a maior motivação para utilização dessa técnica para o problema de ajuste de histórico.

Sendo assim, o Subitem 2.2 a seguir irá mostrar os principais conceitos para compreensão do funcionamento básico de uma RNA. A teoria relacionada à RNA é ampla e, por conta disso, serão mostrados apenas os aspectos relevantes ao presente trabalho.

2.2 Redes neurais artificiais

As tarefas realizadas pelo ser humano no dia a dia, como respiração, pensamento, leitura etc. são comandadas pelo cérebro, composto por uma grande quantidade de neurônios (aproximadamente 10^{11}), interconectados com outros milhares, formando, assim, as redes neurais biológicas. Parte da estrutura da rede neural do cérebro é formada antes do nascimento do ser humano e parte é modificada ao longo da vida.

Acredita-se que todas as funções neurais, tais como a memória, são armazenadas nos neurônios e nas conexões entre eles. O aprendizado é visto como o estabelecimento, perda ou modificação de conexões. A partir desse conceito surge a inspiração para criação das redes neurais artificiais.

Utilizando neurônios artificiais (versão extremamente simplificada de um neurônio biológico) estrutura-se a rede neural artificial. Apesar de terem capacidade infinitamente inferior do que a do cérebro humano, as RNA podem ser treinadas para realizar inúmeros tipos de tarefas.

2.2.1 Redes neurais biológicas

O neurônio pode ser dividido basicamente em três partes principais: os dendritos, o corpo celular e o axônio. A Figura 2.4 mostra um esquema simplificado de um neurônio biológico.




Figura 2.4 – Esquema simplificado de um neurônio biológico².

Os sinais oriundos de outros neurônios são receptados pelos dendritos e enviados ao corpo celular, responsável por processar todas as informações receptadas e o axônio envia o sinal processado para outros neurônios. O contato entre o axônio de um neurônio e o dendrito de outro

² Retirada do site <http://www.din.uem.br/~jmpinhei/IA-CC/08Redes%20Neurais%20Artificiais.pdf>. Acesso em 27 de Abril de 2011 às 15h20.

é chamado de sinapse. A disposição dos neurônios e as intensidades das sinapses dos neurônios, determinadas por processos químicos complexos, estabelecem as funções das redes neurais.

2.2.2 Neurônio artificial

Um exemplo ilustrativo de um neurônio artificial é mostrado na Figura 2.5.




Figura 2.5 – Esquema básico de neurônio artificial (HAGAN *et al.*, 1996, p.2-3).

No neurônio da Figura 2.5, a entrada escalar p é multiplicada pelo peso w formando o produto $w \cdot p$, sendo um dos elementos de entrada do neurônio. Além dessa entrada existe outra chamada de auxiliar, de valor “1”, que é multiplicada pelo peso auxiliar chamado “bias” (ou *offset*) b . Os valores são então somados, resultando no valor n , geralmente referenciado efetivamente como entrada do neurônio, que então passa pela função de transferência (ou de ativação) f , que, por sua vez, gera a saída escalar do neurônio a .

Fazendo uma analogia com o neurônio biológico, o peso w representa a força da sinapse, o corpo celular é representado pelo somador e pela função de transferência e a saída a representa o sinal mandado ao axônio. A saída do neurônio é calculada pela Equação 2.2 (Hagan *et al.*, 1996, p.2-3):

$$a = f(w \cdot p + b) \quad \text{Equação 2.2}$$

em que os escalares w e b são ajustáveis.

2.2.3 Função de transferência (de ativação)

Existem diversas funções de transferência que podem ser utilizadas para calcular a saída de um neurônio. Para problemas de aproximação de função, as mais utilizadas são as do tipo sigmoide e linear. A Figura 2.6 mostra a função do tipo linear (a) e a do tipo tangente hiperbólica (b).




Figura 2.6 – Função de transferência do tipo linear (a) e tangente hiperbólica (b).

A Figura 2.6 mostra como a função varia em relação ao parâmetro de modelagem x . Os limites de variação para o parâmetro utilizado foi de -1 a 1 para a função da Figura 2.6 (a) e -3 a 3 para a função da Figura 2.6 (b), tal que os limites de variação da resposta $F(x)$ varie de -1 a 1.

2.2.4 Arquitetura

Tipicamente um neurônio possui mais de uma entrada. Além disso, geralmente, as redes possuem diversos neurônios e podem ter mais de uma camada. A Figura 2.7 mostra um exemplo de uma rede neural artificial com três camadas.




Figura 2.7 – Ilustração de uma rede neural de 3 camadas (HAGAN *et al.*, 1996, p.2-11).

Quanto à arquitetura, a rede da Figura 2.7 é do tipo direta ou *feedforward* (a saída de um neurônio da i -ésima camada não pode ser utilizada como entrada para neurônios de camada menor ou igual a i), múltiplas camadas (três) e completamente conectada (cada entrada é ligada a todos os neurônios da camada seguinte).

Quanto à nomenclatura utilizada, o índice sobrescrito refere-se à camada, o índice subscrito da esquerda representa o neurônio de destino e o da direita representa a entrada de onde o sinal provém. Assim, a rede em questão possui R entradas, S^1 neurônios na primeira camada, S^2 neurônios na segunda camada e S^3 neurônios na terceira camada. Cada elemento do vetor de entrada (p) é conectado aos neurônios da primeira camada através da matriz de pesos (W). Cada neurônio possui uma entrada auxiliar, na qual possui um peso auxiliar (b_i), chamado de *bias*, um somador, uma função de transferência e uma saída (a_i). A terceira camada, que gera a saída da rede, é chamada de camada de saída. As outras camadas são chamadas ocultas ou intermediárias (*hidden layer*).

A rede da Figura 2.7 também pode ser apresentada na forma abreviada, conforme mostra a Figura 2.8 abaixo:




Figura 2.8 – Rede multicamadas na forma abreviada (HAGAN *et al.*, 1996, p.2-12).

2.2.5 Escolha da arquitetura da rede

Algumas variáveis da rede são determinadas pela especificação do problema proposto, como por exemplo, o número de entradas e saídas da rede. Se o problema em estudo possui quatro parâmetros incertos e um valor de saída, então, o número de neurônio nas camadas de entrada e saída serão quatro e um, respectivamente. A função de transferência a ser utilizada pode ser escolhida segundo a característica desejada no sinal de saída da rede. Por exemplo, se deseja ter valores -1 ou 1 na saída, a função de transferência escolhida deve ser do tipo degrau unitário.

As entradas auxiliares fornecem variáveis extras à rede. Segundo Hagan *et al.* (1996), “pode-se esperar que redes com entradas auxiliares sejam mais poderosas do que redes sem” (HAGAN *et al.*, 1996 p.2-12). Por exemplo, se as entradas p forem todas zero, a presença das entradas auxiliares impede que a entrada n para a função de transferência seja zero.

Quanto ao número de camadas de neurônios a ser empregado, a maior parte dos problemas utilizam de 2 a 3 camadas. Segundo Hagan *et al.* (1996), “Uma rede com duas camadas e tendo função de transferência do tipo sigmoide nas camadas intermediárias e do tipo linear na saída pode ser treinada para aproximar inúmeras funções arbitrariamente bem. Redes de camadas únicas não” (HAGAN *et al.*, 1996 p.2-12). Silva e Oliveira (2004) sugerem que a utilização de um grande número de camadas ocultas não é recomendável, uma vez que elas recebem uma estimativa do erro produzido na camada de saída e, quanto mais distante a camada oculta estiver

da camada de saída, menos precisa é a estimativa do erro. Assim, uma camada é o suficiente para problemas menores e, para problemas maiores, duas camadas devem ser suficientes.

Quanto ao número de neurônios das camadas ocultas, segundo Silva e Oliveira (2004) o valor é escolhido de forma empírica, porém deve-se atentar para não utilizar nem valores de mais (leva a memorização – *overfitting*) nem de menos (a rede não será capaz de aprender os padrões desejados). Um procedimento existente para determinação do número de neurônios, segundo os autores, consiste em utilizar um número de sinapses dez vezes menor do que o número de exemplos utilizados para treinamento.

Portanto, infelizmente, não existe nenhuma teoria ou regra a ser seguida para determinação da quantidade de camadas e neurônios a serem utilizados, sendo na maioria dos casos definidos de forma empírica.

2.2.6 Treinamento de redes neurais artificiais

O processo de treinamento consiste em utilizar uma regra de aprendizado e realizar modificações (ajustes) nos valores dos pesos, até que os níveis de discrepância entre os resultados gerados na saída da rede e os padrões apresentados (exemplos de como a rede deve se comportar, ou seja, conjunto de saídas desejadas) sejam aceitáveis. Assim, o objetivo do treinamento é fazer com que a rede seja capaz de reproduzir um padrão de comportamento desejado quando apresentado certo padrão de entrada. No processo chamado supervisionado, são apresentados padrões de entradas e saídas desejadas (*target*), e os valores dos pesos da rede são ajustados através de um algoritmo de aprendizado. Ao final, se o treinamento for bem sucedido, a rede será capaz de reproduzir o mesmo padrão de saída todas as vezes que novas entradas forem apresentadas a ela.

Existem diversas regras utilizadas para aprendizado supervisionado, sendo uma delas baseada na otimização de uma função de desempenho, que mede a qualidade de generalização da rede. É nessa regra que se baseia o algoritmo de retro propagação, bastante utilizado em diversos problemas. A técnica de treinamento utilizada nesse trabalho é a de *Levenberg-Marquardt* (LM) com regularização *Bayesiana*, que é uma variação do método de Retro propagação (RP).

2.2.6.1 Algoritmo de retro propagação (*backpropagation*)

As etapas básicas do algoritmo de retro propagação (RP) são ilustradas no fluxograma da Figura 2.9.

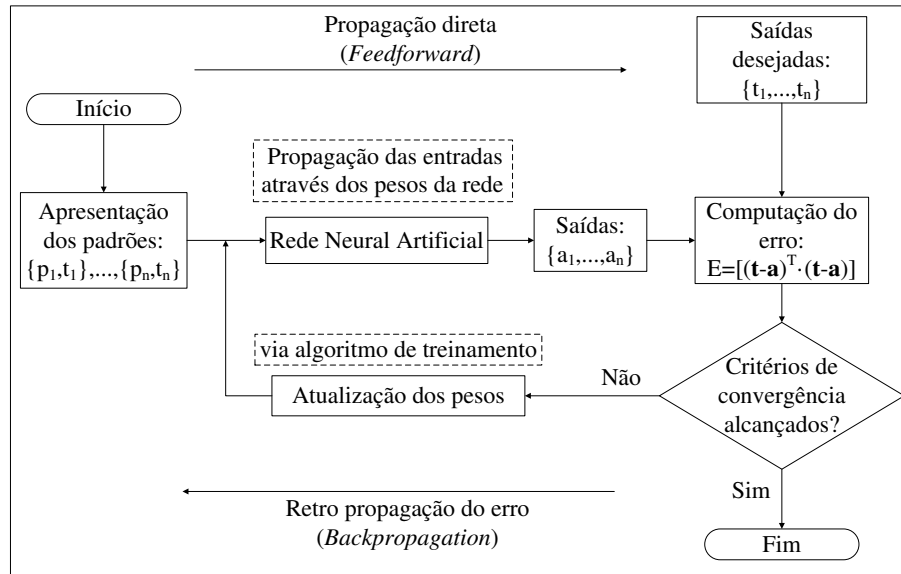


Figura 2.9 – Fluxograma básico do algoritmo de RP.

Inicialmente é fornecido à rede as entradas e saídas desejadas (exemplos de como deseja que a rede se comporte). As entradas são propagadas através das camadas da rede e as respectivas saídas são geradas. Essas saídas são comparadas com as saídas desejadas e os erros entre elas são calculados. Caso o valor do erro obtido não esteja de acordo com o objetivo, os valores dos pesos da rede são alterados de forma a reduzir esse valor. Para tanto, utiliza-se a regra da cadeia para retro propagar o valor do erro, partindo da camada de saída até chegar à camada de entrada, possibilitando a atualização dos pesos de acordo com o erro obtido. Após atualização dos pesos inicia-se nova iteração, propagando as entradas pela rede e calculando novamente o erro.

Uma observação importante sobre o algoritmo, já mencionada anteriormente, é que, ao usar a regra da cadeia, cada camada oculta recebe uma estimativa do erro da camada subsequente, de forma que, quanto maior for o número de camadas, maior será a incerteza do valor do erro que a camada de entrada receberá. Uma abordagem mais completa do algoritmo pode ser encontrada em Hagan *et al.* (1996).

2.2.6.2 Variações do algoritmo de Retro propagação

O algoritmo de RP, apesar de ter revolucionado as pesquisas de RNA, segundo Hagan *et al.* (1996) “é muito lento e ineficaz para muitas aplicações práticas” (HAGAN *et al.*, 1996, p.12-1). Segundo Hagan e Menhaj (1994), desde que o algoritmo se popularizou, surgiram diversas metodologias para acelerar sua convergência, sendo a incorporação de métodos numéricos ao algoritmo padrão uma dessas vertentes. O algoritmo de *Levenberg-Marquardt* (LM), uma variação do método de *Newton*³, é utilizado para minimização da soma quadrada de funções não lineares. Trata-se de uma característica importante que se enquadra muito bem no contexto de RNA, em que o desempenho é medido pela soma ou média do quadrado do erro. Por esse motivo, esse algoritmo foi escolhido para ser aplicado ao presente trabalho. Hagan e Menhaj (1994) publicaram um artigo no qual o algoritmo é aplicado a alguns problemas de aproximação de funções e, segundo os autores, é muito eficiente para aplicação em redes que tenham até algumas centenas de pesos. O desenvolvimento desse algoritmo pode ser encontrado em Hagan *et al.* (1996).

2.2.6.3 Capacidade de generalização de uma rede neural artificial

Um dos maiores problemas que ocorrem durante o processo de treinamento de uma RNA é a memorização (*overfitting*) dos dados. Em tais situações, a rede acaba memorizando as saídas ao invés de aprender o padrão de geração para poder generalizar para outras entradas. Como resultado, a rede produz saídas diferentes do padrão desejado quando são apresentadas entradas que não foram utilizadas para treinamento.

Dois métodos utilizados para melhorar a capacidade de generalização de uma RNA são o método de regularização e de parada prematura (*early stopping*), descritos sucintamente a seguir.

O método de parada prematura consiste em dividir o conjunto de treinamento em três subconjuntos: treinamento, validação e teste. O primeiro conjunto é utilizado para atualização dos pesos, ou seja, aplicação do algoritmo de aprendizagem. O segundo conjunto é utilizado durante

³ A teoria referida pode ser encontrada no livro de Hagan *et al.*, 1996.

o treinamento para monitorar o desempenho da rede. Se o erro de validação começar a subir enquanto o erro de treinamento continua diminuindo é sinal de que está ocorrendo memorização dos resultados. Nessa hora o treinamento é interrompido. O terceiro conjunto é utilizado após o treinamento para testar a capacidade de generalização da rede.

Já o método de regularização consiste em modificar a função de desempenho. O método *bayesiano*, em particular, utiliza informações adicionais para cálculo dessa função, que assume a forma mostrada na Equação 2.3 (Foresse e Hagan, 1997, p.1).

$$F = \beta \cdot E_D + \alpha \cdot E_W \quad \text{Equação 2.3}$$

em que E_D representa a soma do quadrado do erro entre saída desejada e gerada pela rede, E_W representa a soma do quadrado dos pesos da rede e α e β são parâmetros da função objetivo. Basicamente considera-se que os pesos da rede são variáveis aleatórias com uma determinada distribuição de probabilidades, de forma que os parâmetros α e β estejam atrelados a eles, e, seus valores são, então, estimados utilizando técnicas estatísticas. A descrição do método *bayesiano* de regularização pode ser encontrada no trabalho de Foresse e Hagan (1997) e no livro de Bishop (1995).

2.3 Algoritmo genético

Ao gerar o metamodelo, que no caso de RNA nada mais é do que uma rede treinada, ele está pronto para ser utilizado no lugar do simulador no processo de otimização. Nesse trabalho foi utilizado o algoritmo genético (AG) para esse processo.

O AG consiste em uma metodologia de otimização baseada no mecanismo de seleção natural proposto pela teoria de Darwin, na qual diz que indivíduos mais adaptados ao meio sobrevivem e contribuem para propagação das gerações. Assim, as características dos indivíduos mais fortes vão se propagando para as futuras gerações, enquanto que, características desfavoráveis vão se tornando menos frequentes. Proposto por Holland⁴ em 1975, inicialmente foi desenvolvido e aplicado em máquinas com intuito de encontrar explicações para os processos

⁴ John Henry Holland é conhecido por ter criado os algoritmos genéticos.

adaptativos em sistemas naturais. Porém, devido ao seu grande potencial em varrer espaços multidimensionais, passou a ser amplamente empregado em problemas de otimização.

No AG um indivíduo é constituído pelo seu cromossomo, o qual representa uma possível resposta ao problema (conjunto de variáveis). O processo de evolução ocorre alterando-se os valores de cada gene (variável) do cromossomo.

O funcionamento básico do algoritmo consiste em, a partir de uma população inicial de indivíduos (cromossomos), realizar operações de recombinação (*crossover*), mutação e seleção em um processo iterativo de modo que, a cada geração (iteração), a população gere indivíduos mais aptos (melhores soluções) ao ambiente (problema).

No início o AG era padronizado e seguia, em geral, o mesmo procedimento, sendo denominado de *Algoritmo Genético Clássico* (AGC). A estrutura apresentada na Figura 2.10 representa as principais etapas a serem realizadas em um AGC.

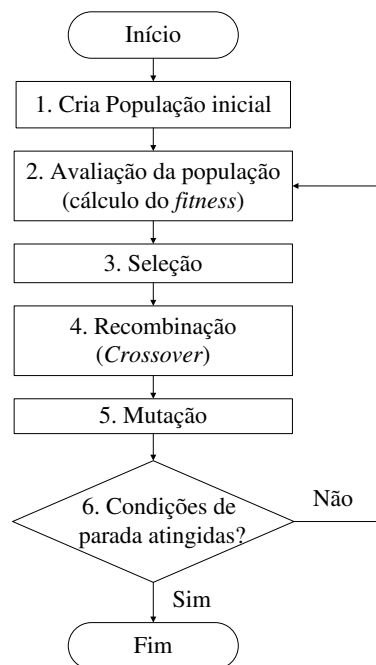


Figura 2.10 – Estrutura básica de um AGC.

Nesse algoritmo (AGC), cada indivíduo da população é composto por um vetor de bits, conforme mostra a Figura 2.11 (a), e representam possíveis respostas ao dado problema.




Figura 2.11 – Exemplo de um indivíduo formado por um vetor de bits (a), ilustração dos processos de recombinação (b) e mutação (c).

Para iniciar o algoritmo, é gerado um conjunto de indivíduos para compor a população inicial. Em seguida, a população é avaliada a fim de encontrar os indivíduos mais fortes. A cada indivíduo é atribuído um valor, determinado através da função de *fitness*, na qual representa o quão distante a solução gerada pelo indivíduo está do valor desejado. Após a avaliação ocorre a seleção dos indivíduos para serem submetidos aos operadores genéticos (recombinação e mutação). No AGC é utilizado o algoritmo da Roleta Russa (*Roulette Wheel*) para o processo de seleção, ilustrado na Figura 2.12.




Figura 2.12 – Ilustração do algoritmo de Roleta Russa⁵.

⁵ Retirada do site http://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia707_01/topico6_01.pdf Acesso em 28 de Maio de 2011, às 13h44.

O algoritmo da Roleta Russa, mostrada na Figura 2.12, consiste em atribuir um valor de probabilidade de seleção a cada indivíduo, proporcional ao seu valor de *fitness* e, a partir daí, os indivíduos são selecionados de forma aleatória de acordo com a probabilidade.

Aos indivíduos selecionados são aplicados os operadores genéticos. O operador de recombinação é realizado pelo método de recombinação de um ponto, em que os cromossomos de dois indivíduos são cortados em um ponto específico e, então, os dois pedaços são trocados, conforme mostra a Figura 2.11 (b). No AGC ainda pode ocorrer mutação em que, com uma probabilidade baixa, um indivíduo pode sofrer alteração em seu gene, conforme mostra a Figura 2.11 (c).

Os indivíduos, após a realização dos mecanismos de reprodução (seleção, recombinação e mutação), compõem a nova população para a próxima geração. Caso as informações desejadas não estejam contidas dentro dos indivíduos dessa nova população, ou seja, se as condições de parada não forem satisfeitas, inicia-se novamente o processo de reprodução. Um ciclo completo do processo de reprodução (etapas de 2 a 6 do fluxograma da Figura 2.10) consiste em uma geração.

A desvantagem do AGC é que o procedimento de reprodução acaba possibilitando a perda do melhor indivíduo da população. Além disso, a codificação de valores em binário torna-se complicada com aumento da precisão dos dados. Para tentar superar essas desvantagens, algoritmos modificados têm sido utilizados, com mecanismos alternativos de seleção/reprodução e codificação dos indivíduos da população em número reais.

Um exemplo de modificação no processo de reprodução e seleção consiste em gerar uma subpopulação a partir da população atual, utilizando operadores genéticos (recombinação e mutação), avaliar e organizar essa subpopulação e realizar nova seleção dentro dela para compor a próxima geração.

O AG é uma ferramenta bastante utilizada para problemas de otimização devido a suas características particulares, que o diferenciam dos algoritmos de busca e otimização tradicionais. Conforme pôde ser observado na introdução, o AG realiza busca sobre uma população de pontos, ao invés de um ponto, de forma paralela e independente. Outra característica importante da

ferramenta é que ela não requer informações de derivadas, sendo necessário fornecer apenas o valor da função objetivo (*fitness*).

2.4 Técnicas de amostragem

Um ponto crítico que merece destaque no processo de treinamento de RNA é a questão dos dados de entrada (dados de treinamento), pois a qualidade do metamodelo está diretamente ligada a eles (Zubarev, 2009). Como as RNA aprendem através de exemplos, se não forem expostos os pontos relevantes e necessários que descrevem a superfície de resposta a qual se deseja modelar, a estrutura gerada muito provavelmente não irá realizar representações satisfatórias nessas regiões onde ocorre falta de informação.

Essa observação traz a tona uma importante característica das RNA para representação de um simulador de escoamento. A RNA tende a suavizar (atenuar) o formato da superfície de resposta quando pouca informação lhe é fornecida. Sendo assim, em regiões onde a superfície possui muitas irregularidades e pouca informação a respeito, essa característica se torna mais importante.

Adicionalmente, em problemas de ajuste de histórico, na prática, o tempo demandado para realizar uma simulação pode ser muito grande e, portanto, a utilização do menor número de pontos possível para realizar o processo se torna importante. Nesse contexto, pode-se dizer que para a metodologia de ajuste a ser adotada nesse trabalho, que é a aplicação de metamodelos gerados a partir de RNA no problema de ajuste de histórico, a técnica utilizada para amostrar os pontos de treinamento das RNA é de suma importância.

Segundo Mckay *et al.* (1979) quando se pretende modelar algum fenômeno do mundo real através de simulação computacional, um problema que surge é saber quais valores devem ser utilizados como entrada. Essa incerteza acerca dos parâmetros é modelada tratando-os como variáveis aleatórias. O comportamento da saída é obtido realizando-se experimentos numéricos a partir da amostragem das variáveis de entrada, com distribuição de probabilidades conhecida.

Existem diversas técnicas de amostragem na literatura, com o propósito de amostrar o espaço de busca dos parâmetros utilizando quantidades reduzidas de amostras.

A ideia original do trabalho consistiu em comparar as técnicas do Hipercubo Latino e Box Behnken para gerar os dados de entrada e os metamodelos a serem utilizados em casos práticos de reservatório. A escolha dessas duas técnicas se deu pelo fato de existirem trabalhos publicados da área de análise de risco em que elas foram aplicadas com sucesso.

A técnica do HL possibilita gerar qualquer quantidade de amostras que se desejar. No entanto, no planejamento BB um conjunto pré-determinado de pontos é selecionado (segundo uma metodologia particular) dentre todas as possíveis combinações das variáveis de modelagem do problema, ou seja, a técnica não tem a flexibilidade que o HL fornece para escolha da quantidade de amostras. Por conta disso, para poucas variáveis, a quantidade de pontos amostrados é pequena, não sendo interessante utilizar a técnica nesses casos.

Para aplicação da metodologia foram escolhidos, inicialmente, casos analíticos de duas variáveis a serem estudados antes de um caso prático de reservatório. Com isso, fez-se necessária a escolha de outra técnica de amostragem para aplicar a metodologia nesses casos preliminares. Através de uma rápida pesquisa bibliográfica decidiu-se utilizar a Sequência de Sobol por se tratar de uma sequência que gera um bom espaçamento entre as variáveis no espaço, sendo uma alternativa interessante em relação ao método de Monte Carlo. Portanto, foram comparadas em um primeiro momento as técnicas do HL e SS, e em um segundo momento as técnicas do HL e BB. Uma breve introdução dessas três técnicas é realizada nos itens subsequentes.

2.4.1 Box Behnken

Aliar um bom espaçamento entre pontos no espaço com menor número de simulações possível é uma tarefa complicada quando envolve grande quantidade de parâmetros. Nesse contexto, o planejamento estatístico tem sido empregado a fim de gerar dados de entrada com qualidade. Segundo Risso (2007) *apud* Montgomery (1996) a técnica consiste basicamente na utilização de métodos estatísticos e matemáticos para modelagem de problemas nos quais as funções-objetivo são influenciadas por vários atributos com a finalidade de otimizar a resposta. Dessa maneira, a etapa de amostragem dos dados de entrada é realizada de forma planejada, utilizando técnicas estatísticas. Segundo Mason *et al.* (2003), a utilização do planejamento estatístico permite que informações sejam obtidas de forma eficiente nas regiões de interesse.

A técnica possui diversas aplicações na indústria de petróleo. Como exemplo pode-se citar o planejamento do tipo Box Behnken (BB), utilizado por Risso (2006) em conjunto com o método de superfície de resposta para estudar o tratamento de atributos na análise de risco. No processo de ajuste de histórico Lima (2009) utilizou metamodelos gerados por planejamento estatístico para realizar o ajuste. Esse método possibilita realizar uma boa amostragem com número bastante reduzido de amostras em situações em que o número de fatores (parâmetros) é elevado.

Supondo que se tenha k fatores (ou variáveis), discretizados em três níveis. O modelo fatorial 3^k é um modelo contendo todas as combinações possíveis de k fatores (variáveis) nesses três níveis. O método de amostragem BB é formado selecionando valores do modelo 3^k fatorial completo segundo uma metodologia particular, detalhada em Box e Behnken (1960). Os três níveis são normalizados de tal forma que se tenha apenas valores 1, -1 e 0.

Os pontos resultantes formam uma matriz na qual as linhas representam o número de simulações e as colunas representam o número de fatores. A Tabela 2.1 mostra um modelo de três fatores.

Tabela 2.1 – Método de BB na forma matricial para 3 fatores, discretizados em 3 níveis.

Experimento	X1	X2	X3	Experimento	X1	X2	X3
1	-1	-1	0	9	0	-1	-1
2	1	-1	0	10	0	1	-1
3	-1	1	0	11	0	-1	1
4	1	1	0	12	0	1	1
5	-1	0	-1	C	0	0	0
6	1	0	-1	C	0	0	0
7	-1	0	1	C	0	0	0
8	1	0	1				

O método de planejamento estatístico foi proposto originalmente para ser utilizado na modelagem de experimentos de laboratório, em que erros de experimento e medição estão presentes. Assim, os experimentos são repetidos para que se possam estimar esses erros. Os experimentos identificados pela letra “C” na Tabela 2.1 representam, então, a repetição dos experimentos.

Os pontos da Tabela 2.1 formam um cubo em que eles se situam no meio das arestas e no centro, conforme mostra a Figura 2.13




Figura 2.13 – Método de BB na forma gráfica para 3 fatores, discretizados em 3 níveis (FERREIRA *et al.*, 2007, p.183).

O número total de simulações realizadas é $N = 2 \cdot k \cdot (k - 1) + C_o$ (Ferreira *et al.*, 2007, p.182), em que k é o número de fatores e C_o é o número de pontos centrais. Assim, o método de BB utiliza menos simulações do que o modelo fatorial completo. Outra característica do modelo é que ele não contém pontos em que todos os fatores são simultaneamente máximos ou mínimos, ou seja, ele não gera condições extremas (Ferreira *et al.*, 2007, p.182). Dessa maneira, o modelo não é indicado para experimentos nos quais se deseja determinar condições extremas.

Segundo Mason *et al.* (2003) a utilização de planejamento estatístico nas etapas de coleta de dados permite realizar conclusões diretas e precisas, o que geralmente não é possível quando a coleta é realizada de forma não planejada.

Uma explicação completa sobre a metodologia pode ser encontrada em Box e Behnken (1960).

2.4.2 Hipercubo Latino

O método do HL foi proposto por McKay *et al.* (1979) como alternativa atrativa ao método aleatório simples (Monte Carlo) em experimentos computacionais. Segundo o autor, o método é utilizado quando se deseja que cada variável de entrada tenha todas as regiões de sua distribuição representadas.

Na amostragem por Hipercubo Latino (HL), o domínio de cada variável é dividido em N intervalos e valores são sorteados dentro de cada intervalo. A quantidade de valores sorteados dentro de cada faixa pode variar de acordo com sua probabilidade, conforme mostra a Figura 2.14.




Figura 2.14 – Exemplo de discretização de uma distribuição normal em 7 intervalos. (MASCHIO *et al.*, 2009, p.3)

Observa-se que a quantidade de valores sorteados na faixa central (em azul) é maior e vai diminuindo conforme a curva de probabilidade da faixa. Para uma distribuição uniforme, as faixas possuem probabilidades iguais ($1/N$). Os componentes sorteados de cada variável são permutados de forma aleatória. A Figura 2.15 mostra um exemplo da amostragem para distribuição normal e uniforme.

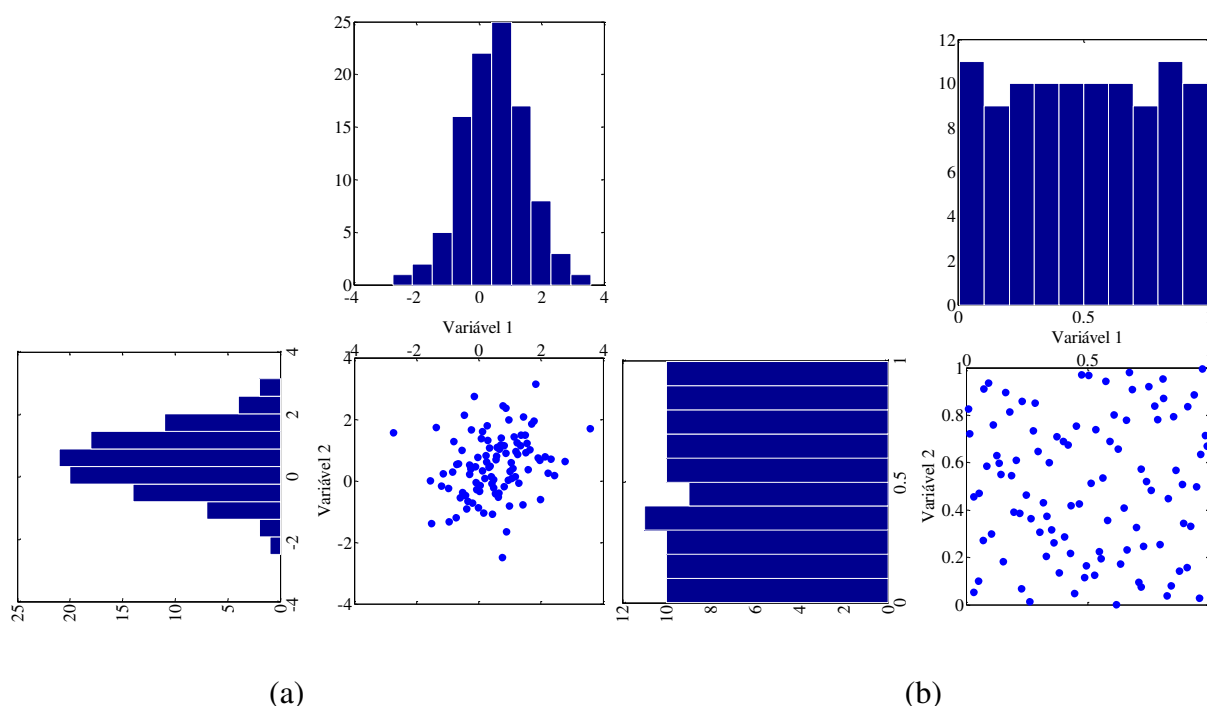


Figura 2.15 - Figura ilustrativa da amostragem por HL, para distribuição normal (a) e uniforme (b).

Segundo Maschio *et al.* (2009), “uma característica importante dessa técnica é que, independentemente do número de sorteios, o número de amostras representa de forma adequada a distribuição de probabilidades” (MASCHIO *et al.*, 2009, p.3).

Maiores detalhes podem ser encontrados no trabalho de Mckay *et al.* (1979), o qual realiza comparações da técnica do HL com o método aleatório simples e estratificado e apresenta as vantagens em estimar empiricamente distribuições.

2.4.3 Sequência de Sobol

A Sequência de Sobol (SS) faz parte do tipo de sequência de baixa discrepância ou quase-aleatória (*quasirandom*) em que, segundo Frota (2003), as amostras são selecionadas de modo a preencherem igualmente todo o domínio do espaço de busca. O autor estudou a aplicação de sequências desse tipo em avaliação de opções americanas tradicionais e complexas (modelos de precificação), mostrando que a aplicação traz vantagens em relação à simulação de Monte Carlo.

O procedimento seguido para construir a SS envolve conceitos de números direcionais e polinômios primitivos e não será demonstrado nesse trabalho. Uma descrição sucinta pode ser encontrada no trabalho de Frota (2003) e uma descrição completa desse procedimento foi realizada por Bratley e Fox (1988). Um exemplo de amostragem pela técnica para 100 pontos é mostrado na Figura 2.16.




Figura 2.16 – Exemplo de amostragem pela Sequência de Sobol.

Uma observação importante dada por Bratley e Fox (1988) é que a SS deve utilizada para problemas de 2 a 6 dimensões.

2.5 Comentário sobre as técnicas de amostragem

Para os casos analíticos, a amostragem pelo HL, devido a suas características, deve proporcionar uma cobertura bem espaçada das amostras no espaço. O mesmo se pode dizer da SS, pois com até seis variáveis ela proporciona bom espaçamento. Assim, no caso de duas variáveis, para avaliação de uma região maior (toda a superfície de busca dos parâmetros), podem-se esperar resultados semelhantes para as duas técnicas em questão de qualidade da modelagem. Porém, se for realizada avaliação em regiões específicas (menores) deve-se destacar a diferença entre elas, pois cada uma tem um padrão de geração das amostras.

Para o caso com mais variáveis, quando comparada às técnicas do HL e BB, a diferença entre elas deve aumentar conforme se aumenta a quantidade de amostras e o tamanho do espaço de busca dos parâmetros, ou seja, os limites de variação de cada variável de modelagem. O BB amostra valores normalizados (mínimo, médio e máximo) enquanto que o HL, apesar de dividir a variável em intervalos, realiza o sorteio em uma faixa contínua de valores. Assim, para espaços maiores, o HL deve fornecer melhor cobertura de todo o espaço de busca.

Deste modo, pode-se esperar que, para o caso prático de reservatório em que se tem maior quantidade de atributos incertos, melhores resultados sejam obtidos através da utilização da técnica do HL.

3 REVISÃO BIBLIOGRÁFICA

3.1 Ajuste de histórico

Para compreender melhor o processo de ajuste de histórico, bem como sua importância para estudos de reservatório, uma pesquisa bibliográfica foi realizada para conhecimento e análise de diferentes metodologias que vêm sendo aplicadas nessa área.

Conforme visto no item de fundamentação teórica, o problema de ajuste de histórico é complexo e mal condicionado. Segundo Schiozer *et al.* (2009) dentre as etapas que envolvem esse processo, a que demanda maior esforço computacional e também em pesquisa e desenvolvimento, é a de otimização dos valores dos parâmetros do reservatório, a fim de ajustar o modelo de simulação com o histórico. Nesse contexto, muitos trabalhos têm sido propostos e o surgimento de novos estudos a fim de melhorar essa etapa é frequente.

A seguir são analisados alguns trabalhos nos quais se realizam testes e comparações de diferentes técnicas nessa área.

Leitão e Schiozer (1998) realizaram uma comparação entre algoritmos de primeira ordem (que utilizam informações de gradiente) e de busca direta (que não necessitam do cálculo da derivada). Os autores ainda utilizaram o pacote PVM (*Parallel Virtual Machine*), que paraleliza as simulações de modo a reduzir o tempo necessário para alcançar os resultados.

Segundo os autores, nos casos em que a função objetivo é complexa, existe alta não linearidade e a superfície de resposta é bastante irregular, com diversos mínimos, sendo que nessas situações, os métodos de busca direta são mais eficientes do que os de primeira ordem, pois o segundo acaba convergindo para mínimos locais. Foi testado também um algoritmo híbrido, no qual se inicializa a otimização com o algoritmo de primeira ordem utilizando o pacote PVM e, posteriormente, utiliza-se o algoritmo de busca direta para refinar a solução.

Santos e Schiozer (2000) realizaram uma breve revisão bibliográfica sobre o assunto de ajuste de histórico e apresentaram uma metodologia utilizando os módulos de paralelização de simulações, análise de sensibilidades e otimização mostrando que a automatização de partes do processo possibilita a redução de tempo.

Maschio e Schiozer (2004) aplicaram o método de busca linear diagonal, baseado no método de busca direta em um espaço discreto, para aumentar a eficiência em relação ao algoritmo de busca linear em conjunto com uma metodologia de ajuste de histórico assistido. A técnica resultou na redução do número de simulações para os casos estudados.

Maschio e Schiozer (2005) realizaram ainda um estudo comparativo da aplicação de uma técnica de busca direta e um método baseado em cálculo de gradientes. O método dos gradientes reduz o esforço computacional, porém, o método baseado em busca global se mostrou mais eficiente para casos que possuem mais de um mínimo local.

Maschio *et al.* (2006) testaram a aplicação do método Simplex ao problema de ajuste de histórico, avaliando a versão contínua e discreta do algoritmo e comparando com o algoritmo de *Hooke & Jeeves*, baseado na busca direta, mostrando que a técnica possui um bom potencial para ser aplicada em problemas de ajuste de histórico.

Schulze-Riegert e Ghedan (2007) realizaram revisão de técnicas e metodologias para ajuste de histórico e análise de incertezas, ressaltando suas importâncias e aplicabilidades. Para ajuste de histórico foi realizada uma introdução e discussão sobre algoritmos evolucionários, otimização multiobjectivo e métodos de superfície de resposta (metamodelos). Segundo os autores, a aplicabilidade de metamodelos deve ser avaliada caso a caso, analisando os objetivos do estudo.

Schiozer *et al.* (2009) realizaram uma breve introdução ao assunto de ajuste de histórico e utilizaram três exemplos de aplicação para mostrar os problemas inerentes ao processo com aumento da complexidade. Um enfoque maior no processo de ajuste assistido foi dado, ressaltando suas características e vantagens em relação ao método tradicional e automático de ajuste.

Esses são apenas alguns dos exemplos encontrados na literatura. Uma boa ênfase tem sido dada à realização de estudos comparativos e ao desenvolvimento de novas metodologias para aplicação nessa área.

3.2 Aplicação de redes neurais artificiais e metamodelos

A utilização de RNA para gerar metamodelos tem ganhado destaque, pois se trata de uma excelente ferramenta para ser utilizada em casos com alta não linearidade entre entrada e saída. Com relação à aplicação de RNA aos problemas da área de petróleo os seguintes trabalhos foram consultados:

Doraisamy *et al.* (2000) aplicaram RNA para determinar a localização para alocação de novos poços em problemas de desenvolvimento de campo. Para tal propósito a RNA foi treinada utilizando as saídas geradas pelo simulador de escoamento. Seus resultados mostraram que a ferramenta pode trazer vantagens quando aplicada em conjunto com o simulador.

Mohaghegh (2000) realizou uma breve introdução a respeito de RNA e citou algumas de suas aplicabilidades na indústria de petróleo, ressaltando que é recomendável a utilização da ferramenta em casos em que a modelagem matemática do problema se torna muito complexa. Em tais casos, as RNA podem ser construídas para observar o comportamento do sistema (que tipo de saída é produzido como resposta a certos valores de entrada) de modo a buscar “imitar” esse comportamento.

Hirschen e Schafer (2006) aplicaram o método de regularização bayesiana para treinamento de RNA para determinação de parâmetros que definam a geometria de uma junção de canais, nos quais resultem na menor queda de pressão. O metamodelo gerado foi utilizado no lugar do simulador numérico no processo de otimização dos parâmetros. Seus estudos mostraram que redes treinadas com regularização bayesiana são melhores que redes convencionais (sem aplicação da regularização) para o caso estudado, porém, mais estudos na modelagem da rede e consequente melhoria na capacidade de aproximação se mostraram necessários.

Lima *et al.* (2009) estudaram algumas formas de aplicação de metamodelos gerados por técnicas de planejamento estatístico em um reservatório sintético para o problema de ajuste de histórico. Seus estudos mostraram que utilizar o metamodelo para determinar a região de mínimo e depois realizar uma otimização local é mais eficiente do que realizar todo o processo de ajuste apenas com o metamodelo ou apenas com um algoritmo de otimização (usando somente o simulador). Os autores ainda observaram que o metamodelo não foi capaz de representar com

precisão a região de mínimo quando treinada para representar o reservatório inteiro para o caso estudado.

3.3 Metamodelos gerados por redes neurais artificiais no processo de ajuste de histórico

Para aplicação de RNA no processo de ajuste de histórico, encontram-se diversos estudos na literatura, sendo destacados alguns deles.

Al-Thuwaini *et al.* (2006) estudaram a aplicação de SOM (*Self Organizing Maps*) para agrupar blocos do reservatório por regiões com propriedades semelhantes, possibilitando realizar ajustes de parâmetros de forma regional.

Cullick *et al.* (2006) utilizaram RNA em conjunto com planejamento estatístico para gerar metamodelos representativos do simulador. O metamodelo gerado foi utilizado no processo de otimização para gerar valores iniciais para otimização direta com o simulador. Seus resultados mostraram que a utilização do metamodelo proporciona bons resultados com menos simulações.

Silva *et al.* (2006) testaram a utilização de algumas RNA como *RBN* (*Radial Basis Network*) e *GRNN* (*Generalized Regression Neural Network*) para serem utilizadas para representar o simulador, ressaltando a importância de escolher uma arquitetura adequada ao caso a ser estudado a fim de obter boa generalização e número reduzido de simulações. Segundo o autor, um metamodelo pode ser considerado ótimo se o coeficiente de correlação linear entre resultados do simulador e do metamodelo estiverem entre 0.7 e 0.8.

A ferramenta MATLAB[®] da empresa The Mathworks Inc., utilizada nesse trabalho, calcula o coeficiente de correlação linear de acordo com a Equação 3.1.

$$r_k = \frac{\sum_{t=1}^N (x_t - \bar{x}) \cdot (x_{t+k} - \bar{x})}{\sum_{t=1}^N (x_t - \bar{x})^2} \quad \text{Equação 3.1}$$

em que x_t representa o dado no passo t , k representa o atraso e a média é dada pela Equação 3.2.

$$\bar{x} = \sum_{t=1}^N \frac{x_t}{N}$$

Equação 3.2

A função *corrcoef* utilizada pelo MATLAB® produz uma matriz de coeficientes de correlação linear, na qual cada coluna representa um dado diferente. Os valores podem variar de -1 a 1, onde valores próximos de 1 indicam que há uma correlação linear positiva entre os dados; valores perto de -1 indicam que há uma correlação linear negativa entre os dados e valores próximos de zero indicam que não existe nenhuma correlação linear entre os dados.

Zangl *et al.* (2006) estudaram a aplicação de metamodelos gerados por RNA em processos de otimização de produção e atentaram para alguns fatores.

- O resultado gerado pela rede não será confiável caso seja utilizado como entrada valores que excedam os limites de variação para a qual a rede foi treinada.
- As configurações da rede são baseadas unicamente em observações numéricas, sem levar em consideração qualquer natureza ou conhecimento do problema, não existindo uma equação ou função que explique o valor gerado na saída. Assim, com os atuais recursos tecnológicos não é possível representar de forma analítica a resposta gerada pela rede, em relação à entrada.
- Se o problema possui grau de liberdade elevado, muitas restrições e dependências presentes ou pouca correlação entre espaço de entrada e saída, a rede não será capaz de realizar uma representação satisfatória do comportamento desejado.

Assim a aplicação da ferramenta, para cada caso, deve ser cuidadosamente analisada.

Ramgulam *et al.* (2007) estudaram a aplicação de RNA para estimativa de atributos incertos do reservatório, realizando diversos testes para definição de arquiteturas de redes e adição de propriedades nos dados de treinamento da rede. Um exemplo de adição de propriedades utilizada pelo autor é o quociente entre a distância do poço produtor até o limite do reservatório e a permeabilidade em cada região (D/k) ou o quociente entre a área de cada região e a permeabilidade de cada região (A/k). A metodologia foi capaz de reduzir o erro entre os dados histórico e simulado e o número de simulações necessárias para atingir um bom ajuste.

Maschio *et al.* (2008) utilizaram metamodelos gerados a partir de RNA para utilização no processo de ajuste de histórico, mostrando que a ferramenta é capaz de reduzir bem o erro entre resultados do simulador e do histórico com um número menor de simulações. A qualidade do ajuste foi medida utilizando a expressão mostrada na Equação 3.3:

$$A = \left[1 - \left(\frac{Ajustado}{Base} \right) \right] \cdot 100 \quad \text{Equação 3.3}$$

em que “Ajustado” representa o afastamento (com relação ao histórico) do modelo ajustado e “Base” representa o afastamento (com relação ao histórico) do modelo base (Caso Base).

Os autores atentaram para o fato de que, para uma aplicação correta da técnica, a escolha dos pontos e método de treinamento é fundamental, sendo necessário aprimorar o processo de treinamento e geração dos metamodelos. Esse constituiu o ponto de partida e motivação para o presente trabalho.

De acordo com a Equação 3.3, a qualidade do ajuste é medida em uma escala que vai de algum valor negativo até 100%. Valores entre 0% e 100% representam uma melhora do ajuste em relação ao Caso Base. O valor 100% representa um ajuste perfeito. Em contrapartida, valores negativos significam que houve uma piora em relação ao Caso Base. Vale lembrar que o afastamento é calculado utilizando a fórmula descrita pela Equação 2.1. Assim, por se tratar de uma soma quadrática o valor do coeficiente de ajuste (A) terá o mesmo valor, caso a curva esteja espelhada do lado oposto em relação ao histórico.

A Figura 3.1 mostra o comportamento do indicador (Q) da curva de produção de um determinado modelo com relação à curva de produção do Caso Base.




Figura 3.1 – Exemplo do indicador de qualidade de ajuste com relação ao Caso Base.

Sampaio *et al.* (2009) estudaram a aplicação de RNA do tipo direta (*feedforward*) para aplicação em um caso de ajuste de histórico, relatando as dificuldades existentes em definir e configurar uma rede adequadamente.

Zubarev (2009) estudou a utilização de metamodelos como substitutos do simulador em algumas áreas, entre elas o ajuste de histórico. Em seu estudo o autor utilizou diferentes técnicas para criação dos metamodelos. Seus resultados mostraram que a qualidade do metamodelo é altamente dependente da qualidade dos dados de treinamento e de teste, sendo este seu ponto fraco. Se o conjunto de entrada possui informações a respeito do ótimo global, então este poderá ser encontrado, caso contrário, há uma grande chance de parar em ótimos locais. Tratando especificamente de RNA, diferentes topologias geram diferentes resultados. Além disso, elas “suavizam” o formato da superfície de resposta (fato que se torna mais evidente em casos em que a superfície possui muitas irregularidades), o que gera um erro inerente à aplicação da técnica. Assim, conhecer suas limitações e definir um critério de confiabilidade é importante.

Como pôde ser observado existem inúmeras metodologias para ajuste de histórico, como métodos de gradiente, de busca global, algoritmos híbridos, paralelização de simulações, utilização de metamodelos e tantos outros não mencionados aqui. Isso reforça o fundamento de que o processo de ajuste pode ser extremamente complexo, possuindo particularidades a cada caso, de modo que uma ferramenta que serve para um determinado caso pode não servir para outro, e vice-e-versa. Assim, estudos e atualizações nessa área devem ser constantemente realizados.

Vários trabalhos mostram que a aplicação de RNA no problema de ajuste de histórico pode contribuir para a redução do número de simulações. Porém, conforme ressaltado por Zubarev (2009) a qualidade das RNA depende das variáveis de entrada, utilizadas no processo de treinamento. Em problemas de ajuste de histórico a escolha das variáveis de entrada influencia diretamente nos resultados, em que a quantidade e qualidade dos dados são cruciais para obter bons ajustes. Como cada caso possui particularidades, é difícil definir a quantidade mínima necessária para proporcionar resultados satisfatórios. A melhor maneira de se determinar a quantidade e qualidade desejada dos dados é através da experiência dos profissionais da área e da avaliação dos objetivos propostos. Dessa maneira, a compreensão da influência que as variáveis

de entrada exercem sobre o desempenho do metamodelo gerado por RNA contribui para melhorar a qualidade dos resultados proporcionados pela ferramenta.

4 METODOLOGIA

Com o intuito de deixar claros os objetivos do estudo e escolher os casos de aplicação mais adequados à proposta, a metodologia desse trabalho foi dividida em duas partes. A primeira parte consistiu na metodologia geral do trabalho, na qual foram definidos basicamente os objetivos de estudo, os casos de aplicação e o procedimento de ajuste a ser adotado. A segunda parte consistiu na metodologia específica, em que o procedimento de ajuste foi definido.

4.1 Metodologia geral do trabalho

As etapas seguidas pela metodologia geral do trabalho estão descritas no fluxograma da Figura 4.1.

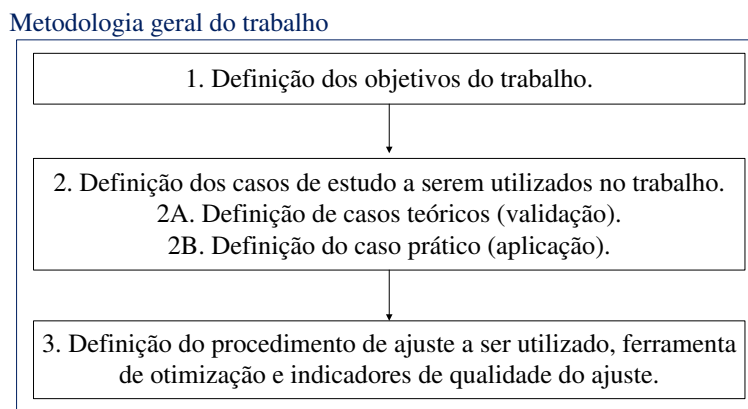


Figura 4.1 - Fluxograma descrevendo as etapas utilizadas para realização da metodologia geral do trabalho.

A Etapa 1 da metodologia geral consistiu em definir os objetivos a serem alcançados através do processo de ajuste. Conforme especificado no Subitem 1.2 (Objetivos), o objetivo foi avaliar a aplicação de metamodelos gerados através de redes neurais artificiais no processo de ajuste de histórico, e, posteriormente, avaliar a forma de utilização da ferramenta em conjunto com o simulador de escoamento. Dessa maneira, o foco não foi conseguir ao final um ajuste perfeito das

curvas, mas avaliar a aplicação da ferramenta como substituta do simulador de escoamento ou complementar.

A Etapa2 consistiu em definir os casos de estudo para aplicação da metodologia, sendo dividida em duas subetapas.

Na Etapa 2A foram definidos casos analíticos, de apenas duas variáveis, para avaliar as características e limitações com relação à aplicação das RNA, e um caso simples de reservatório para validar os resultados obtidos. Como são casos de duas variáveis, foi possível realizar uma avaliação direta do comportamento da superfície de resposta gerada pela RNA.

Na Etapa 2B, foi definido um caso complexo de reservatório com características reais, para simular uma aplicação prática.

A Etapa3 consistiu em definir o procedimento de ajuste, a ferramenta utilizada para otimização e os indicadores de qualidade a serem utilizados nos casos de estudo.

Para esse trabalho um procedimento semelhante ao de Ertekin *et al.* (2001) e aos utilizados nos trabalhos de Cullick *et al.* (2006), Maschio *et al.* (2008) e Sampaio *et al.* (2009) foi elaborado e será descrito no Subitem 4.2 a seguir.

Para realizar o processo de otimização dos parâmetros foi escolhido o Algoritmo Genético. Como indicador da qualidade dos metamodelos gerados, nos casos analíticos, utilizou-se principalmente a superfície de resposta para avaliar os resultados. Como indicadores secundários foram utilizados o coeficiente de correlação (Equação 3.1) e o erro médio. Para os casos de reservatório, foi empregado o coeficiente de correlação como indicador principal para avaliação e comparação do desempenho de cada metamodelo gerado, uma vez que não é possível realizar a análise visual da superfície de resposta. Os valores do coeficiente de correlação e erro médio são calculados entre a saída desejada e a gerada pela RNA. Para o caso prático ainda foi utilizado um indicador que mede quanto o modelo ajustado melhorou o afastamento em relação ao Caso Base, descrito pela Equação 3.3 e ilustrado na Figura 3.1, além da análise das curvas de produção, comparando os resultados do modelo de simulação ajustado com o histórico.

4.2 Metodologia específica - procedimento de ajuste

O procedimento de ajuste adotado consistiu em utilizar metamodelos gerados através de RNA para realizar a parte de alteração dos atributos do reservatório (exploração do espaço de soluções). Os passos seguidos para realizar o procedimento de ajuste estão descritos no fluxograma mostrado na Figura 4.2.

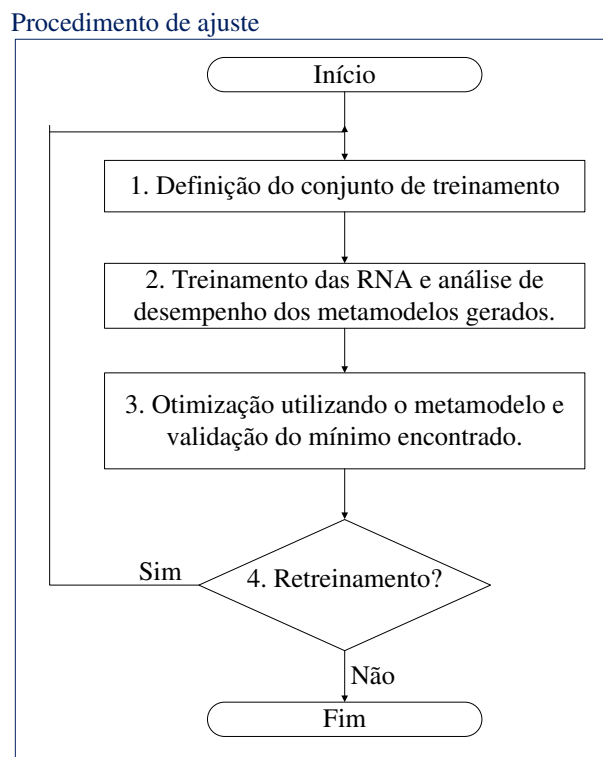


Figura 4.2 – Fluxograma que descreve os passos seguidos pelo procedimento de ajuste adotado nesse trabalho.

O procedimento mostrado na Figura 4.2 pode ser dividido em duas partes principais; treinamento das RNA (geração dos conjuntos de treinamento; treinamento e avaliação dos metamodelos gerados – Passos 1 e 2) e a aplicação do metamodelo gerado no processo de ajuste de histórico (Passos 3). E adicionalmente, se necessário, Passo 4.

4.2.1 Treinamento das redes neurais artificiais

O Passo 1 consistiu na definição do conjunto de treinamento, formado pelas entradas e saídas desejadas da rede, que são as variáveis de modelagem e as respostas do dado problema, respectivamente. Para gerar as entradas foram utilizadas técnicas de amostragem distintas. Dessa maneira, conjuntos com diferentes características de espaçamento e quantidade de amostras foram obtidos. Ao serem geradas, as entradas foram utilizadas para determinar as saídas desejadas, que representam as respostas do problema.

Os casos analíticos são funções em que a superfície de resposta é descrita por uma equação. Assim, as saídas desejadas para esses casos foram determinadas calculando o valor da função, dado pela resposta da equação para as duas variáveis de entrada.

Nos casos de reservatório, as saídas desejadas foram determinadas com o auxílio do simulador de escoamento. A entrada gerada (atributos que modelam o reservatório, ou seja, um modelo de simulação) é simulada com o simulador de escoamento e as curvas de produção são comparadas com o histórico para calcular o afastamento do modelo com relação ao histórico, parâmetro que consistiu na saída desejada para esses casos.

O Passo 2 consistiu no treinamento das RNA e análise de desempenho dos metamodelos gerados. Nesse trabalho, a RNA treinada é chamada de metamodelo. Para avaliar o desempenho dos metamodelos gerados foram utilizados os indicadores definidos na Etapa 4 da metodologia geral (Subitem 4.1).

A respeito do treinamento das RNA, alguns algoritmos empregados no processo de treinamento, que não serão abordados nesse trabalho, possuem certo grau de aleatoriedade, de modo que, a cada treinamento, um metamodelo diferente é gerado. Dessa maneira, o processo de treinamento foi realizado diversas vezes com a finalidade de encontrar um metamodelo capaz de atender aos requisitos com a confiabilidade desejada.

4.2.2 Aplicação de metamodelos no processo de ajuste de histórico

Cullick *et al.* (2006), Maschio *et al.* (2008) e Sampaio *et al.* (2009) utilizaram metamodelos gerados a partir de RNA para realizar a otimização dos atributos no lugar do simulador de escoamento. Apesar de utilizarem diferentes ferramentas para otimização e diferentes FO, a metodologia utilizada pelos autores foi capaz de encontrar resultados satisfatórios, e dessa maneira, serviu como base para a aplicação do algoritmo genético.

O Passo 3 do procedimento de ajuste consistiu na otimização utilizando o metamodelo e validação do mínimo encontrado. Na otimização utilizou-se o metamodelo gerado para calcular o valor da Função Objetivo (FO) a ser minimizada pelo AG. Para validação, nos casos analíticos o mínimo encontrado foi comparado com o mínimo global do problema, determinado através da otimização utilizando a equação que define cada caso. Já para os casos de reservatório, como na prática a resposta não é conhecida, a validação é realizada através da comparação das curvas de produção do modelo simulado com o histórico de produção e pressão medido nos poços. O modelo simulado consiste no mínimo encontrado através da otimização, em que, conforme mencionado, o metamodelo gerado é utilizado para calcular a FO no processo de minimização.

Uma maneira de melhorar a capacidade de representação e generalização da rede é realizar um novo treinamento em uma região específica do espaço de soluções, pois com uma região reduzida torna-se mais fácil a representação pelo metamodelo. Com o Passo 3, acredita-se que o mínimo encontrado esteja nas proximidades do mínimo global do problema.

Dessa maneira, para casos em que o valor encontrado com a otimização não atenda aos critérios de precisão desejados, mas que estejam relativamente próximos (o quão próximo varia de caso a caso) define-se uma região de interesse ao redor do valor encontrado (mínimo) e realiza-se novo procedimento de treinamento (repetição dos Passos 1, 2 e 3). Assim, o Passo 4 consistiu em avaliar e, caso constatada a necessidade, realizar novo treinamento em um subdomínio do espaço de busca.

Para a definição de uma nova faixa de variação dos atributos adotou-se o seguinte procedimento:

- A partir dos resultados da otimização com o metamodelo tomou-se como base os indivíduos que geraram valores de FO inferiores a um determinado valor de corte (particular a cada caso);
- Dentre os indivíduos que atendem à condição anterior consideraram-se os limites máximo e mínimo de variação dos atributos para nova amostragem, os quais definiram uma nova região de interesse.

Para os casos analíticos, em caso de novo retreinamento, a definição da nova região para amostragem foi feita a partir da avaliação visual da superfície de resposta, por ser mais direta e precisa.

5 APLICAÇÃO

Esse capítulo é dedicado à apresentação dos casos de estudo aos quais a metodologia proposta foi aplicada. Foram escolhidos quatro casos analíticos, um caso de reservatório simples (validação) e um caso de reservatório complexo com características reais.

5.1 Casos analíticos

Para os casos analíticos, primeiramente foi escolhido um caso simples para iniciar os estudos; posteriormente, um caso em que a superfície de resposta a ser modelada possui alguma irregularidade, com um mínimo global e um local; um caso com diversas irregularidades, com mais de um mínimo global e diversos mínimos locais (diversas regiões de interesse) e, finalmente, um caso em que a superfície de resposta é modelada por mais de uma função. Com isso buscou-se avaliar as características e limitações da ferramenta para casos com diferentes graus de dificuldade.

5.1.1 Premissas e considerações

Os casos analíticos consistiram em casos de duas variáveis, em que a superfície de resposta é descrita por uma equação.

O mínimo global de cada problema foi determinado através do processo de otimização, utilizando a equação que descreve a função para calcular o valor da Função Objetivo. O mínimo encontrado nesse processo foi considerado como sendo o mínimo global da função.

Para esses casos, a superfície de resposta foi utilizada como parâmetro principal na avaliação do desempenho do metamodelo gerado.

Como complementos foram utilizados o coeficiente de correlação, cuja expressão foi mostrada na Equação 3.1 (Capítulo 3), e o erro entre a saída desejada e gerada pelo metamodelo, mostrado abaixo na Equação 5.1.

$$E_m = \frac{\sum \left[\left(\frac{d_{sim} - d_{obs}}{d_{obs}} \right) \cdot 100 \right]}{n} \quad \text{Equação 5.1}$$

em que d_{sim} representa os dados simulados com o metamodelo, d_{obs} representa os dados calculados diretamente com a função analítica e n representa o número total de amostras

5.1.2 Caso 1A

O Caso 1A é o mais simples, representado por uma superfície com concavidade voltada para baixo e com um mínimo global, conforme mostra a Figura 5.1. Esse caso foi utilizado apenas para iniciar os estudos, com o intuito de mostrar que para casos extremamente simples a RNA modela a resposta desejada sem dificuldades.




Figura 5.1 – Superfície de resposta para o Caso 1A.

A saída desejada para treinar a RNA consistiu no valor da função que modela a superfície, mostrada pela Equação 5.2:

$$z = x^2 + y^2$$

Equação 5.2

5.1.3 Caso 1B

A superfície de resposta do Caso 1B é mostrada na Figura 5.2, a seguir:




Figura 5.2 – Superfície de resposta para o Caso 1B.

A saída desejada para treinar a RNA consistiu no valor da função que modela a superfície, mostrada pela Equação 5.3:

$$z = 3 \cdot (1 - x^2) \cdot e^{-(x^2 - (y+1)^2)} - 10 \cdot (x/5 - x^3 - y^5) \cdot e^{(-x^2 - y^2)} - \dots$$

$$1/3 \cdot e^{-(x+1)^2 - y^2}$$

Equação 5.3

Como pode ser observado na Figura 5.2, a superfície de resposta para esse caso possui um mínimo global e um mínimo local.

5.1.4 Caso 1C

Esse caso possui uma superfície de resposta irregular, com mais de um mínimo global (quatro no total) e diversos mínimos locais, conforme pode ser observado na Figura 5.3:




Figura 5.3 – Superfície de resposta para o Caso 1C.

A saída desejada para treinar a RNA consistiu no valor da função que modela a superfície, mostrada pela Equação 5.4:

$$z = x \cdot \sin(4x\pi) - y \cdot \sin(4y\pi + \pi) + 1 \quad \text{Equação 5.4}$$

5.1.5 Caso 1D

O Caso 1D é modelado por uma função pré-definida pelo *Matlab* chamada *NonSmothFcn*, formada por três diferentes superfícies e possui apenas um mínimo global, conforme pode ser visualizado na Figura 5.4.




Figura 5.4 – Superfície de resposta para o Caso 1D.

A saída desejada para treinar a RNA consistiu no valor da função no espaço que é retornada automaticamente através da função *NonSmoothFcn* do *Matlab*.

5.2 Casos de reservatório

Para os dois casos de reservatório (2A e 2B) utilizou-se o mesmo modelo, porém para o Caso 2A foram realizadas algumas modificações para simular um caso simples de validação dos resultados obtidos com o estudo dos casos analíticos.

5.2.1 Premissas e considerações

Trata-se de um reservatório sintético no qual o histórico é conhecido. Os atributos incertos do reservatório são fornecidos, de forma que se considera que sejam os que mais influenciam na produção de água do reservatório.

Para os casos de reservatório foi utilizado como indicador principal para avaliação de desempenho o coeficiente de correlação linear entre saída do metamodelo e do simulador. Como não é possível realizar a visualização da superfície de resposta, graficamente foi utilizada a

relação entre os afastamentos gerados através da simulação com o simulador de escoamento (histórico) e aqueles gerados através da simulação com os metamodelos.

5.2.2 Reservatório utilizado

O modelo, construído sinteticamente através de técnicas geoestatísticas, é mostrado na Figura 5.5.




Figura 5.5 - Modelo de reservatório (permeabilidade horizontal – md).

O modelo mostrado na Figura 5.5 representa um reservatório de óleo leve, cujo mecanismo de produção natural é a expansão de líquido e gás em solução e o mecanismo de recuperação é a injeção de água. Ele foi discretizado em uma malha *corner point* com dimensão 90x110x5 (49500 blocos), é composto por três fácies caracterizadas de acordo com três faixas de permeabilidades (baixa, intermediária e alta) e possui quatro falhas, representadas pelas linhas em preto na Figura 5.5. Um modelo de referência (escolhido dentre as possíveis combinações dos dezesseis atributos incertos do problema) foi simulado para gerar o histórico de dez anos. O reservatório é drenado por quinze poços verticais (oito produtores e sete injetores). Os dezesseis atributos, considerados de maior impacto sobre o comportamento do reservatório são mostrados no Subitem 5.2.4.

5.2.3 Caso 2A

Os atributos incertos do reservatório para o Caso 2A foram definidos como sendo o multiplicador da porosidade da fácies 2, o multiplicador do logaritmo da permeabilidade horizontal da fácies 2, a transmissibilidade da falha 3 e o expoente do modelo de *Corey* para a permeabilidade relativa da água da fácies 2, totalizando 4 atributos incertos, que estão elencados na Tabela 5.1.

Tabela 5.1 – Atributos incertos para o caso 2A.

Atributos	Descrição	Tipo	Min.	Máx.
1	Porosidade (Por2) – fácies 2	Multiplicador	0.85	1.15
2	Permeabilidade horizontal (kx2) - fácies 2	Multiplicador do log. (kx)	0.75	1.1
3	Transmissibilidade da falha (T3)	Multiplicador	0	1
4	Permeabilidade relativa (kr2) - fácies 2	Expoente da fase água (modelo de <i>Corey</i>)	1	5

Para esse caso o problema consistiu em realizar o ajuste da vazão de água do campo (apenas uma saída). Assim, para gerar os metamodelos, os valores de saída desejada utilizados foram o afastamento da vazão de água do campo (entre modelo simulado e o histórico).

5.2.4 Caso 2B

Para o Caso 2B os atributos incertos foram definidos como sendo o multiplicador do logaritmo da permeabilidade horizontal, multiplicador da porosidade, razão entre permeabilidades vertical e horizontal e o expoente do modelo de *Corey* para permeabilidade relativa da água. Como o modelo é caracterizado por três fácies, conforme citado anteriormente no Subitem 5.2.2, os atributos incertos são considerados distintos para cada fácies. O modelo ainda possui quatro falhas, conforme pode ser observado na Figura 5.5. A transmissibilidade de cada falha também foi incluída na lista de atributos incertos, totalizando, assim, dezesseis variáveis incertas, mostradas na Tabela 5.2, que serão modificadas no processo.

Tabela 5.2 – Atributos incertos para Caso 2B.

Atributos	Descrição	Tipo	Min.	Máx.
1 ao 3	Porosidade (Por1-3)	Multiplicador	0.85	1.15
4 ao 6	Permeabilidade horizontal (kx1-3)	Multiplicador do log. (kx)	0.75	1.1
7 ao 9	Permeabilidade vertical (kz1-3)	Porcentagem de kx	4	25
10 ao 13	Transmissibilidade da falha (T1-4)	Multiplicador	0	1
14 ao 16	Permeabilidade relativa (kr1-3)	Expoente da fase água (modelo de <i>Corey</i>)	1	5

O objetivo desse caso foi realizar o ajuste de vazão de água de cada poço (oito poços produtores), sendo assim, o problema composto por uma Função Objetivo calculada pela média de oito componentes a ser minimizada. Deste modo, cada valor de saída desejada, utilizada para gerar os metamodelos, corresponde ao afastamento de um poço (diferença entre vazão de água do modelo simulado e o histórico).

5.3 Geração dos conjuntos de entrada para treinamento

Para a amostragem dos conjuntos de entrada foram utilizadas as técnicas de Hipercubo Latino (HL), Sequencia de Sobol (SS) e Box Behnken (BB). Com isso obtiveram-se amostras dispostas de forma diferente no espaço dos parâmetros. Adicionalmente a esse fator foram gerados amostras de 25, 50 e 100 pontos para os Casos 1A a 1D. Para o Caso 2A as mesmas quantidades de pontos foram amostradas, porém utilizando apenas a técnica do HL. Para o Caso 2B, 100, 250 e 396 pontos foram amostrados utilizando as técnicas do HL e BB (apenas um conjunto com 396 pontos, que é o número de combinações pré-fixado pela técnica de Box Behnken para 16 variáveis). Nos casos de reservatório, cada conjunto de dados de entrada amostrado representa um modelo de simulação.

Uma observação a ser feita é que a técnica do BB, conforme mencionado no Subitem 2.5, para poucas variáveis a quantidade de pontos amostrados é muito baixa. Por isso ela foi aplicada apenas para o Caso 2B, que contém 16 variáveis de entrada (resultando em 396 amostras: 16 atributos, 3 níveis = 16^3 pontos). Dessa maneira, para os Casos 1A e 1D foi utilizada a SS, a fim de obter uma comparação entre dados com diferentes características de espaçamento. No Caso 2A, como foi utilizado apenas para validação, aplicou-se somente o HL para gerar os dados.

Com relação aos dados de teste, nos Casos 1A a 1D, os pontos de treinamento gerados por uma técnica foram utilizados como pontos de teste para a outra e vice-e-versa, ou seja, foram utilizados os 100 pontos amostrados da SS para testar os metamodelos gerados com dados do HL e os 100 pontos amostrados pelo HL para testar os metamodelos gerados com dados da SS. Já para o Caso 2A foram gerados 25 pontos pelo HL e para o Caso 2B foram gerados 100 pontos pelo HL para realizarem as simulações de teste.

As saídas desejadas, para os Casos 1A a 1D foram calculadas utilizando a equação que define cada caso. Já para os casos de reservatório, foram geradas através do simulador de escoamento utilizando o programa IMEX da CMG. Os dados de produção de água, resultantes da simulação, foram comparados com o histórico de produção disponível e o afastamento foi calculado, compondo dessa maneira as saídas desejadas para esses casos.

Conforme citado anteriormente, para o Caso 2A o afastamento do campo foi utilizado. Já para o Caso 2B, foi usado o afastamento poço a poço. A fórmula utilizada para calcular o afastamento é a mesma mostrada na Equação 2.1, considerando o valor do peso igual a “1” para todos os dados, resultando na expressão mostrada na Equação 5.5.

$$D = \sum_{i=1}^N (d_{obs}^i - d_{sim}^i)^2 \quad \text{Equação 5.5}$$

em que N representa o número de dados observados de cada série (produção de água, por exemplo), d_{obs}^i e d_{sim}^i são os dados observados e simulados, respectivamente.

Para o Caso 2B, foi realizada a análise de sensibilidade para gerar conjuntos adicionais de entrada a fim de melhorar a qualidade dos resultados e realizar comparações entre os diversos metamodelos gerados. Assim, para entrada foram utilizadas duas opções de configuração:

- Opção 1: utilizar todos os atributos incertos;
- Opção 2: utilizar os atributos determinados através da AS.

Nesse procedimento foram realizadas simulações (com o simulador de escoamento) com valores extremos de cada atributo (máximo e mínimo) enquanto se mantém as outras no valor do Caso Base (valor médio). Assim, avaliou-se quanto o afastamento dos poços variou com um dado

atributo em relação ao afastamento do Caso Base, possibilitando, dessa maneira, identificar quais atributos influenciam mais a FO para o caso a ser estudado. Com isso, determinaram-se os seguintes atributos para treinar a RNA, mostrados na Tabela 5.3.

Tabela 5.3 – Atributos que mais influenciam os poços.

Atributo	Atributo	Poço								Média
		1	2	3	4	5	6	7	8	
Porosidade (Por)	1	x								
	2	x	x	x		x	x	x	x	x
	3		x	x			x			x
Permeabilidade horizontal (kx)	4		x			x	x		x	x
	5	x		x		x	x		x	x
	6	x	x				x		x	x
Permeabilidade vertical (kz)	7									
	8		x			x			x	x
	9			x			x			
Transmissibilidade da falha (T)	10						x			
	11	x	x							
	12						x			
	13			x	x	x		x		x
Permeabilidade relativa (kr)	14	x							x	
	15	x	x	x	x	x	x	x	x	x
	16		x	x	x	x	x			x

Na Tabela 5.3, os atributos marcados com “x” representam aqueles considerados de maior impacto sobre cada poço e sobre a média dos oito poços, em relação ao comportamento da curva de produção de água. Para tanto foram considerados aqueles atributos nos quais a soma das variações causadas pela alteração de seus valores para os limites máximo e mínimo resultaram em valor maior ou igual a 20%.

Para saída da RNA também foram definidas duas configurações diferentes:

- Opção 1: treinar uma RNA para cada poço, ou seja, treinar oito RNA independentes, de uma saída;
- Opção 2: treinar uma RNA para os oito poços, ou seja, ou RNA com oito saídas.

Assim, os atributos marcados nas colunas “Poço 1” a “Poço 8” foram escolhidos para compor os dados de treinamento para treinar uma RNA para representar cada poço, e os atributos

selecionados na coluna “Média” foram utilizados na opção em que foi treinada uma RNA para representar os oito poços.

Juntando as duas opções de configuração para entrada e para a saída, puderam-se definir quatro opções de configuração de RNA a serem estudadas nesse caso:

- Opção 1 (PP_SAS – por poço, sem análise de sensibilidade):
 - Entrada: todos os dezesseis atributos incertos do reservatório;
 - Saída: treinamento de oito RNA de uma saída, cada uma representando um poço produtor.
- Opção 2 (PROD_SAS – produtores, sem análise de sensibilidade):
 - Entrada: todos os dezesseis atributos incertos do reservatório;
 - Saída: treinamento de uma RNA com oito saídas, representando os oito poços produtores.
- Opção 3 (PP_AS – por poço, com análise de sensibilidade):
 - Entrada: apenas os atributos que mais influenciam no comportamento de cada poço. Nesse caso quais atributos são utilizados como entrada para cada RNA varia. Por exemplo, para a RNA treinada para representar o poço PROD4, de acordo com o resultado da AS mostrada na Tabela 5.3, foram utilizados como entrada os atributos 13, 15 e 16.
 - Saída: treinamento de oito RNA de uma saída, cada uma representando um poço produtor.
- Opção 4 (PROD_AS – produtores, com análise sensibilidade):
 - Entrada: apenas os atributos que mais influenciam no comportamento dos oito poços produtores, ou seja, mais influenciam na média do afastamento da vazão de água dos oito poços produtores.
 - Saída: treinamento de uma RNA com oito saídas, representando os oito poços produtores.

Resumindo, as configurações de RNA aplicadas a cada caso foram:

Casos 1A a 1D:

- Dados de treinamento:
 - 25, 50 e 100 pontos gerados pela técnica do HL
 - 25, 50 e 100 pontos gerados pela técnica da SS
- Dados de teste:
 - RNA treinadas com pontos do HL: 100 pontos gerados pela técnica da SS
 - RNA treinadas com pontos da SS: 100 pontos gerados pela técnica do HL
- Configurações de RNA:
 - Entrada: as duas variáveis de modelagem da função
 - Saída: uma rede para representar o valor da função no ponto

Caso 2A:

- Dados de treinamento:
 - 25, 50 e 100 pontos gerados pela técnica do HL
- Dados de teste:
 - 25 pontos gerados pela técnica do HL
- Configurações de RNA:
 - Entrada: quatro atributos incertos do reservatório (Tabela 5.2)
 - Saída: uma rede para representar o afastamento da produção de água do modelo simulado com relação ao histórico

Caso 2B:

- Dados de treinamento:
 - 100, 250 e 396 pontos gerados pela técnica do HL
 - 396 pontos gerados pela técnica do BB
- Dados de teste:
 - 100 pontos gerados pela técnica do HL
- Configurações de RNA:
 - As quatro opções descritas anteriormente,

5.4 Treinamento das redes neurais artificiais

Para treinar uma RNA é necessário inicialmente criá-la e configurá-la. Para isso foi utilizado o *software* MATLAB[®] da Mathworks Inc., pois ele possui um Toolbox de RNA (*Neural Network Toolbox*) o qual disponibiliza diversas estruturas, algoritmos e funções pré-definidas, cabendo ao usuário configurar a rede da maneira que desejar. Os principais parâmetros configurados são mostrados a seguir.

- Tipo de rede *Feed-Forward* completamente ligada.
- Funções de transferência do tipo tangente hiperbólica na camada oculta e linear (Casos 1A a 1D e 2A) ou tangente hiperbólica (Casos 2A e 2B) na camada de saída.
- Métodos de pré e pós-processamento dos dados: *fixunknowns*, *removeconstantrows* e *mapminmax* para os dados de entrada e *removeconstantrows* e *mapminmax* para os dados de saída. A função *fixunknowns* transforma linhas contendo valores definidos como NAN (desconhecidos) em linhas que processam a mesma informação numericamente; a função *removeconstantrows* remove linhas com valores constantes e a função *mapminmax* transforma valores para intervalos entre -1 e 1 (normalização).
- Algoritmo de treinamento *Levenberg-Marquardt* com *Regularização Bayesiana* - *trainbr*- (maiores informações no Capítulo 2, de fundamentação teórica).
- Método para prevenir contra memorização *Early Stopping*: separação do conjunto de treinamento em três partes: treinamento, validação e teste. O conjunto de treinamento é utilizado para atualizar os valores dos pesos; o conjunto de validação serve para que, de tempo em tempo, a rede seja testada para verificar se está havendo memorização dos dados e, caso positivo, parar o treinamento no momento em que a rede começar a perder a capacidade de generalização (erro de treinamento baixo, porém erro de validação alto); e o conjunto de teste serve para testar a rede após o treinamento. Os dados são separados de forma aleatória, de maneira que o treinamento deve ser realizado diversas vezes para obter resultados satisfatórios. O valor *default* é 60%, 20% e 20% (treino, validação e teste) do total de dados de treinamento e foi o valor adotado nesse trabalho.

Ainda existe o algoritmo de inicialização dos pesos da rede. Esse algoritmo utiliza um padrão tal que os valores dos pesos são inicializados em uma faixa determinada com certo grau de aleatoriedade. Assim, a cada inicialização têm-se diferentes valores dos pesos, o que pode levar a RNA diferentes no final do treinamento. Portanto, é altamente recomendável realizar diversos treinamentos com a mesma configuração para determinar o melhor modelo para o problema.

Com base nas sugestões de Silva e Oliveira (2004), para os Casos 1A a 1D e Caso 2A foi utilizada uma camada oculta e para o Caso 2B, de maior complexidade, foram testadas uma, duas e três camadas para treinar as redes. Para o número de neurônios em cada camada utilizou-se um valor tal que a quantidade de sinapses fosse em torno de dez vezes menor do que o número de amostras utilizadas para treinamento. Para o Caso 2B foram testados mais valores situados ao redor desse patamar para expandir o horizonte de resultados.

Ainda em relação ao Caso 2B, devido à complexidade do problema, foi testada a geração de um metamodelo por poço e um metamodelo para os oito poços produtores, ou seja, foram treinadas oito redes de uma saída e uma única rede com oito saídas. Dentre essas duas possibilidades, foram utilizadas como entrada um conjunto de dados contendo as dezesseis variáveis incertas e um conjunto de dados provenientes da análise de sensibilidade, conforme descrito no Item 5.3.

5.5 Otimização

O processo de otimização foi realizado utilizando o algoritmo genético. O MATLAB[®] também disponibiliza um *Toolbox (Global Optimization Toolbox)* para essa técnica já com as configurações padrão. Foram utilizadas para todos os casos essas configurações com algumas modificações, julgadas necessárias a cada caso. A Tabela 5.4 mostra os valores dos parâmetros principais que foram utilizados pelo AG nos processos de otimização. O tamanho da população refere-se à quantidade de modelos que serão utilizados em cada iteração; o número máximo de gerações representa o máximo de iterações que o algoritmo irá executar; a fração de *crossover* indica quantos indivíduos, do total, sofrerão recombinação (*crossover*); e a taxa de mutação representa a probabilidade de o indivíduo sofrer mutação.

Tabela 5.4 – Principais parâmetros utilizados pelo AG.

Parâmetro	Valor		
	Casos 1A a 1D	Caso 2A	Caso 2B
Tamanho da população	50	50	50
Máximo de gerações	100	500	500
Fração de <i>crossover</i>	0.6	0.8	0.8
Taxa de mutação	50%	50%	50%

6 RESULTADOS E DISCUSSÃO

Os resultados mostrados nesse capítulo referem-se à aplicação do procedimento de ajuste definido no Subitem 4.2 de Metodologia.

Conforme citado no Subitem 4.1, primeiramente foram estudados os casos analíticos (Casos 1A a 1D) e, posteriormente, o caso intermediário (Caso 2A) e complexo (Caso 2B). Assim, os itens subsequentes foram ordenados dessa maneira: casos analíticos, caso intermediário e caso complexo, seguindo os passos do procedimento de ajuste adotado.

Conforme detalhado no capítulo de aplicação, foram utilizados diferentes conjuntos de pontos para treinamento, gerados através das técnicas do HL e SS. Nos itens subsequentes, no entanto, não serão mostrados todos os gráficos e resultados devido ao grande volume de dados obtidos. Serão mostrados apenas alguns resultados, considerados de maior relevância para as conclusões.

6.1 Caso 1A

6.1.1 Passo 1: Definição do conjunto de treinamento

A Figura 6.1 mostra os conjuntos de treinamento de 25 pontos amostrados utilizando as técnicas do HL (a) e SS (b), respectivamente, representados pelos pontos em preto, sobrepostos na superfície de resposta, gerada pela função analítica.

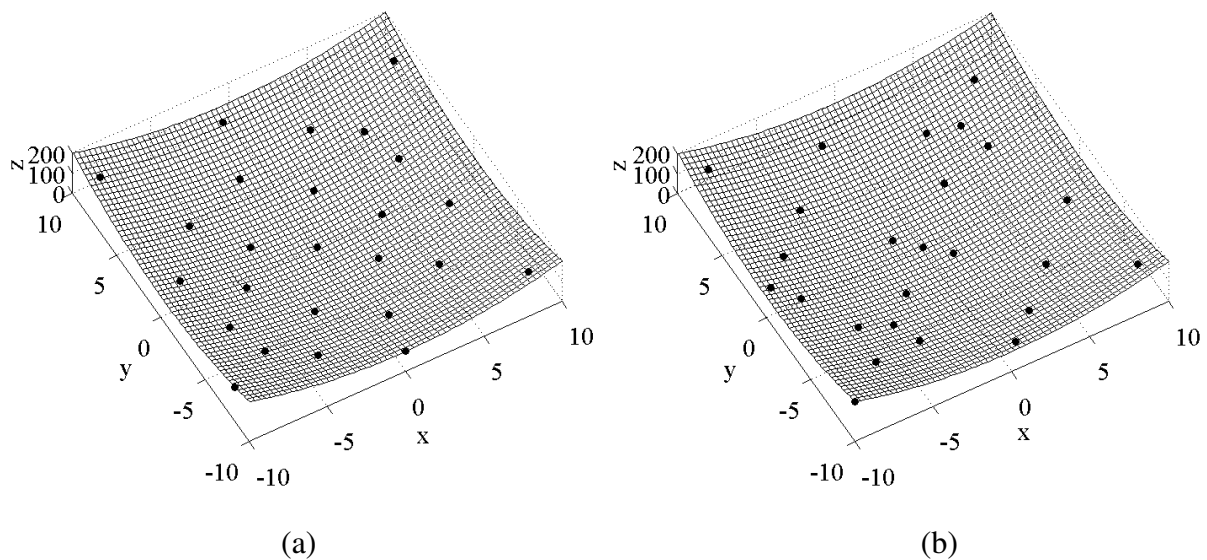


Figura 6.1 – Amostragem no espaço do conjunto de treinamento de 25 pontos; HL (a) e SS (b) – Caso 1A.

Pela Figura 6.1 observa-se que o HL proporcionou espaçamento melhor dos pontos do que a SS, que possui algumas regiões concentradas de pontos. Pode-se observar ainda que 25 pontos são capazes de proporcionar boa cobertura de todo o espaço. Para os demais conjuntos de pontos pôde-se observar melhor cobertura do espaço de soluções e a diminuição dos espaços vazios entre pontos, constantes na Figura 6.1 (b).

6.1.2 Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados

Por se tratar de um caso muito simples, pouca diferença com relação à qualidade do metamodelo pôde ser observada entre os dados gerados com HL25 e SS25.

Para obter um comparativo entre quantidade de amostras, a Figura 6.2 mostra as saídas dos metamodelos, gerados através do treinamento das RNA com HL25 (a) e HL50 (b) pontos.

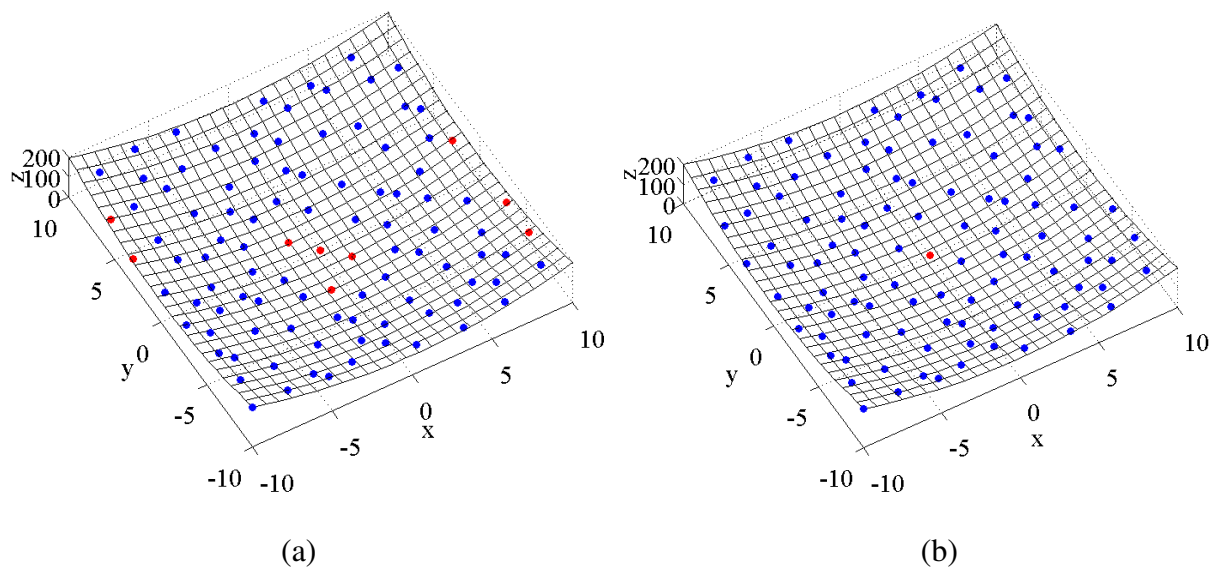


Figura 6.2 – Superfícies de resposta e conjunto de teste, para os metamodelos gerados com HL25 (a) e HL50 (b) – Caso 1A. Pontos em azul: erro médio menor que 1% e pontos em vermelho: erro médio maior ou igual a 1%.

Pode-se observar que o erro para o metamodelo gerado com HL50 pontos foi menor, mostrando que o aumento da quantidade de amostras para treinamento melhorou a capacidade de representação.

O erro pode ser visualizado de forma diferente na Figura 6.3, que mostra os gráficos do erro em função da coordenada do eixo horizontal, para os metamodelos gerados com HL25 (a) e HL50 (b) pontos, em que são mostrados apenas os pontos nos quais o erro foi menor que 4% e 0.012% para os metamodelos gerados com HL25 e HL50 pontos, respectivamente.




Figura 6.3 – Visualização dos erros ponto a ponto para os metamodelos gerados com HL25 (a) e HL50 (b) pontos – Caso 1A.

Os valores dos coeficientes de correlação linear e erro médio entre saídas do metamodelo e saídas calculadas pela equação que modela a função, referentes ao conjunto de teste estão mostrados na Tabela 6.1.

6.1.3 Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado

Os valores dos mínimos encontrados, assim como suas respectivas localizações no espaço estão mostrados na Tabela 6.1. Observa-se que a utilização de 25 amostras para treinamento foi suficiente para alcançar resultados satisfatórios, pois o metamodelo Caso1A_RNA_HL25 encontrou uma coordenada para o mínimo muito próximo da localização real do mínimo global (0,0). Observa-se ainda que a adição de mais amostras para treinamento ajudou a melhorar a precisão.

É importante salientar que, mesmo com muitos pontos, o erro ainda existe, pois o mínimo global não está incluído no conjunto de treinamento, o que induz a RNA a “suavizar” a superfície nessa área.

Comparando-se os resultados obtidos entre os metamodelos gerados com HL e SS, observa-se que os resultados foram bem próximos, não sendo possível concluir qual tipo de ferramenta de amostragem foi a melhor.

Nesse caso não foi necessário realizar o processo de retreinamento, pois conforme mostrado através dos gráficos e tabela apresentados, a região de mínimo foi identificada com precisão com apenas 25 pontos.

Tabela 6.1 – Coeficiente de correlação linear, erro médio e mínimo determinados através da otimização utilizando o metamodelo - Caso 1A.

Tipo de dado	Nome Metamodelo	Erro (%)	Coeficiente correlação	Mínimo (FO)	Variável x	Variável y
HL25	Caso1A_RNA_HL25	0.4195	0.9999	0.16320	0.012000	0.001400
HL50	Caso1A_RNA _ HL50	0.0017	1.0000	0.01700	-0.0000398	0.000034
HL100	Caso1A_RNA _ HL100	0.0011	1.0000	0.000192	0.0000235	0.000257
SS25	Caso1A_RNA _ SS25	0.6919	0.9999	0.07630	0.022700	0.014100
SS50	Caso1A_RNA _ SS50	0.0065	1.0000	0.00100	-0.000227	-0.0000357
SS100	Caso1A_RNA _ SS100	0.0021	1.0000	-0.00034	0.000095	0.0000518

6.2 Caso 1B

6.2.1 Passo 1: Definição do conjunto de treinamento

A Figura 6.4 mostra os pontos amostrados para treinamento (em preto) no espaço de busca dos parâmetros para os conjuntos de HL25 (a) e SS25 (b) pontos.




Figura 6.4 – Amostras de 25 pontos, do HL (a) e da SS (b) para treinamento – Caso 1B.

Observa-se que com 25 pontos poucas informações do comportamento da superfície foram obtidas. Por outro lado, dentre os 25 pontos do HL, um deles se situa na região de interesse, próxima do mínimo global, o que pode fazer com que essa região seja identificada pelo metamodelo gerado.

A Figura 6.5 mostra os conjuntos de treinamento para HL50 e SS50 pontos.

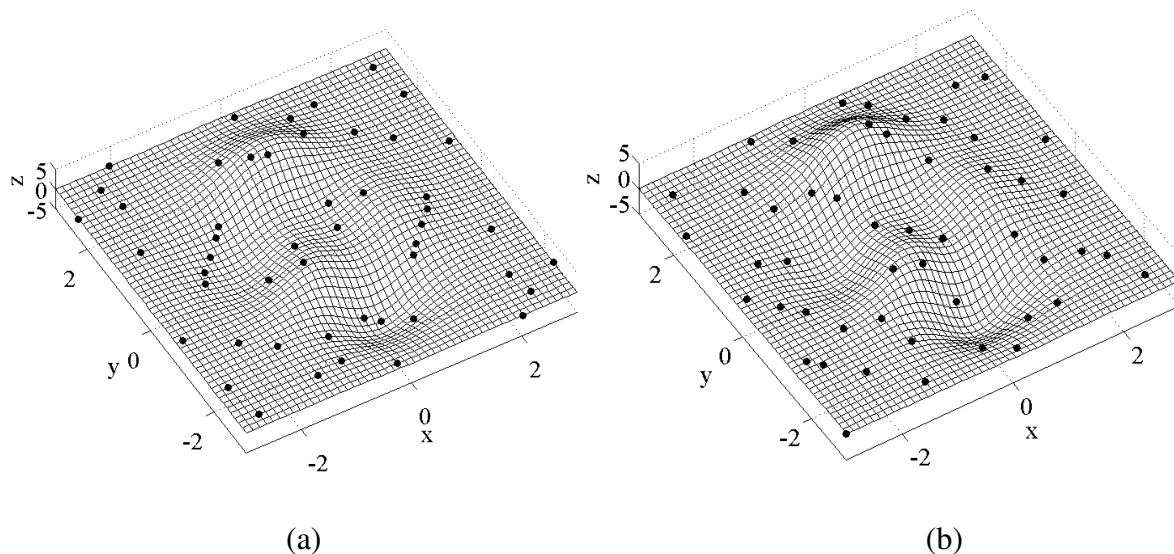


Figura 6.5 - Amostras de 50 pontos, do HL (a) e da SS (b) para treinamento – Caso 1B.

Observa-se que com 50 pontos, informações mais detalhadas sobre a superfície de resposta foram amostradas. Porém, ainda existem espaços vazios, o que pode fazer com que nessas regiões

a precisão seja inferior às demais. No entanto, a presença de um número maior de amostras nas vizinhanças pode fazer com que uma representação satisfatória seja obtida (padrão de comportamento dessas regiões seja representado).

Apesar de não apresentada, a amostragem com 100 pontos, para as duas técnicas, foi capaz de proporcionar uma boa cobertura do espaço de soluções.

6.2.2 Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados

As superfícies de resposta dos metamodelos gerados com HL25 e SS25 pontos são mostradas na Figura 6.6 (a) e (b), respectivamente. Para mostrar os pontos sobre o espaço foi utilizado um ângulo de visão diferente para proporcionar uma avaliação mais eficiente da distribuição dos mesmos. Por outro lado, para mostrar a superfície de resposta do metamodelo foi utilizado outro ângulo de visão, com o intuito de proporcionar uma avaliação mais eficiente de todas as irregularidades presentes. Esse padrão foi aplicado para todos os casos analíticos apresentados.




Figura 6.6 – Superfícies de resposta dos metamodelos gerados com 25 pontos do HL (a) e da SS (b) – Caso 1B.

Pela Figura 6.6, observa-se que apesar de apresentar maior dificuldade em relação ao Caso 1A, o metamodelo gerado com HL25 pontos foi capaz de identificar a região de mínimo. É de se notar que nas regiões às quais pouca ou nenhuma informação (amostragem) foi obtida, o metamodelo não proporcionou boa representação. Esse aspecto pode ser analisado comparando-se as imagens da Figura 6.6 com as da Figura 6.4, que mostram as regiões com e sem informação na amostragem.

Observa-se ainda que, conforme previsto no Subitem 6.2.1, a presença de uma amostra dentro da região de interesse fez com que o metamodelo fosse capaz de fornecer uma boa modelagem dessa região. Da mesma forma a ausência de amostras dentro dessa área para o conjunto SS25 fez com que o metamodelo gerado com esse conjunto não a representasse bem. A comparação entre as duas superfícies da Figura 6.6 deixa claro que a representação proporcionada pelo metamodelo gerado com 25 pontos do HL foi superior a SS, conforme previsto no Subitem 6.2.1.

A Tabela 6.2 mostra os valores dos coeficientes de correlação e do erro médio entre saída do metamodelo e da equação que modela a superfície, relativos ao conjunto de teste para todos os metamodelos.

Observa-se que foram obtidos valores elevados para o erro médio. O motivo se deve ao fato de a parte plana da superfície de resposta desse caso situar-se muito próxima do zero ($z=4.1030 \times 10^{-5}$), de modo que, assim como no Caso 1A, qualquer valor um pouco diferente desse ponto acabou gerando erro elevado. Uma possível saída seria utilizar a diferença simples para medição do erro ao invés da Equação 5.1, ou adicionar uma constante à função para “elevar” a superfície de resposta de modo a evitar a realização de cálculos de valores próximos do zero.

Ao se compararem os valores dos coeficientes de correlação dos metamodelos gerados com HL25 e SS25, os valores foram semelhantes, porém, como mostra a Figura 6.6, a superfície modelada com cada um foi diferente. Assim, através da análise dos resultados fica clara a importância de realizar a avaliação conjunta entre resultados numéricos e gráficos, pois a avaliação de apenas um deles isoladamente pode levar a conclusões equivocadas.

Com o aumento do número de amostras para 50 e 100 pontos, para ambas as técnicas, a representação da superfície de resposta proporcionada pelos metamodelos melhorou

significativamente, conforme pode ser observado pelos coeficientes de correlação mostrados na Tabela 6.2, que superaram 0.97, e pelos resultados gráficos apresentados na Figura 6.7, que mostram as superfícies de resposta dos metamodelos gerados com HL25 (a), HL50 (b), HL100 (c) pontos e a superfície da função analítica (d).




Figura 6.7 - Superfícies de resposta dos metamodelos gerados com HL25 (a), HL50 (b), HL100 (c) pontos e da função analítica (d) – Caso 1B.

A partir da visualização das superfícies da Figura 6.7, fica clara a melhora na qualidade da superfície gerada pelos metamodelos com o aumento do número de amostras, podendo observar como a superfície vai se assemelhando à da função analítica com a adição de mais amostras para treinamento.

6.2.3 Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado

Os valores dos mínimos encontrados, assim como suas coordenadas no espaço para a otimização utilizando os metamodelos gerados estão mostradas na Tabela 6.2, que também mostra o mínimo e suas coordenadas para a função analítica (“Função peaks”).

Apesar da semelhança numérica entre os coeficientes de correlação linear obtidos com os metamodelos gerados com HL25 e SS25 (0.6911 e 0.7110, respectivamente), o valor final da otimização para o metamodelo Caso1B_RNA_HL25 foi melhor (valor do mínimo), conforme comprovado visualmente pela Figura 6.6.

Tabela 6.2 – Coeficiente de correlação linear, erro médio e mínimo determinados através da otimização utilizando o metamodelo - Caso 1B.

Tipo de dado	Nome Rede	Erro médio (%)	Coeficiente correlação	Mínimo	Variável x	Variável y
-	Função peaks	-	-	-6.5511	0.2258	-1.6258
HL25	Caso1B_RNA_HL25	22590	0.6911	-5.6154	0.2258	-1.7159
HL50	Caso1B_RNA_HL50	12849	0.9755	-6.4047	0.2878	-1.5755
HL100	Caso1B_RNA_HL100	3032.2	0.9993	-6.5550	0.2106	-1.6257
SS25	Caso1B_RNA_SS25	8200.8	0.7110	-1.8480	0.4061	-1.9087
SS50	Caso1B_RNA_SS50	6563.5	0.9786	-5.3705	0.2572	-1.5941
SS100	Caso1B_RNA_SS100	4346.3	0.9996	-6.5573	0.2325	-1.6353

6.2.4 Passo 4: Retreinamento

A partir dos resultados da otimização utilizando o metamodelo Caso1B_RNA_HL25 definiu-se uma nova região de busca, de acordo com o mínimo encontrado na otimização. O critério adotado para definir a nova região de amostragem foi baseado em uma inspeção visual. Uma vez que os casos teóricos possibilitarem avaliar diretamente a superfície de resposta, a definição da nova região também foi realizada de forma direta, sem utilizar o critério de valor de corte, conforme consta na metodologia. Assim, a partir das coordenadas do mínimo encontrado pela otimização utilizando o metamodelo, foi considerada uma região ao redor com distância unitária, respeitando os limites máximos dos parâmetros.

A Tabela 6.3 mostra as coordenadas do mínimo encontrado com a otimização utilizando o metamodelo e o novo limite de variação dos parâmetros para amostragem.

Tabela 6.3 – Definição dos novos limites para retreinamento – Caso 1B.

Metamodelo	Coordenada do mínimo x	Coordenada do mínimo y	Novos limites-variável x	Novos limites-variável y
RNA_caso2_HL25	0.2258	-1.7159	[-0.7, 1.3]	[-2.7, -0.7]

Na Figura 6.8 (a) é mostrado o novo limite de variação dos parâmetros (área em negrito) e os respectivos pontos amostrados (em vermelho, sendo amostrados 25 pontos pelo HL), e a Figura 6.8 (b) mostra a superfície de resposta do metamodelo gerado com o novo treinamento (região em negrito da Figura 6.8 (a)), em que os pontos em vermelho representam regiões onde o erro em relação à superfície da função analítica ultrapassa 10% e os pontos em azul representam erros até 10%.

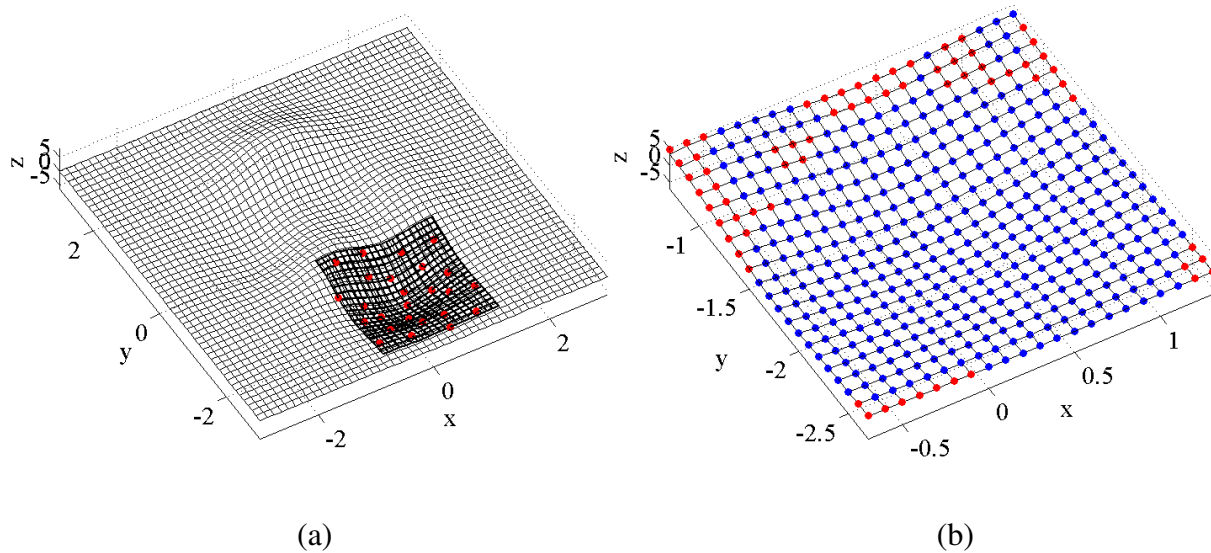


Figura 6.8 – Conjunto de treinamento e novos limites (a) e superfície de resposta do metamodelo gerado (b), relativos ao retreinamento – Caso 1B.

Os valores encontrados com a otimização utilizando o novo metamodelo são mostrados na

Tabela 6.4, juntamente com os resultados do treinamento com 25 e 100 pontos e da função analítica (Peaks). O erro médio apresentado corresponde ao valor calculado na área retreinada.

Tabela 6.4 - Resultados obtidos com o retreinamento – Caso 1B.

Metamodelo	Erro Médio (%)	Mínimo	Variável x	Variável y
Peaks	-	-6.5511	0.2258	-1.6258
HL25	149.6033	-5.6154	0.2258	-1.7159
HL100	10.2412	-6.5550	0.2106	-1.6257
HL25_RTR	10.7055	-6.5517	0.2265	-1.6265

Conforme pode ser observado, o retreinamento melhorou o resultado, obtendo erro médio baixo para a região retreinada e foi capaz de encontrar um valor muito próximo do mínimo global da função.

Com o processo de retreinamento foram utilizadas, no total, 50 amostras (25 pontos para o primeiro treinamento e mais 25 pontos para o retreinamento) e os resultados obtidos foram semelhantes aos obtidos com 100 pontos. Para esse caso, realizar um treinamento geral (representação de todo o espaço de soluções) para encontrar a região de mínimo e, posteriormente, realizar uma busca mais refinada (amostragem em uma região menor, específica) se mostrou eficiente. Porém, vale ressaltar que se fosse utilizado o metamodelo treinado com SS25, talvez o objetivo não fosse alcançado, uma vez que ele não foi capaz de representar bem a superfície de resposta na região de mínimo, conforme comentado no Subitem 6.2.3. Isso mostra a grande importância da qualidade dos dados de treinamento, os quais influenciam fortemente no sucesso do processo de retreinamento e representação da superfície de resposta.

Mesmo para o caso do metamodelo gerado com SS25 pontos poderia ser adotado um procedimento de retreinamento diferente daquele proposto na metodologia (que consiste em realizar busca em um região específica). Um novo treinamento, após uma nova amostragem de todo o espaço de busca dos parâmetros poderia ser realizada. Assim, podem-se adicionar pontos de treinamento em etapas, de forma iterativa, possibilitando encontrar uma quantidade reduzida de amostras que são capazes de proporcionar boa representação do espaço de soluções.

Esse procedimento, no entanto, considerando as técnicas de amostragem utilizadas nesse trabalho se restringe a ser aplicada somente com a técnica do HL, uma vez que a SS possui limitações quanto a gerar conjuntos com características diferentes e o BB gera sempre o mesmo conjunto de pontos.

Apesar de visualmente estar claro quando um mínimo está na região de interesse, para casos com mais de duas variáveis essa conclusão deve ser tomada realizando-se a validação do mínimo obtido através da otimização com o mínimo real.

O mesmo princípio aplica-se à definição da nova região de retreinamento. Nesse caso foi possível obter maior confiança através da inspeção visual, porém, em casos com mais de duas variáveis deve-se utilizar a metodologia do valor de corte, descrita no Capítulo 4.

6.3 Caso 1C

6.3.1 Passo 1: Definição do conjunto de treinamento

A Figura 6.9 mostra os conjuntos de treinamento para 25 pontos gerados através das técnicas do HL (a) e da SS (b), distribuídos na superfície de busca dos parâmetros.

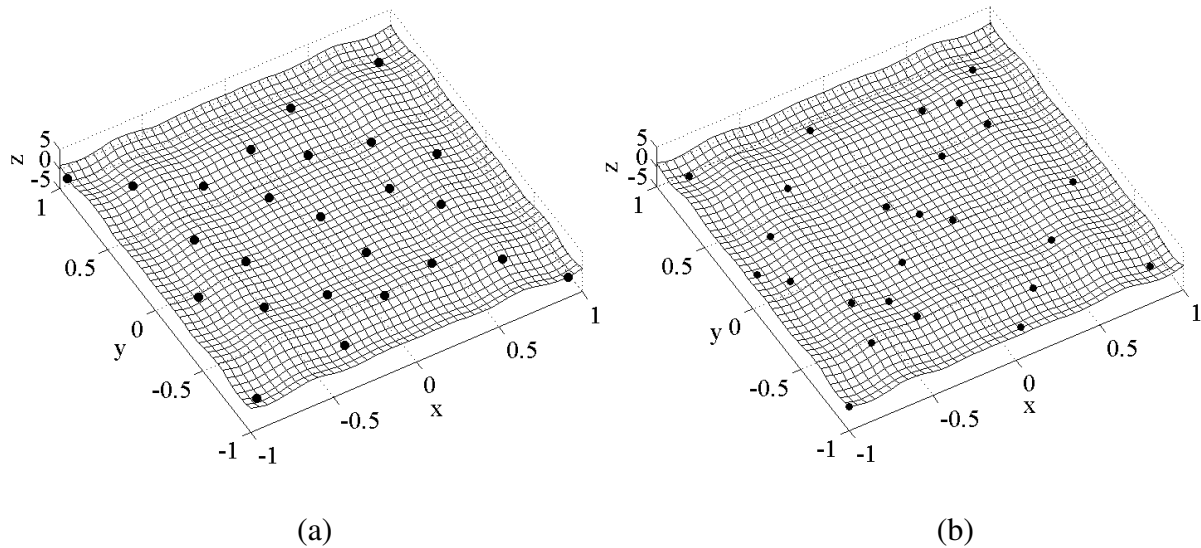


Figura 6.9 - Conjunto de treinamento para HL25 (a) e SS25 (b) - Caso 1C.

Observa-se que, tanto para o HL quanto para a SS, existe uma amostra em cada uma das quatro regiões de mínimo global da função. Porém, quase nenhum ponto foi amostrado nas regiões de mínimos locais, situados próximos aos mínimos globais. Isso pode fazer com que o metamodelo não seja capaz de determinar as regiões de mínimos globais precisamente, pois não

se sabe que padrão de comportamento a superfície terá ao redor dessas regiões que não tem informação.

A Figura 6.10 mostra os conjuntos de treinamento para 50 pontos amostrados utilizando as técnicas do HL (a) e da SS (b).

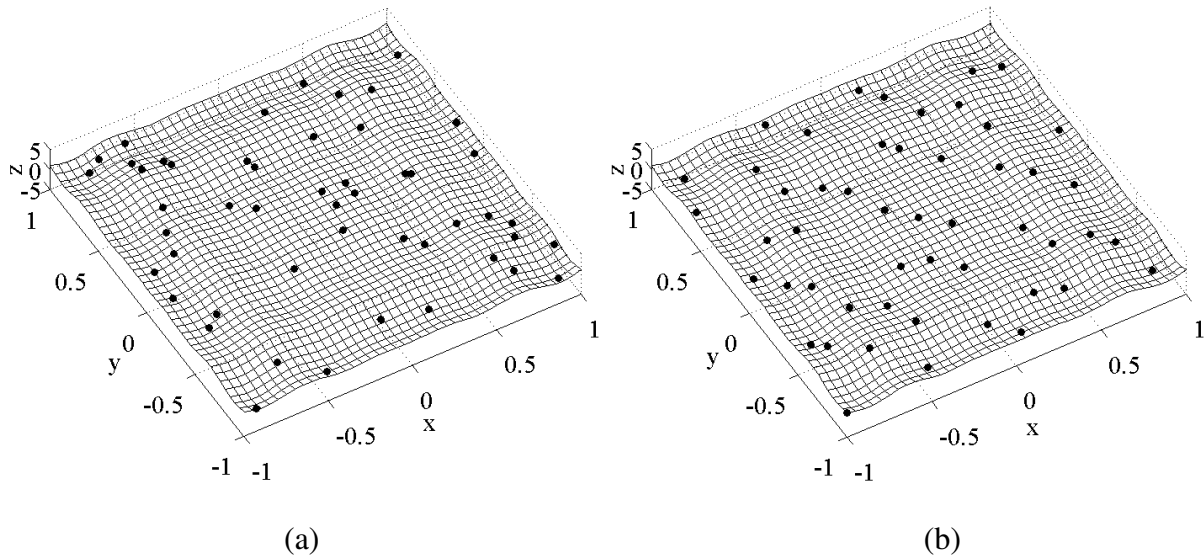


Figura 6.10 – Conjunto de treinamento para HL50 (a) e SS50 (b) - Caso 1C.

A Figura 6.10 mostra que com 50 pontos foi possível melhorar a amostragem em algumas regiões, porém ainda ficaram algumas “lacunas” entre os pontos amostrados, de forma que possivelmente uma representação precisa da superfície de resposta em todo o espaço também não seja possível para essa quantidade de amostras. Já com a amostragem realizada com 100 pontos, ambas as técnicas proporcionaram boa amostragem do espaço.

6.3.2 Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados

A Figura 6.11 mostra as superfícies de resposta dos metamodelos gerados com HL25 (a) e SS25 (b) pontos.




Figura 6.11 - Superfícies de resposta dos metamodelos gerados com HL25 (a) e SS25 (b) pontos - Caso 1C.

Observa-se que 25 pontos foram incapazes de extrair todas as informações necessárias para uma representação confiável da função. A partir da Figura 6.11 (a) pode-se visualizar que os quatro pontos amostrados na região de mínimo global contribuíram para que o metamodelo representasse bem essas regiões (regiões em cor azul acentuada). No entanto, o padrão de comportamento nas outras regiões ficou mal representado devido à falta de informações.

A Tabela 6.5 mostra os valores dos coeficientes de correlação e do erro médio entre a saída gerada pelo metamodelo e a saída calculada pela equação que descreve a função, com relação ao conjunto de teste para todos os metamodelos gerados. Os resultados quantitativos apresentados na Tabela 6.5 mostram que os metamodelos gerados com 50 pontos também foram incapazes de proporcionar uma boa representação, pois os coeficientes de correlação foram baixos e os erros médios foram altos, apesar de melhorarem bastante os resultados em relação aos metamodelos gerados com 25 pontos.

A Figura 6.12 mostra as superfícies de resposta dos metamodelos gerados com HL50 (a) e SS50 (b) pontos.




Figura 6.12 - Superfícies de resposta dos metamodelos gerados com HL50 (a) e SS50 (b) pontos - Caso 1C.

Ao se comparar as superfícies geradas pode-se observar que, apesar de resultarem em coeficientes de correlação parecidos, o formato das superfícies resultantes das duas técnicas foi diferente, refletindo os valores de erro médio. Como o caso possui muitas irregularidades, a diferença da característica de espaçamento dos pontos ficou evidente (quando analisada visualmente).

Os valores encontrados para os coeficientes de correlação e erros médios dos metamodelos gerados com 100 pontos mostram que uma representação confiável foi obtida, conforme pode ser visualizado pela Figura 6.13, que mostra as superfícies de resposta dos metamodelos gerados com HL100 (a) e SS100 (b) pontos.




Figura 6.13 - Superfícies de resposta dos metamodelos gerados com HL100 (a) e SS100 (b) pontos - Caso 1C.

Pela Figura 6.13 fica claro que com 100 pontos a diferença entre a característica de espaçamento entre as duas técnicas desapareceu, e ambas proporcionaram resultados semelhantes.

Para mostrar como a qualidade de representação melhorou com o aumento da quantidade de amostras a Figura 6.14 mostra as superfícies dos metamodelos gerados com HL 25 (a), 50 (b) e 100 (c) pontos e da função analítica (d).




Figura 6.14 - Superfícies de resposta dos metamodelos gerados com HL25 (a), HL50 (b), HL100 (c) pontos e da função analítica (d) – Caso 1C.

Assim, pode-se concluir que, para esse caso, foram necessários 100 pontos para uma boa representação do problema. O erro médio mostrado na Tabela 6.5 indica que os 25 e 50 pontos não forneceram toda a informação necessária para reproduzir as irregularidades presentes. O resultado da escassez de informação foi uma superfície “mais suave”, com menos irregularidades e, portanto, com menos precisão.

Nesses casos de duas variáveis ficou explícito, através da inspeção visual do espaço de soluções, quando um conjunto de treinamento não é capaz de representar o comportamento desejado. Para casos com mais de duas variáveis, porém, devem-se utilizar indicadores de

qualidade para chegar a essas conclusões. O coeficiente de correlação linear pode mostrar se o metamodelo gerado foi capaz de representar a região descrita pelos dados de teste. Porém, uma conclusão precisa é extraída através da validação do mínimo encontrado com a resposta conhecida do problema.

6.3.3 Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado

Os mínimos encontrados e suas respectivas coordenadas no espaço para o processo de otimização utilizando os metamodelos gerados são mostrados na Tabela 6.5.

Tabela 6.5 - Coeficiente de correlação linear, erro médio e mínimo determinados através da otimização utilizando os metamodelos - Caso 1C.

Tipo de dado	Metamodelo	Erro médio (%)	Coeficiente correlação	Mínimo	Variável x	Variável y
HL25	Caso1C_RNA_HL25	177.1364	0.3235	-0.8669	-0.7414	-0.9896
HL50	Caso1C_RNA_HL50	253.3417	0.4132	-1.9427	-0.9959	0.9973
HL100	Caso1C_RNA_HL100	1.5516	0.9999	-0.7433	-0.8816	0.8863
SS25	Caso1C_RNA_SS25	137.5484	0.2155	-1.4290	-0.9696	0.4463
SS50	Caso1C_RNA_SS50	87.9112	0.4872	-2.7439	0.9844	0.9934
SS100	Caso1C_RNA_SS100	0.9445	0.9999	-0.7504	0.8833	-0.8902

Com 25 e 50 pontos, como a superfície é bastante irregular, a diferença quanto ao tipo de dado pôde ser observado. Já com o aumento do número de pontos a diferença entre as técnicas desapareceu, pois todas as irregularidades presentes no problema foram devidamente representadas. Em diversas situações práticas, no entanto, a utilização de uma quantidade suficientemente grande para alcançar tal situação é muitas vezes inviável.

Quando não se conhece o comportamento da superfície de resposta e não é viável realizar amostragem grande, o melhor procedimento a ser adotado é ir adicionando amostras aos poucos até se atingir uma precisão desejada através da validação. Nesse sentido, o HL é a melhor escolha, pois a técnica da SS, além de amostrar sempre o mesmo padrão de espaçamento (limitado quanto à diversificação dos pontos quando se realizada diversas amostragens), passa a não ser viável para problemas de dimensões maiores.

Quanto ao valor do mínimo apresentado, nota-se que apenas um valor foi encontrado em cada otimização, enquanto que, conforme pode ser observado na Figura 6.15 (a), a função possui 4 mínimos. O motivo é que o AG, apesar de varrer com eficiência o espaço de busca dos parâmetros, tende a convergir para apenas um valor final de mínimo. Para contornar esse problema, os resultados de todas as gerações foram armazenados em um arquivo para posterior análise e possível identificação de outros mínimos. Para essa análise foi adotado o seguinte procedimento:

1. Estabeleceu-se um valor de corte de FO e consideraram-se apenas valores menores ou iguais a esse valor de corte;
2. Estabeleceu-se um critério de vizinhança baseado na discrepância das variáveis. Se um mínimo que atende a condição anterior for vizinho a outro mínimo, apenas um deles é considerado mínimo de interesse.

A Figura 6.15 mostra a localização dos mínimos globais da função sobre a superfície de resposta (a), representados por pontos azuis, e uma ilustração do critério de vizinhança adotado para identificação de mínimos de interesse (b). A Figura 6.15 (b) mostra três pontos (preto, vermelho e azul) sendo que, através do critério de vizinhança adotado, os pontos em preto e vermelho são considerados vizinhos (região em vermelho) e, portanto apenas um deles (o menor) é tomado como mínimo de interesse.




Figura 6.15 - Mínimos globais, representados pelos pontos em azul (a); e critério de vizinhança adotado para identificação de mínimos de interesse (b) – Caso 1C.

A Tabela 6.6 mostra os resultados da avaliação dos mínimos de interesse para HL25, HL100 pontos e $F(x)$, que representa os quatro mínimos globais da função.

Tabela 6.6 - Mínimos de interesse - Caso 1C.

Metamodelo	Conjunto	Mínimo	Variável x	Variável y
F(x)	1	-0.7558	0.8865	0.8813
	2	-0.7554	-0.8871	-0.8830
	3	-0.7513	0.8798	-0.8733
	4	-0.7515	0.8798	0.8735
Caso1C_RNA_HL25	1	-0.8669	-0.7414	-0.9896
	2	0.5555	0.8629	-0.4172
	3	-0.5361	-0.8713	-0.6043
	4	-0.9675	-0.9115	-0.6270
	5	0.7603	0.7757	-0.4175
	6	-0.9820	-0.5928	-0.4164
Caso1C_RNA_HL100	1	-0.7433	-0.8816	0.8863
	2	-0.7236	0.8822	-0.8709
	3	-0.7360	0.8822	0.8662
	4	-0.7428	-0.8816	-0.8709

Pelos resultados da Tabela 6.6, a otimização utilizando o metamodelo Caso1C_RNA_HL25 identificou, pelo critério adotado anteriormente, seis regiões de mínimo, sendo que apenas uma delas é realmente uma região de mínimo global (resultado em negrito). Em contrapartida, com o metamodelo Caso1C_RNA_HL100 foi possível identificar as quatro regiões de mínimo global da função.

Foi comentado no Subitem 6.3.1 que, apesar do conjunto de HL25 pontos englobar amostras nas quatro regiões de mínimos globais, a falta de informação nas regiões vizinhas, com irregularidades, poderia gerar um padrão de comportamento que poderia vir a prejudicar a representação pelo metamodelo. Analisando novamente a Figura 6.9 (a) observa-se que perto do mínimo que se situa próximo às coordenadas (-1,-1) existem ainda duas amostras vizinhas nas regiões de mínimos locais. Isso fez com que fosse possível identificar esse mínimo, enquanto que os outros mínimos globais não foram identificados devido ao padrão de comportamento menos preciso da região próxima.

O procedimento adotado de analisar posteriormente os valores obtidos com a otimização, foi aplicado para verificar se o metamodelo foi capaz de modelar as outras regiões de mínimo. Nesse caso também foi utilizada a inspeção visual, porém em casos com mais de duas variáveis, a decisão de utilizar tal procedimento deve surgir a partir da validação dos mínimos encontrados na otimização com a resposta conhecida do problema.

Ao invés de realizar a análise posterior dos resultados, uma opção seria estudar a utilização de um algoritmo de otimização que determine mais de uma região de mínimo. Isso não foi realizado nesse trabalho, pois o foco não foi a etapa de otimização dos parâmetros (utilizada apenas como parte complementar aos estudos).

A partir da análise do resultado da otimização com o metamodelo HL25 pontos, foi constatado que uma região de mínimo foi identificada. Essa informação poderia ser incluída no procedimento de novo treinamento proposto no Subitem 6.3.2, de forma que na nova amostragem menos pontos fossem amostrados nessa região e mais pontos seriam amostrados nas outras regiões, de menor precisão.

6.4 Caso 1D

6.4.1 Passo 1: Definição do conjunto de treinamento

A Figura 6.16 mostra os conjuntos de treinamento (pontos em preto), amostrados sobre o espaço de busca dos parâmetros, de HL25 (a) e SS25 (b) pontos.




Figura 6.16 – Conjunto de treinamento para HL25 (a) e SS25 (b) pontos – Caso 1D.

Pode-se observar que, na região de mínimo, enquanto que para o conjunto HL25 existem apenas duas amostras na região, para o conjunto SS25 existem três amostras mais concentradas perto do mínimo global. Assim, pode-se esperar que na região de mínimo, o desempenho do metamodelo gerado com SS25 pontos seja melhor do que o do metamodelo gerado com HL25 pontos.

6.4.2 Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados

As superfícies de resposta dos metamodelos gerados com HL25 e SS25 pontos são mostradas na Figura 6.17.

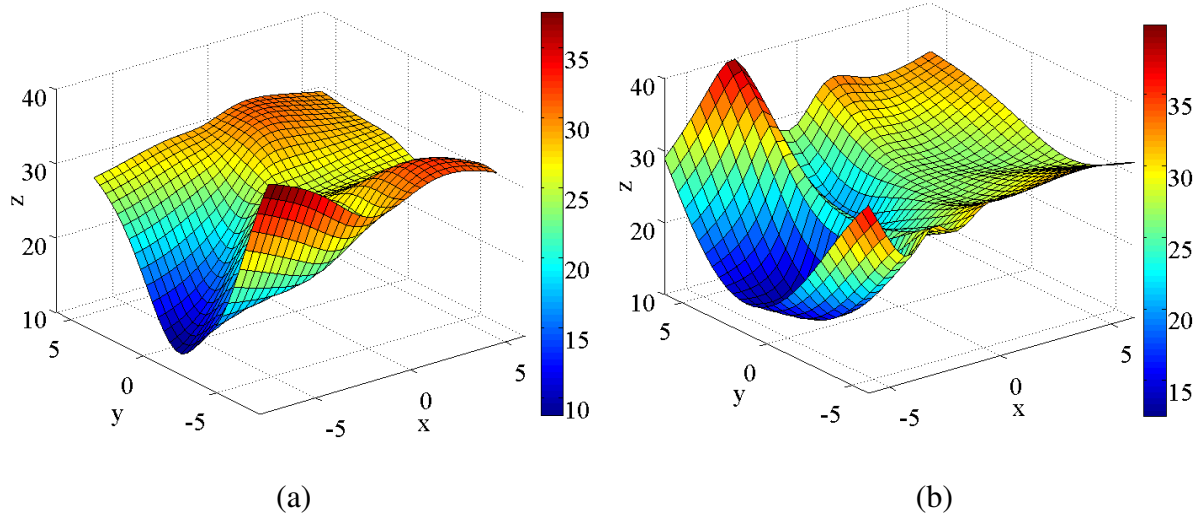


Figura 6.17 - Superfícies de resposta dos metamodelos gerados com HL25 (a) e SS25 (b) pontos - Caso 1D

Pode-se observar que a superfície da Figura 6.17 (b) está melhor do que a da Figura 6.17 (a), porém ambas foram capazes de identificar a região de interesse, representada pela cor azul acentuada.

Para mostrar como a qualidade de representação melhorou com o aumento da quantidade de amostras a Figura 6.18 mostra as superfícies de resposta dos metamodelos gerados com 25 (a), 50 (b) e 100 (c) pontos do HL e da função analítica (d).

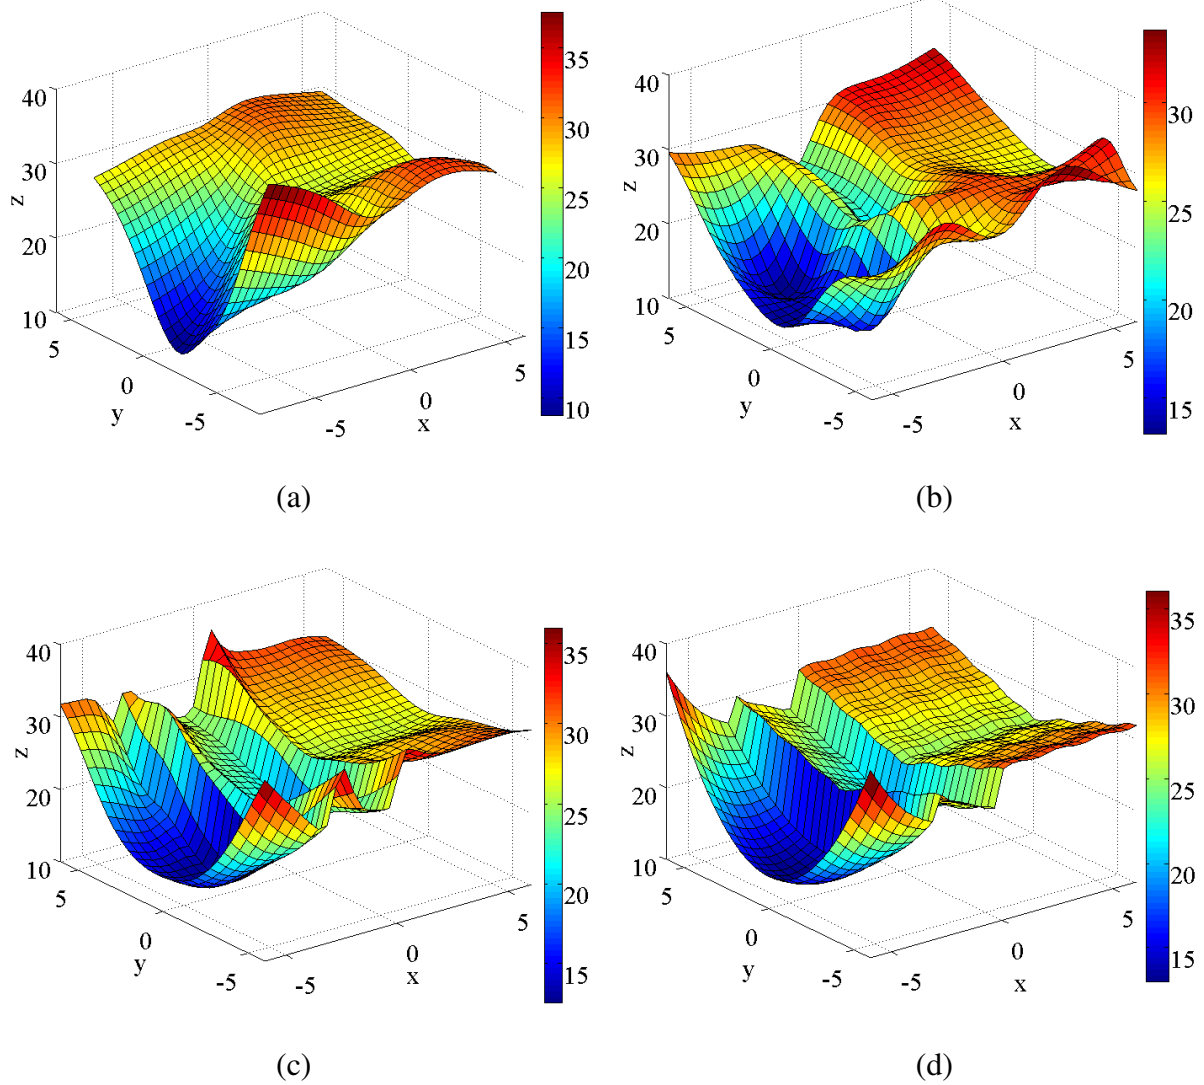


Figura 6.18 - Superfícies de resposta dos metamodelos gerados com HL25 (a), HL50 (b), HL100 (c) pontos e da função analítica (d) – Caso 1D.

A Figura 6.18 mostra que o aumento do número de pontos proporciona melhor representação da superfície de resposta. Uma observação interessante é que perto de regiões de mudança brusca no formato da superfície de resposta, os erros foram maiores. Isso comprova que, para situações de alta irregularidade da função, a rede tende a gerar erros maiores.

Os valores dos coeficientes de correlação linear e erro médio entre saída gerada pelo metamodelo e pela equação que descreve a função para todos os metamodelos gerados são mostrados na Tabela 6.7. Os resultados mostram que desempenhos semelhantes foram obtidos

entre os metamodelos gerados com HL e SS, em questão de representação de todo o espaço de soluções.

6.4.3 Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado

Os valores dos mínimos encontrados, assim como suas coordenadas no espaço para a otimização utilizando os metamodelos gerados, são mostrados na Tabela 6.7. É mostrado também o valor do mínimo e sua coordenada para a função analítica $F(x)$.

Tabela 6.7 - Coeficiente de correlação linear, erro médio e mínimo determinados através da otimização utilizando o metamodelo - Caso 1D.

Tipo de dado	Nome da rede	Erro médio (%)	Coeficiente correlação	Mínimo	Variável x	Variável y
-	$F(x)$	-	-	13.000	-4.7124	8.1258e-06
HL25	Caso1D_RNA_HL25	7.8769	0.8875	5.6007	-6.0000	0.4753
HL50	Caso1D_RNA_HL50	5.6256	0.9031	13.1296	-3.7178	-2,3725
HL100	Caso1D_RNA_HL100	2.2230	0.9808	12.5672	-3.6153	-0.2673
SS25	Caso1D_RNA_SS25	6.2709	0.8781	12.5224	-4.4154	0.1136
SS50	Caso1D_RNA_SS50	5.2949	0.9256	11.9259	-3.9644	0.1949
SS100	Caso1D_RNA_SS100	2.8880	0.9633	12.7835	-3.5991	-0.3232

Observa-se que, apesar de todos os metamodelos encontrarem a região de mínimo, a determinação mais precisa da localização não foi possível. O fato da superfície de resposta possuir mudanças repentinas em seu formato acabou criando dificuldades para a rede definir padrões que representem a função nessa região com precisão.

Apesar de não ter encontrado a localização precisa da coordenada do mínimo, a região foi encontrada facilmente com poucos pontos, de maneira que um retreinamento posterior seria capaz de encontrar a localização do mínimo com precisão.

A Tabela 6.7 mostra que o mínimo encontrado pela otimização utilizando o metamodelo Caso1D_RNA_SS25, assim como suas coordenadas, foi mais preciso comparativamente à otimização utilizando o metamodelo Caso1D_RNA_HL25, complementando a observação realizada no Subitem 6.4.1. Apesar dessa diferença na precisão com relação ao mínimo global, no aspecto geral, a qualidade da representação da superfície de resposta proporcionada pelos dois

metamodelos foi semelhante, uma vez que os valores dos coeficientes de correlação linear e do erro médio foram parecidos.

Esse resultado mostra que, apesar de globalmente as duas técnicas de amostragem proporcionarem desempenhos semelhantes aos metamodelos, quando analisadas em regiões específicas, elas possuem suas particularidades, podendo uma destacar-se em relação à outra.

A Tabela 6.7 mostra que, apesar de ter resultado em menor correlação linear, o metamodelo gerado com SS25 pontos foi melhor que todos os demais para determinar o mínimo. Para avaliar melhor esse resultado, na Figura 6.19 são expostos os conjuntos de treinamento de HL100 (a) e SS100 (b) pontos.

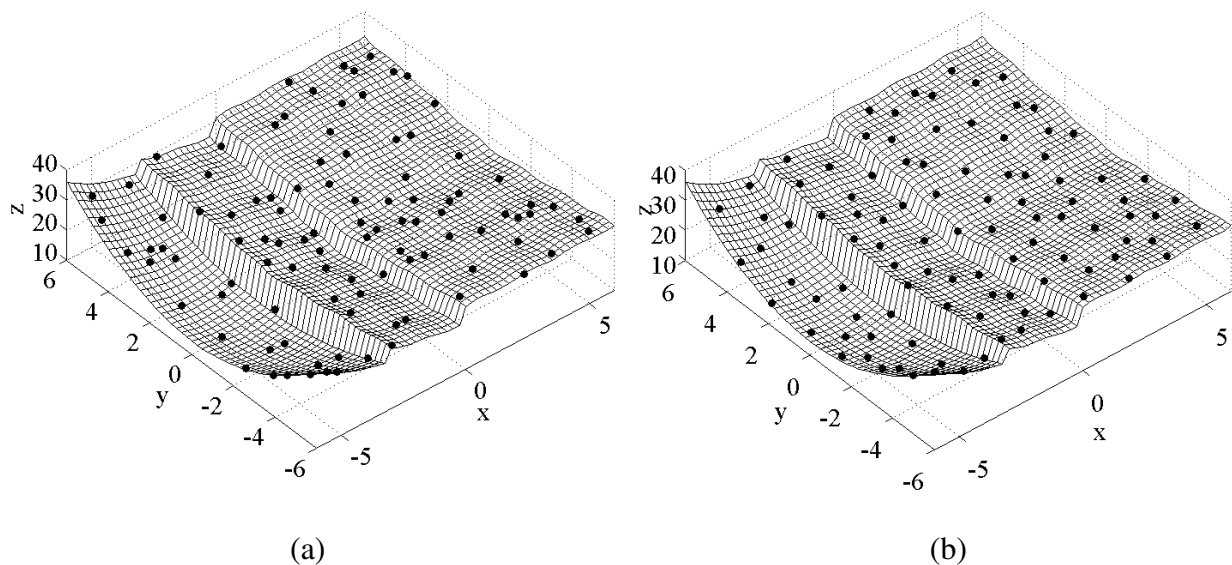


Figura 6.19 – Conjunto de treinamento de HL100 (a) e SS100 (b) pontos – Caso 1D.

Comparando os conjuntos SS25 (Figura 6.16 (b)) e HL100 observa-se que em relação ao mínimo, a amostragem proporcionada pelo conjunto SS25 foi melhor, porém para a modelagem de toda a superfície o conjunto HL100 foi melhor, refletindo os valores de correlação e do mínimo encontrado. Porém, com relação à amostragem do conjunto SS100, a Figura 6.19 (b) mostra que mesmo na região de mínimo sua amostragem foi melhor do que a de SS25 pontos. O motivo do resultado inferior com relação ao mínimo é que, provavelmente, o treinamento não tenha ocorrido bem para o metamodelo SS100 escolhido. Um novo treinamento deve resultar em um metamodelo com melhor qualidade.

Esse resultado mostra que o treinamento da RNA deve ser realizado diversas vezes para garantir a geração de um metamodelo de qualidade. Adicionalmente, um critério de escolha bem definido deve ser utilizado para obter um metamodelo que proporcione o melhor desempenho possível para o problema.

6.5 Comentários dos casos analíticos

Os casos analíticos estudados possibilitaram a identificação de particularidades e, principalmente, limitações das RNA que devem ser consideradas em sua aplicação.

Caso 1A

A primeira característica importante das RNA observada foi que, por mais simples que seja a superfície de resposta a qual se deseja modelar, existe um erro envolvido na representação proporcionada pelo metamodelo gerado (comentado no Subitem 6.1.3), a não ser que se tenha um número suficiente de amostras convenientemente espaçadas (tal que cubram de forma eficiente todo o espaço de busca dos parâmetros), o que dificilmente será possível. Portanto, pode-se esperar que em regiões que não possuem informações sobre o comportamento da superfície de resposta, a RNA provavelmente proporcione uma modelagem menos confiável. Isso faz com que a otimização utilizando o metamodelo não seja capaz de determinar a coordenada precisa do mínimo de interesse, porém, não significa que a região de mínimo não seja identificada. Para saber se o metamodelo foi capaz de modelar a superfície de resposta tal que a região de interesse seja identificada, deve-se realizar a validação do resultado da otimização com a resposta conhecida do problema.

Por outro lado, caso a região a ser modelada seja comportada, a RNA é capaz de modelar o seu padrão de comportamento com poucas amostras sem maiores dificuldades.

Caso 1B

Pelo Caso 1B pôde-se comprovar que a presença de amostras na região de interesse contribuiu para que o metamodelo fosse capaz de modelar com maior precisão essa região, conforme comentado no Subitem 6.2.2.

A falta de informação em determinadas regiões faz com que a RNA atenua ou acentua a curvatura da superfície, dependendo do padrão de curva que a superfície possui ao seu redor, podendo levar a solução a regiões de mínimo equivocadas (Subitem 6.2.2).

Para esse caso a determinação de uma nova região de treinamento foi realizada através da inspeção visual (Subitem 6.2.4), porém conforme já comentado nos resultados, para casos de mais de duas variáveis o procedimento a ser adotado é o proposto na metodologia.

Caso 1C

Para casos com mais de um mínimo global é necessário utilizar uma ferramenta de otimização que seja capaz de fornecer mínimos situados em regiões diferentes como resposta. Outra opção é realizar o procedimento proposto no Caso 1C, que consiste em analisar os resultados da otimização posteriormente, para verificar se o metamodelo encontrou regiões potencialmente de mínimos (Subitem 6.3.3).

No caso de duas variáveis foram utilizados mais pontos para treinar as RNA (utilização de 100 pontos). Porém, em casos complexos, e, portanto, com mais variáveis, um procedimento adequado consistiria em iniciar o treinamento com poucos pontos, em seguida validar os resultados com a resposta conhecida do problema e, caso houvesse necessidade, mais pontos seriam adicionados (novamente para todo o espaço de busca dos parâmetros) e as RNA seriam treinadas novamente. Esse processo iterativo de treinamento e validação de RNA prosseguiria até que uma qualidade satisfatória de representação dos metamodelos fosse alcançada.

Com isso possivelmente pode-se encontrar uma quantidade reduzida de pontos capaz de modelar o padrão desejado do problema. No Caso 1C, por exemplo, poderia se chegar a um metamodelo bom com 75 pontos ou até com 50 pontos através desse procedimento.

Caso 1D

Com o Caso 1D, que mostra uma superfície modelada por mais de uma função, pôde-se observar que nas regiões de mudança brusca de comportamento a RNA gera maior erro.

Conforme comentado no Subitem 6.4.3, ao se analisarem os resultados em algumas regiões específicas, a diferença em relação à técnica utilizada para amostrar os dados pôde ser

evidenciada, ao realizar a comparação entre os metamodelos Caso1D_RNA_HL25 e Caso1D_RNA_SS25.

Dessa maneira, mesmo um metamodelo com menos pontos pode proporcionar melhores resultados, quando regiões específicas são analisadas.

Os resultados do Caso 1D ainda mostraram que a realização de vários treinamentos e a utilização de um critério bem definido para escolher o metamodelo treinado é importante para obter aquele que proporcione melhor modelagem para o problema. Pelos resultados apresentados no Subitem 6.4.3, pôde-se observar que apesar de o metamodelo SS100 resultar em melhor coeficiente de correlação linear comparativamente ao metamodelo SS25, as coordenadas do mínimo encontradas pelo metamodelo SS25 foram melhores. Isso mostra que a definição de um critério específico, que realize a comparação na região de interesse é importante.

Comentários gerais

Uma maneira de melhorar a qualidade da modelagem é através de um novo treinamento, em uma região menor. Porém, a realização desse tipo de procedimento nem sempre é vantajosa, de forma que só agregará valor caso a região identificada para realizar o novo treinamento seja realmente uma região de interesse (que contém o mínimo). No entanto, identificar se o mínimo encontrado é um mínimo local ou global não é fácil em situações em que exista muita irregularidade na superfície de resposta e pouca informação do problema.

Através dos resultados dos casos analíticos, pôde-se identificar e propor mais um tipo de retreinamento. Esse procedimento deve proporcionar bons resultados para casos complexos.

As técnicas de amostragem, em geral, proporcionaram metamodelos de qualidade semelhante quando analisadas globalmente, ou seja, o resultado para toda a superfície de resposta, conforme pôde ser observado pelos coeficientes de correlação linear e pelos erros para todos os casos. Porém, quando analisada em regiões específicas, a diferença entre o tipo de amostragem apareceu. Dessa maneira, um estudo para definição de critérios de comparação em regiões específicas deve agregar valor aos resultados.

Nos casos analíticos, várias conclusões puderam ser tiradas a partir da análise visual da superfície de resposta (espaço de soluções). Porém, o procedimento de validação com a resposta

conhecida do problema permite realizar avaliações importantes, como determinar se o mínimo encontrado está na região de interesse, se o caso possui diversas regiões de interesse, se é necessário realizar novo treinamento, se esse retreinamento deve ser refinado ou global etc. de forma que qualquer decisão ou avaliação mais precisa dos resultados seja realizada através da validação.

Assim, pode-se concluir que através da análise visual do espaço de soluções foram identificadas características e particularidades das RNA, de forma que novos procedimentos e necessidades de estudo puderam ser identificados e propostos. O conhecimento proporcionado pelos estudos dos casos analíticos contribuiu para formar uma base teórica para aplicação da ferramenta nos casos de maior complexidade.

6.6 Caso 2A

6.6.1 Passo 1: Definição do conjunto de treinamento

A Figura 6.20 mostra a relação existente (amostragem no espaço) entre dois dos quatro atributos incertos (porosidade da fácies 2 e transmissibilidade da falha 3), do conjunto de treinamento HL25 (a) e HL50 (b) pontos.




Figura 6.20 – Pontos de treinamento, relativos aos atributos porosidade da fácies 2 e transmissibilidade da falha 3 para os conjuntos HL25 (a) e HL50 (b) pontos - Caso 2A.

Observa-se que para o conjunto de HL50 existem mais pontos concentrados bem próximos. Esse fator pode resultar em melhor representação do espaço de soluções nessas áreas, quando comparado com o metamodelo gerado com o conjunto HL25, que possui apenas pontos individualmente dispersos no espaço e algumas regiões sem amostragem. Em contrapartida existem também espaços vazios para o conjunto de HL50, onde há falta de informações. O motivo disso vem do fato de que a técnica do hipercubo latino, apesar de amostrar valores bem distribuídos para cada atributo, realiza a combinação entre eles de forma aleatória, o que acaba gerando regiões com mais e com menos informações.

Para avaliar os valores de afastamento com relação ao histórico gerado, a Tabela 6.8 mostra a frequência de ocorrência dos valores de saídas desejadas, geradas pela simulação dos conjuntos de treinamento amostrados (afastamento da produção de água do campo, do modelo simulado com relação ao histórico).

Tabela 6.8 – Frequência de ocorrência dos valores de saída para os conjuntos de treinamento, HL25, HL50 e HL100 pontos – Caso 2A.

HL25		HL50		HL100	
Frequência	Faixa ($\times 10^8$)	Frequência	Faixa ($\times 10^8$)	Frequência	Faixa ($\times 10^8$)
16	0.0125 - 1.35	33	0.00585 - 1.25	59	0.00224 - 1.19
4	1.35 - 2.69	4	1.25 - 2.50	17	1.19 - 2.37
3	2.69 - 4.03	3	2.50 - 3.75	3	2.37 - 3.55
0	4.03 - 5.37	5	3.75 - 5.00	6	2.55 - 4.74
1	5.37 - 6.71	1	5.99 - 6.25	4	4.74 - 5.92
1	6.71 - 8.05	3	6.25 - 7.50	3	5.92 - 7.10
		0	7.50 - 8.75	5	7.10 - 8.29
		1	8.75 - 10	2	8.29 - 9.47
				0	9.47 - 10.7
				1	10.7 - 11.8
Mínimo	0.0125		0.00585		0.00224
Máximo	8.05		10		11.8

As faixas mostradas na Tabela 6.8 indicam que uma determinada quantidade de amostras (coluna “Frequência”), possui valor de afastamento situado entre um limite mínimo e máximo, especificados (coluna “Faixa”). Por exemplo, para o conjunto HL25 pontos, dezesseis amostras geraram afastamentos que se situam em uma faixa entre 1.25×10^6 e 1.35×10^8 . Assim, quanto menor for o valor de afastamento gerado pela amostra, significa que mais perto do mínimo de interesse ela se situa e, quanto mais amostras de valores menores existirem dentro do conjunto de treinamento, melhor a qualidade do conjunto de treinamento.

A Figura 6.21 mostra os histogramas com a frequência de ocorrência dos valores de saída da Tabela 6.8, referente aos conjuntos de treinamento HL25 e HL50 pontos.





Figura 6.21 – Histograma dos valores de saída para os conjuntos de treinamento HL25 e HL50 pontos – Caso 2A.


A avaliação dos histogramas da Figura 6.21 mostra a superioridade do conjunto de HL50 pontos comparativamente ao conjunto de HL25 pontos, com relação a fornecer informações mais próximas à região de interesse (de mínimo). Além de amostrar um valor mínimo mais próximo do mínimo de interesse, o conjunto HL50 pontos também concentra maior quantidade de pontos em regiões mais próximas do mínimo.

6.6.2 Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados


A Figura 6.22 mostra os gráficos de dispersão (*crossplot*) entre os afastamentos da produção de água obtidos com o simulador e com o metamodelo, com relação às amostragens realizadas com HL25 (a), HL50 (b) e HL100 (c) pontos.



(a)



(b)



(c)

Figura 6.22 – Gráfico de dispersão (*crossplot*) entre saída do simulador e saída do metamodelo, gerado com HL25 (a), HL50 (b) e HL100 (c) – Caso 2A; pontos em azul: pontos de treinamento e pontos em vermelho: pontos de teste.

A partir dos gráficos da Figura 6.22 fica claro que com 100 pontos a rede obteve melhor correlação dos dados. Em contrapartida, a diferença entre os gráficos obtidos com os metamodelos gerados com 25 e 50 pontos não ficou evidente.

A Tabela 6.9 mostra os valores obtidos para os coeficientes de correlação linear entre saída do simulador e do metamodelo, relativos aos conjuntos de treino e teste.

Tabela 6.9 – Correlação linear entre saída do simulador e do metamodelo (afastamento da produção de água, do modelo de simulação com relação ao histórico), relativos aos conjuntos de treino e teste – Caso 2A.

Metamodelo	Tipo	Correlação linear
Caso2A_HL25	Treino	0.9880
	Teste	0.9743
Caso2A_HL50	Treino	0.9794
	Teste	0.9825
Caso2A_HL100	Treino	0.9948
	Teste	0.9972

A avaliação apenas dos valores de coeficiente de correlação linear, mostrados na Tabela 6.9, não possibilita definir qual metamodelo foi melhor, pois os valores são bem próximos. Apesar disso, os valores para teste sugerem que o aumento da quantidade de amostras contribuiu para melhorar a qualidade do metamodelo.

6.6.3 Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado

Os resultados da otimização utilizando os metamodelos gerados são apresentados na Tabela 6.10, que mostra os afastamentos do mínimo determinado pela otimização, com relação ao histórico, quando simulado com o metamodelo (coluna “Metamodelo”) e com o simulador (coluna “Simulador”).

Tabela 6.10 – Afastamento obtido com o mínimo encontrado na otimização, quando simulado com o metamodelo e com o simulador – Caso 2A.

Metamodelo	Metamodelo ($\times 10^6$)	Simulador ($\times 10^6$)
Caso2A_HL25	7.3398	209.6290
Caso2A_HL50	24.5380	4.8652
Caso2A_HL100	11.5150	0.2701

Observa-se que para o metamodelo Caso2A_HL25, a simulação do mínimo com o metamodelo gerou um valor baixo de afastamento, enquanto que a simulação com o simulador resultou em valor de afastamento elevado. Isso indica que a otimização utilizando esse metamodelo não identificou de fato a região de mínimo, ou seja, levou a solução para uma região

de afastamento elevado. Portanto, pode-se concluir que esse metamodelo não foi capaz de representar o simulador com precisão.

Já em relação aos metamodelos Caso2A_HL50 e Caso2A_HL100, observa-se que os valores obtidos com o metamodelo e o simulador não foram tão discrepantes, provando que proporcionaram bons resultados. Vale ressaltar que essa diferença existente dificilmente será eliminada, pois o metamodelo fornece apenas uma estimativa da resposta, na qual deve ser confirmada posteriormente através da simulação.

A Figura 6.23 mostra as curvas de produção de água do campo dos modelos encontrados com a otimização utilizando os metamodelos.




Figura 6.23 – Curva de produção de água do campo do Caso base, histórico e metamodelos gerados com HL25, HL50 e HL100 pontos – Caso 2A.

Com relação às curvas apresentadas na Figura 6.23, a do metamodelo Caso2A_HL25 ficou distante do histórico, chegando até a piorar o ajuste em comparação com o Caso base, enquanto que as curvas dos metamodelos Caso2A_HL50 e Caso2A_HL100 melhoraram o Caso base e ajustaram bem a curva de produção de água do campo em relação ao histórico. Foi traçada a curva e produção de água obtida através do metamodelo Caso2A_HL25, porém, na prática essa solução seria descartada, pois piorou o Caso base. Nesse trabalho o resultado foi considerado

para mostrar que, com menos pontos, a probabilidade de obter resultados equivocados é maior. Em outras palavras, a probabilidade de amostrar a região de mínimo é menor.

O fato de a correlação linear para o metamodelo Caso2A_HL25 ter resultado em valores elevados indica que o espaço de soluções do problema possui irregularidades e que os 25 pontos não foram capazes de fornecer essa informação, de forma que, mesmo que nos pontos amostrados a correlação esteja boa, não significa que nas demais regiões a correlação também esteja. O mesmo se pode dizer a respeito dos dados de teste que indicaram boa correlação. Se os dados de teste englobassem alguma região com irregularidade ou a região de interesse, o resultado da correlação para o metamodelo HL25 provavelmente teria sido ruim. Assim, o ideal para os dados de teste é que eles indiquem a qualidade do metamodelo na região de interesse. A melhor maneira de obter uma avaliação precisa dos resultados, no entanto, é através da validação da curva de produção do modelo com o histórico.

Um procedimento que poderia melhorar essa etapa de análise seria calcular o coeficiente de correlação linear em uma região mais refinada, em que os valores de afastamento fossem abaixo de um determinado valor de corte. Assim, ter-se-ia uma avaliação para uma região maior e uma avaliação em uma região menor, possivelmente próxima do mínimo de interesse.

6.6.4 Passo 4: Retreinamento

O processo de retreinamento realizado nesse trabalho, conforme consta no Capítulo 4 de metodologia, consistiu em realizar uma nova amostragem e treinamento das RNA em uma região menor, ao redor do mínimo encontrado através da otimização utilizando o metamodelo. O ideal seria realizar o retreinamento com o metamodelo que utilizou menos pontos, no caso o Caso2A_HL25. Porém, conforme pôde ser observado pelo gráfico da Figura 6.23, o mínimo encontrado com esse metamodelo gerou uma curva de produção distante do mínimo desejado para esse caso. Por esse motivo, a realização de um novo treinamento, utilizando como base o mínimo encontrado com esse metamodelo, não iria melhorar os resultados, pois o retreinamento ocorreria em uma região de mínimo errada.

Apesar disso, para comprovar essa hipótese foi realizado o retreinamento utilizando os resultados desse metamodelo. O gráfico de produção gerado, conforme se esperava, continuou distante do histórico, apesar de melhorar um pouco com relação ao treinamento. O retreinamento foi, então, realizado a partir do mínimo encontrado com a otimização utilizando o metamodelo gerado com HL50 pontos.

Para a definição dos novos limites de treinamento (conforme Subitem 4.2.2 do capítulo de metodologia) foi adotado um valor de corte de 40% de FO (modelos que resultam em FO menor que 40% do valor máximo alcançado na otimização, ou seja, que proporcionaram mais de 60% de redução em relação ao valor máximo atingido com a otimização), e chegou-se aos limites mostrados na Tabela 6.11.

Tabela 6.11 – Definição dos atributos para novo treinamento – Caso 2A.

Limite	Por2	Kx2	Falha3	Kr2
Inferior	0.9727	0.7500	0.4512	2.6180
Superior	1.1492	0.9402	1.0000	3.6223

Para dados de teste foram utilizados 5 dos 25 pontos amostrados, sendo os outros 20 pontos utilizados para validação e treino (5 pontos para validação e 15 pontos para treino).

A Tabela 6.12 a seguir mostra o coeficiente de correlação linear (treino e teste) entre saída do simulador e do metamodelo e o valor do mínimo encontrado com a otimização, referente ao retreinamento.

Tabela 6.12 – Coeficientes de correlação linear do retreinamento; mínimo obtido com a otimização e simulação do mínimo com o simulador – Caso 2A.

Metamodelo	Treinamento		Otimização ($\times 10^6$)	
	Correlação linear		Metamodelo	Simulação
	Treino	Teste		
Caso2A_HL50_novo	0.9906	0.9536	-0.6984	0.2644

Observa-se que o valor de afastamento obtido com a simulação do modelo resultante da otimização foi próximo ao adquirido com o metamodelo gerado com 100 pontos (Caso2A_HL100), mostrado na Tabela 6.10 (0.2701).

O valor negativo que aparece para o mínimo encontrado com a otimização foi devido à utilização da função linear como função de transferência para treinamento da RNA. Apesar disso, como os valores dos atributos do reservatório respeitam os limites impostos, a simulação do modelo resultante da otimização com o simulador gerou valores plausíveis, conforme mostra o resultado da simulação da Tabela 6.12.

A Figura 6.24 mostra as curvas de produção de água do campo para o retreinamento.




Figura 6.24 - Curva de produção de água do campo do Caso base, histórico e metamodelos gerados com HL50, HL100 pontos e HL50 após retreinamento – Caso 2A.

Observa-se que a curva de produção de água obtida com o retreinamento assemelhou-se à curva resultante da otimização utilizando o metamodelo gerado com HL100 pontos.

Nesse caso, a realização de um novo treinamento agregou valor aos resultados uma vez que com um total de 75 simulações (50 para primeiro treinamento e mais 25 para retreinamento) foi possível obter uma curva de produção igual à obtida com 100 simulações. Isso foi possível porque o conjunto de treinamento incluía informações suficientes a respeito da região de interesse (de mínimo).

Com o intuito de entender melhor a influência dos dados de entrada na qualidade do metamodelo gerado, foi realizada uma análise comparativa entre os dados HL50, HL100 e HL25

(este último utilizado no retreinamento). Para cada atributo, foi calculada a diferença absoluta e normalizada entre o valor do atributo do modelo amostrado e o valor real conhecido pelo modelo de referência. A soma dessas diferenças para os quatro atributos que compõem o modelo de simulação foi considerada como sendo a distância média da amostra em relação ao valor conhecido. A fórmula utilizada para calcular a diferença é mostrada pela Equação 6.1.

$$A = ABS \left[\frac{d_{obs} - d_{amost}}{d_{obs}} \right] \quad \text{Equação 6.1}$$

em que d_{obs} representa o dado observado e d_{amost} representa o dado amostrado.

Com isso foi possível obter uma ideia de quão distante do modelo de referência o modelo amostrado estava, conforme consta na Tabela 6.13, que mostra para cada conjunto de entrada a quantidade de amostras que se situam nas diferentes faixas de distâncias médias (0% - 100% de distância) em relação ao modelo de referência.

Tabela 6.13 - Relação da distância relativa dos atributos de treinamento com o histórico – Caso 2A

Faixa de variação	HL50	HL100	HL25 (retreino)
0% - 10%	1	0	0
11% - 50%	5	6	17
51% - 100%	17	37	8
>101%	27	57	0

Observa-se pela Tabela 6.13 que são poucos os dados amostrados perto da região de mínimo, ou seja, amostragem de modelos próximos ao histórico (faixa de 0% - 10%). Porém, a amostragem de 50 pontos conseguiu reunir a mesma quantidade de dados (informações), situados na faixa entre 0% a 50%, que os 100 pontos, justificando o bom desempenho do metamodelo gerado com esses dados e, conseqüentemente, o retreinamento.

6.7 Caso 2B

6.7.1 Análise de sensibilidade

A Figura 6.25 mostra os resultados da análise de sensibilidade dos atributos utilizados no modelo de reservatório do Caso 2B, com relação a um dos poços (PROD4) e a média aritmética dos oito poços. O eixo horizontal apresenta a variação percentual no valor do afastamento, em relação ao Caso Base (modelo de referência), e o eixo vertical apresenta os atributos, sendo que a cor em bege indica que o atributo foi alterado para o seu limite inferior e a cor em azul indica que ele foi alterado para o seu limite superior. Valores negativos indicam que o afastamento do modelo piorou em relação ao afastamento do Caso Base e valores positivos indicam o contrário (exemplo na Figura 3.1).




Figura 6.25 – Análise de sensibilidade para o afastamento da produção de água do poço PROD4 (a) e média aritmética (b) – Caso 2B.

A Figura 6.25 (a) mostra que existem atributos que não influenciam na produção de água do poço PROD4, sendo que, nesse caso em particular, são poucos os atributos que influenciam. O poço PROD7 também teve poucos atributos que o influenciam, porém, para os demais poços a quantidade de atributos que influenciam é maior (ver Tabela 5.3).

Observa-se que enquanto a variação de um atributo acarreta uma redução do afastamento (em relação ao Caso Base) para o poço PROD4, para a média ela acarreta em aumento. Como os

atributos são regionalizados, o impacto que cada um deles causa varia de poço a poço, podendo ser até desprezível, como pode ser observado pelos resultados para o PROD4.

A Tabela 6.14 mostra os valores numéricos do gráfico apresentado na Figura 6.25. As colunas do limite inferior e limite superior mostram a variação porcentual do afastamento quando os valores dos atributos são alterados para os seus limites inferior e superior, respectivamente.

Tabela 6.14 – Análise de sensibilidade do poço PROD4 e da média dos oito poços.

Atributo	Variação no afastamento - PROD4 (%)		Variação no afastamento - média (%)	
	Limite inferior	Limite superior	Limite inferior	Limite superior
Por1	0	0	-2	1
Por2	0	0	-45	10
Por3	0	0	-13	-6
Kx1	0	0	-23	16
Kx2	4	0	33	-10
Kx3	0	8	11	-19
Kz1	0	0	0	0
Kz2	0	0	-19	10
Kz3	0	0	7	-7
F1	0	0	1	0
F2	0	0	-9	-1
F3	0	0	6	-3
F4	19	0	22	0
Kr1	0	0	4	-5
Kr2	42	0	-176	7
Kr3	41	0	-23	-11

Conforme mostra a Tabela 6.14, para o poço PROD4, ao modificar o valor da permeabilidade horizontal da fácies 3 para o limite superior, reduziu-se em 8% o afastamento em relação ao Caso Base; ao modificar os atributos permeabilidade horizontal da fácies 2, transmissibilidade da falha 4 e os expoentes do modelo de *Corey* para a permeabilidade relativa da água das fácies 2 e 3 para o limite inferior reduziu-se o afastamento em 4%, 19%, 42% e 41%, respectivamente. Os demais atributos não influenciaram no afastamento para esse poço, nem ao aumentar seus valores para o limite superior, nem ao reduzir seus valores para o limite inferior. Baseado nesses valores obtidos definiu-se que os atributos F4, kr2 e kr3 devem ser aqueles a

serem utilizados como entrada para treinar a RNA na representação do comportamento do poço PROD4, pois apresentaram maior influência nos resultados para esse poço.

Considerando a média dos afastamentos dos poços, foram utilizados nove atributos: por2, por3, kx1, kx2, kx3, kz2, F4, kr2 e kr3. Foram escolhidos os atributos nos quais a soma da variação percentual quando alterados os limites inferior e superior fosse maior que 20%. O mesmo procedimento foi adotado para definição dos atributos que mais influenciam os demais poços.

Os atributos encontrados com a análise de sensibilidade poço a poço foram utilizados para treinar as RNA no caso de treinar um RNA para cada poço. No caso de treinar uma única RNA para representar todos os poços, os atributos determinados segundo a análise de sensibilidade para a média dos afastamentos dos poços foram utilizados.

6.7.2 Passo 1: Definição do conjunto de treinamento

A Figura 6.26 mostra os gráficos de dispersão dos pontos de treinamento entre os atributos Kz2 e Kr2, relativos aos conjuntos HL100 (a) e HL250 (b) pontos.

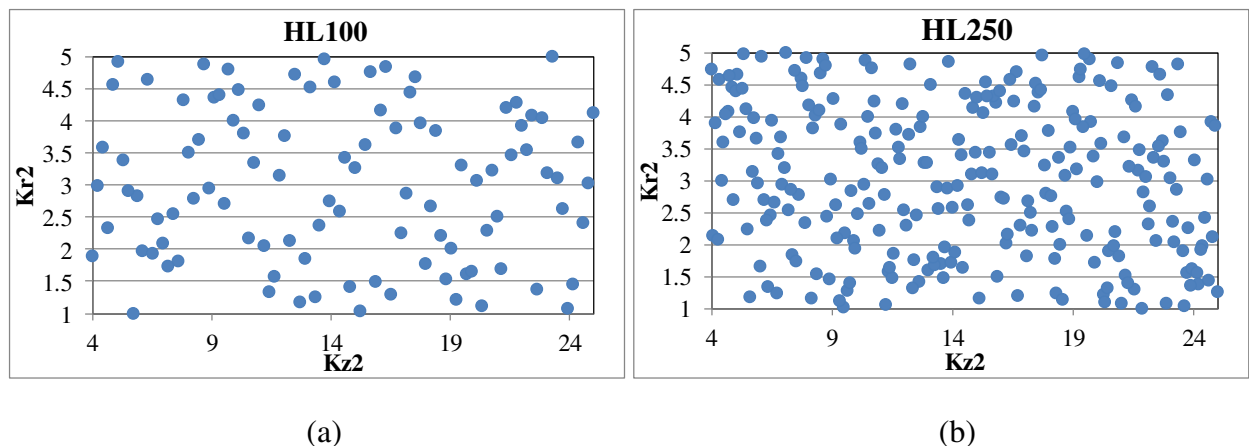


Figura 6.26 – Gráfico de dispersão dos pontos de treinamento entre os atributos Kz2 e Kr2, relativo aos conjuntos HL100 (a) e HL250 (b) pontos – Caso 2B.

Os gráficos da Figura 6.26 mostram que os pontos seguem uma distribuição aproximadamente uniforme no espaço, sendo que os HL250 pontos apresentam mais pontos próximos uns dos outros. Em contrapartida os HL100 pontos apresentam algumas “lacunas”, que

são as áreas sem informação do comportamento a respeito do espaço de soluções. Essa característica de espaçamento, conforme já mencionado (Subitem 6.1.1), se deve ao fato de que o HL realiza a combinação das diversas variáveis de forma aleatória, de modo que, mesmo que os pontos estejam bem espaçados entre uma variável e outra, eles podem não estar com relação a uma terceira. Observa-se ainda que os pontos extremos de cada variável foram amostrados, porém, as condições extremas não (amostras situadas em um dos quatro cantos dos gráficos da Figura 6.26). O mesmo padrão foi observado para os demais atributos.

A Figura 6.27 mostra os gráficos de dispersão dos pontos de treinamento entre os atributos Kz2 e Kr2, referente aos conjuntos HL396 (a) e BB396 (b).




Figura 6.27 - Gráficos de dispersão dos pontos de treinamento entre os atributos Kz2 e Kr2, referente aos conjuntos HL396 (a) e BB396 (b) – Caso 2B.

A diferença entre as duas técnicas pode ser observada comparando-se os gráficos da Figura 6.27. Apesar da Figura 6.27 (b) mostrar que as condições extremas entre essas duas variáveis foram amostradas, o mesmo não ocorre quando comparadas todas as dezesseis variáveis, ou seja, um modelo composto pelos valores extremos de todas as variáveis. Conforme mencionado no Subitem 2.4.1 de fundamentação teórica, o BB utiliza uma matriz pré-definida, composta por valores extremos e médios, em que as combinações entre as variáveis também são pré-definidas.

6.7.3 Passo 2: Treinamento das redes neurais artificiais e análise de desempenho dos metamodelos gerados

Das opções de configuração de RNA definidas no Subitem 5.3 de aplicação, nesse capítulo serão mostrados apenas os resultados relativos aos metamodelos gerados com a opção 4 de configuração (PROD_AS – produtores, com análise de sensibilidade), que consistiu em treinar uma RNA com oito saídas (representando os oito poços produtores), em que, como entrada, foi utilizado o conjunto com os nove atributos que mais influenciam a média dos afastamentos dos oito poços produtores.

De acordo com os resultados, através dessa opção de configuração, obteve-se o modelo de RNA que gerou o menor afastamento final, ao simular o modelo de simulação encontrado com a otimização utilizando o metamodelo. Esses resultados são mostrados resumidamente no Apêndice II.

Com a utilização de oito RNA independentes, eventuais inter-relações existentes entre os poços não puderam ser captadas. Por outro lado, a utilização de uma única rede para representar os oito poços pode captar essas inter-relações, o que constitui uma possível causa para seus melhores resultados.

Quanto aos atributos, utilizar apenas aqueles sugeridos pela análise de sensibilidade também pode contribuir para melhorar os resultados, pois são selecionados apenas os mais importantes para a Função Objetivo (maior influência).

A Tabela 6.15 mostra os valores dos coeficientes de correlação linear entre saídas geradas através do simulador de escoamento (afastamento da produção de água do modelo com relação ao histórico) e do metamodelo (coeficientes poço a poço, geral e média, para as oito saídas), com relação aos metamodelos gerados com BB396, HL396, HL250 e HL100 pontos com a configuração de rede do tipo PROD_AS. As linhas “Tr” são relativas ao conjunto de treinamento e as linhas “Tt” são relativas ao conjunto de teste.

Tabela 6.15 – Coeficientes de correlação linear dos metamodelos gerados – PROD_AS – Caso 2B.


Meta modelo	Tipo dado	PROD								Geral	Média
		1	2	3	4	5	6	7	8		
BB396	Tr	0.80	0.95	0.89	0.75	0.88	0.87	0.98	0.72	0.93	0.86
	Tt	0.63	0.95	0.86	0.66	0.91	0.86	0.78	0.60	0.89	0.78
HL396	Tr	0.74	0.98	0.96	0.83	0.95	0.91	0.95	0.70	0.96	0.88
	Tt	0.62	0.96	0.95	0.78	0.92	0.92	0.86	0.70	0.94	0.84
HL250	Tr	0.83	0.97	0.95	0.82	0.93	0.90	0.95	0.83	0.95	0.90
	Tt	0.56	0.97	0.96	0.80	0.90	0.83	0.90	0.85	0.93	0.85
HL100	Tr	0.87	0.98	0.96	0.78	0.94	0.89	0.91	0.82	0.96	0.89
	Tt	0.67	0.95	0.94	0.73	0.91	0.84	0.83	0.75	0.92	0.83

Conforme mostra a Tabela 6.15, alguns poços como o PROD1, PROD4 e PROD8 resultaram em baixos valores de correlação linear comparativamente aos demais poços, independentemente da quantidade e tipo de dado amostrado. Isso pode ser devido a não linearidade existente entre entrada e saída, diferente para cada poço.


Apesar das diferenças nos coeficientes poço a poço, os coeficientes de correlação linear geral (coeficiente analisando as oito saídas juntas) atingiram valores relativamente altos.

Ao comparar a média dos valores de correlação linear pode-se observar que os metamodelos gerados com HL tiveram valores semelhantes (HL396-0.84, HL250-0.85 e HL100-0.83) e foram superiores ao metamodelo gerado com BB (BB396-0.78).


As Figura 6.28 e Figura 6.29 mostram os gráficos de dispersão (*crossplot*) entre saída do simulador de escoamento e do metamodelo, para os poços PROD2 (Figura 6.28) e PROD3 (Figura 6.29).




(a)



(b)




(c)




(d)


Figura 6.28 - Gráficos de dispersão (*crossplot*) para o poço PROD2 – PROD_AS – Caso 2B.




(a)



(b)



(c)



(d)

Figura 6.29 - Gráficos de dispersão (*crossplot*) para o poço PROD3 – PROD_AS – Caso 2B.

Comparando os gráficos de HL396 e BB396 observa-se que o gráfico do metamodelo HL396 está um pouco melhor, pois os pontos se concentram mais ao redor da linha “ $y=x$ ” em preto, o que demonstra melhor correlação linear. Analisando apenas os gráficos do HL, pode-se observar uma melhoria do metamodelo gerado com 250 pontos em relação ao gerado com 100 pontos, relativo à concentração dos pontos ao redor da linha “ $y=x$ ”, porém entre os metamodelos gerados com 250 e 396 pontos não é possível observar grandes diferenças.

Realizando a comparação entre os poços, a correlação linear para o poço PROD2 foi melhor do que para o poço PROD3, concentrando mais valores com afastamento menor (mais

perto da origem) enquanto que para o poço PROD3, além de poucos valores perto do mínimo, eles ficaram dispersos. Isso demonstra que o poço PROD3 oferece mais dificuldade em relação ao poço PROD2 para modelar, de modo que se pode inferir que existe maior não linearidade entre entrada e saída para o poço PROD3, comparativamente ao poço PROD2. Para os demais poços, também existem aqueles com dados mais concentrados perto da origem, quanto dados mais afastados ou mais dispersos.

A Figura 6.30 mostra os coeficientes de correlação linear da Tabela 6.15 na forma de barras para visualizar melhor a diferença que existe entre os poços e os tipos de dados. O grupo de barras que aparecem na esquerda representam os resultados do treinamento e os que aparecem na direita representam os resultados do teste.




Figura 6.30 – Coeficiente de correlação linear em gráfico de barras; grupo de barras da esquerda: resultados do treinamento; grupo de barras da direita: resultados do teste – Caso 2B.

A diferença entre a correlação dos dados de treinamento e dos dados de teste que pode ser visualizada na Figura 6.30 é natural, uma vez que os dados de teste são dados para os quais o

metamodelo nunca foi utilizado. Pela Figura 6.30 fica claro que os valores de correlação linear para os poços PROD1, PROD4 e PROD8 foram piores, comparativamente aos demais poços.

Os valores de correlação linear mostrados na coluna “Geral” (relativo aos oito poços) e na coluna “Média” mostram que o desempenho dos metamodelos gerados pelo HL foi melhor que o do metamodelo gerado pelo BB. Em relação aos metamodelos gerados pelo HL pode-se observar que o aumento do número de amostras contribuiu para melhorar o valor da correlação linear quando comparados os resultados para os conjuntos de 100 e 250 pontos. Porém, não houve melhora na qualidade dos resultados ao aumentar de 250 para 396 pontos.

Uma possibilidade para a qualidade inferior do metamodelo HL396 com relação ao H1250 seria a memorização, ou seja, o metamodelo, apesar de boa correlação, estaria começando a memorizar os resultados e isso pode ter contribuído para que não houvesse um aumento expressivo na sua capacidade de generalização.

6.7.4 Passo 3: Otimização utilizando o metamodelo e validação do mínimo encontrado

A Tabela 6.16 mostra os afastamentos dos oito poços produtores e a sua média aritmética (coluna “Média”) em valores numéricos e percentuais, que indicam a redução do afastamento em relação ao Caso Base (qualidade do metamodelo – Equação 3.3 e Figura 3.1). Para obter os valores dos afastamentos, os valores dos atributos (ponto de mínimo) encontrados com a otimização utilizando o metamodelo foram substituídos no simulador de escoamento. O objetivo dessa tabela é apresentar um resumo dos resultados de forma quantitativa. Porém, a sua análise dever ser realizada em conjunto com os gráficos de produção apresentados mais adiante.

Tabela 6.16 – Valores de afastamento e indicador de qualidade (%), obtidos com a simulação do mínimo ($\times 10^6$) – PROD_AS – Caso 2B.

Modelo	PROD ($\times 10^6$) – Valores absolutos								Média
	1	2	3	4	5	6	7	8	
Base	0.973	4.32	31.9	5.76	11.5	0.738	1.10	0.439	7.09
BB396	1.44	1.34	0.493	0.0176	7.28	0.273	0.204	0.108	1.39
HL396	3.49	0.179	2.16	9.17	1.44	0.0153	0.919	0.0083	2.17
HL250	2.68	0.0413	1.28	0.0791	1.92	0.716	0.0738	0.0052	0.851
HL100	0.924	0.525	2.40	7.75	0.278	0.217	0.257	0.708	1.63
Valores em %									
BB396	-48	69	98	100	37	63	81	75	80
HL396	-259	96	93	-59	87	98	16	98	69
HL250	-175	99	96	99	83	3	93	99	88
HL100	5	88	92	-35	98	71	77	-61	77

Analisando a coluna “Média” para porcentagem da Tabela 6.16 pode-se observar que em geral a metodologia proposta foi capaz de melhorar o Caso Base, variando de uma redução de 69% no valor do afastamento para o metamodelo gerado com HL396 pontos até uma redução de 88% no valor do afastamento para o metamodelo gerado com HL250 pontos.

A otimização utilizando o metamodelo gerado com HL396 acabou piorando o afastamento do poço PROD1 em relação ao Caso Base muito mais que em relação aos demais metamodelos (-259%), o que explica a média menor em relação aos demais. Porém, o poço PROD1, conforme mostrado na Figura 6.31 (a) adiante, já estava razoavelmente ajustado e possui vazão de produção de água elevada, de modo que uma pequena variação da curva acaba gerando valor de erro muito alto.

Os resultados para o metamodelo HL250 mostrados na Tabela 6.16 indicam que os ajustes para os poços PROD1 e PROD6 não foram bons. Porém, conforme citado no parágrafo anterior o poço PROD1 já se encontrava relativamente bem ajustado e a Figura 6.32 (b), apresentada adiante, mostra que o poço PROD6 também se encontrava bem ajustado. Para os demais poços a otimização utilizando o metamodelo HL250 melhorou o Caso Base consideravelmente (todos acima de 80%), indicando que a sua utilização proporcionou bons ajustes das curvas de produção dos poços.

A Figura 6.31 e a Figura 6.32 mostram as curvas de produção de água geradas pela simulação dos modelos encontrados através da otimização utilizando os metamodelos, assim como a curva do Caso Base e do histórico, para todos os poços.

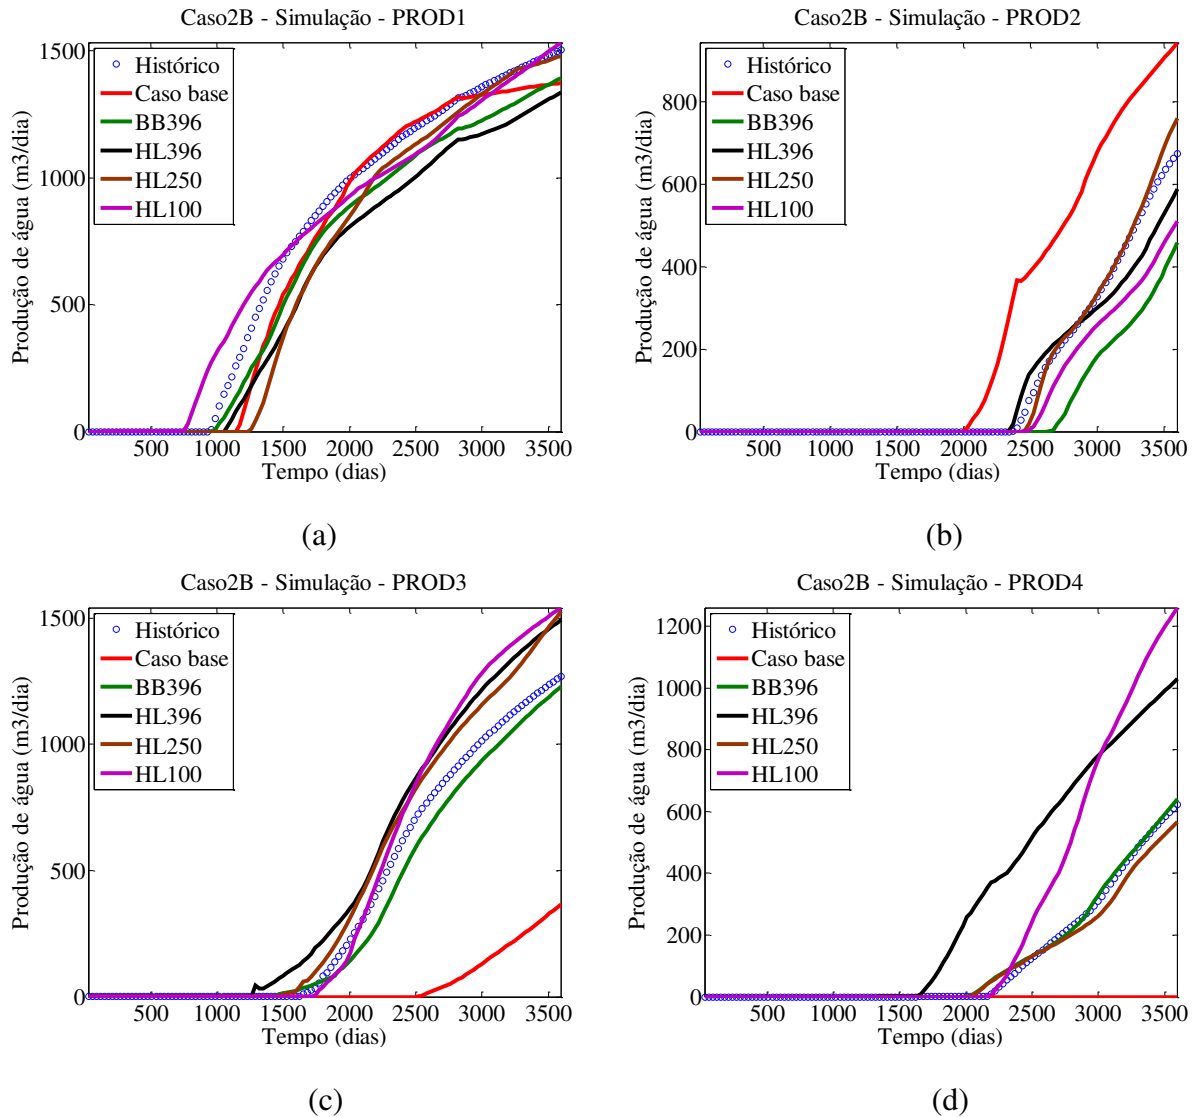


Figura 6.31 – Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD1 (a), PROD2 (b), PROD3 (c) e PROD4 (d) – PROD_AS – Caso 2B.

A Figura 6.32 (a) do poço PROD1 mostra que a curva do Caso Base (vermelho) já estava bem ajustada, justificando o comentário realizado anteriormente sobre pequenos desvios das curvas gerarem grandes erros, conforme observado na Tabela 6.16. Para os poços PROD2, PROD3 e PROD4 é possível notar que houve melhora na curva de produção de água com relação ao Caso Base, sendo que para o PROD4 a curva do metamodelo HL250 se aproximou bastante do

histórico e do metamodelo BB396 ajustou o histórico perfeitamente. Em contrapartida, os modelos otimizados através dos metamodelos HL100 e HL396 apresentaram uma vazão de água maior que o histórico.

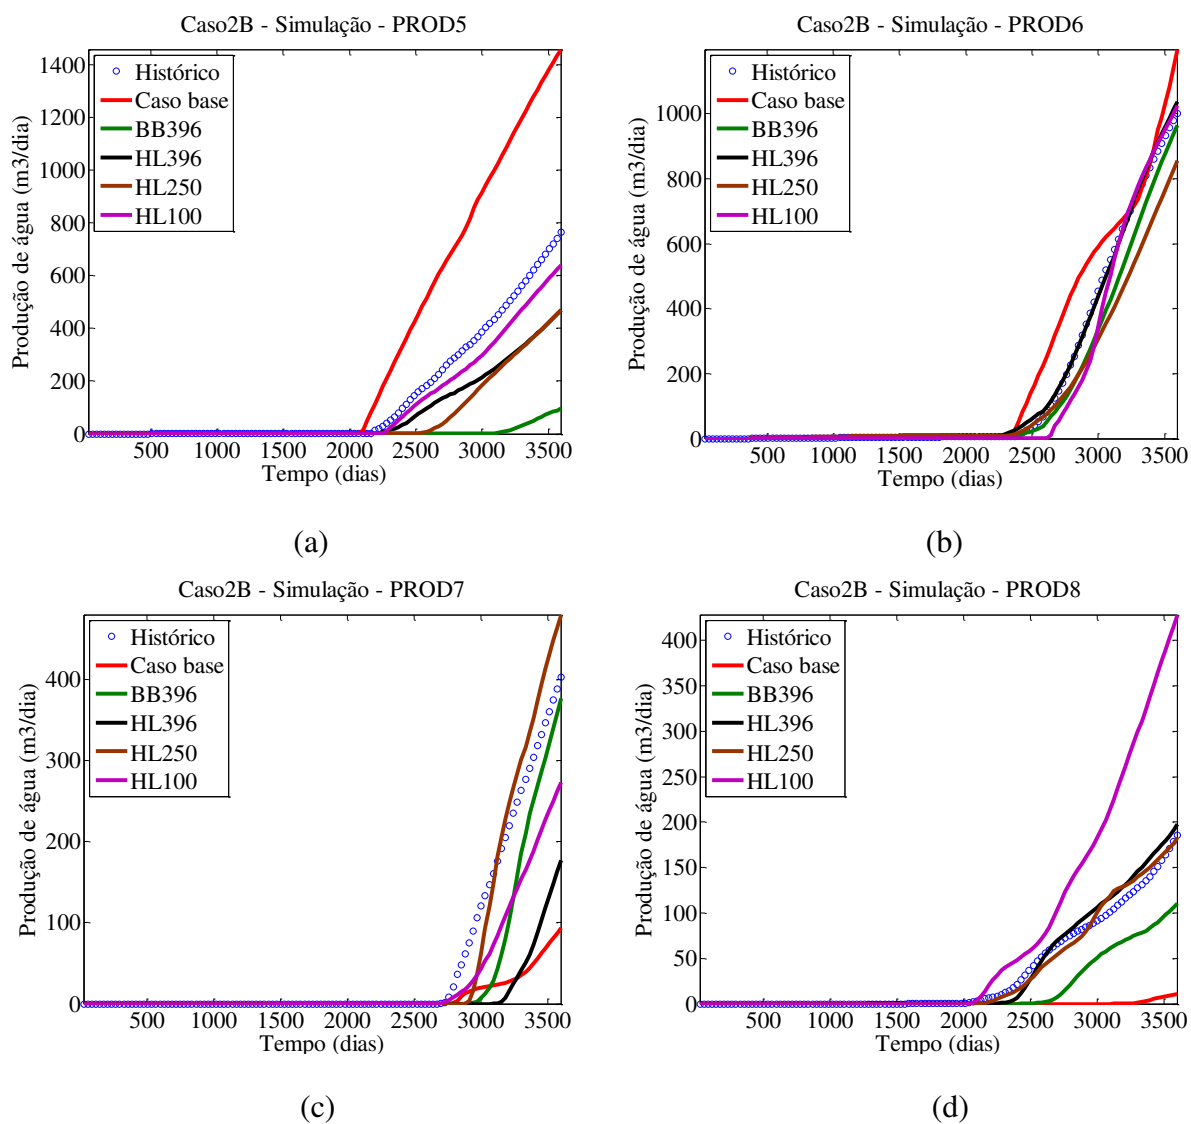


Figura 6.32 - Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD5 (a), PROD6 (b), PROD7 (c) e PROD8 (d) – PROD_AS – Caso 2B.

Para os poços PROD5, PROD6, PROD7 e PROD8, os modelos encontrados melhoraram o Caso Base.

Os resultados mostram que a qualidade dos resultados para os metamodelos gerados com HL foi superior em comparação a do BB. Em relação à quantidade de amostras, comparando os

resultados do HL, houve uma melhora significativa dos resultados para os casos com 250 e 396 pontos em relação ao caso com 100 pontos. No entanto, o resultado do metamodelo gerado com HL250 pontos foi melhor do que o HL396 pontos. Pode ser que o metamodelo HL396 escolhido estivesse começando a memorizar os resultados, o que constitui uma possível explicação para sua qualidade inferior. Uma maneira de contornar esse problema seria utilizar diversos metamodelos gerados para a fase de otimização e realizar a comparação entre eles através da validação com o simulador de escoamento. Os resultados também sugerem que a melhora na qualidade do metamodelo não é linear com o aumento da quantidade de amostras, tendendo, possivelmente, a um ponto de saturação, em que a adição de mais pontos não aumenta de forma expressiva a qualidade dos resultados.

6.7.5 Passo 4: Retreinamento

Para avaliar o efeito do retreinamento foi utilizado o metamodelo HL100_PROD_AS. Conforme critério de corte definido na seção 4.2.2, o valor de corte considerado para esse caso foi 70% da Função Objetivo do Caso Base, ou seja, o valor máximo e mínimo de variação dos atributos dos modelos que conseguiram reduzir mais que 30% a média dos afastamentos (oito poços) com relação à média do Caso Base.

A Tabela 6.17 mostra os coeficientes de correlação linear entre saída do simulador e do metamodelo para o conjunto de treinamento, relativo ao novo processo de treinamento.

Tabela 6.17 - Coeficientes de correlação linear – PROD_AS – Caso 2B – retreinamento.

Nome		PROD								Geral	Média
		1	2	3	4	5	6	7	8		
HL100 RTR	Tr	0.83	0.98	0.97	0.90	0.94	0.98	0.75	0.82	0.97	0.90

A Tabela 6.17 mostra que o retreinamento resultou em boa correlação linear, atingindo uma média de 0.90.


A Tabela 6.18 mostra os valores numéricos e percentuais (que indicam a redução com relação ao Caso Base, ou seja, qualidade do ajuste – Equação 3.3) dos afastamentos poço a poço e a média aritmética dos oito poços, calculados a partir da simulação do modelo obtido com a otimização utilizando o metamodelo HL100_PROD_AS e HL100_PROD_AS_RTR (retreinamento). Foram inseridos também os valores de afastamento do Caso Base para comparação.

Tabela 6.18 – Valores de afastamento gerados com a simulação dos mínimos obtidos com a otimização – PROD_AS – Retreinamento – Caso 2B.


Nome	PROD ($\times 10^6$)								Total
	1	2	3	4	5	6	7	8	Média
PROD ($\times 10^6$) – Valores absolutos									
Base	0.973	4.32	31.9	5.76	11.5	0.738	1.10	0.439	7.09
HL100	0.924	0.525	2.40	7.75	0.278	0.217	0.257	0.708	1.63
HL100 RTR	0.761	0.111	0.849	1.20	1.87	1.62	0.00708	0.0575	0.809
Valores em %									
HL100	5	88	92	-35	98	71	77	-61	77
HL100 RTR	22	97	97	79	84	-120	99	87	89

A Tabela 6.18 mostra que o treinamento proporcionou melhor ajuste em comparação ao treinamento anterior (HL100), conseguindo um valor médio de 89% do indicador de ajuste, chegando a valores similares aos alcançados no treinamento com HL250 pontos (88%). Apesar disso, os ajustes para os poços PROD5 e PROD6 pioraram em relação ao treinamento. O poço PROD6, porém, estava bem ajustado, e qualquer pequena alteração resultaria em grandes mudanças em seu valor percentual.


Os gráficos da Figura 6.33 mostram as curvas de produção de água dos poços PROD1 (a), PROD2 (b), PROD3 (b) e PROD4 (b), referente ao treinamento, comparadas com o histórico.




(a)



(b)



(c)



(d)

Figura 6.33 – Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD1 (a), PROD2 (b), PROD3 (b) e PROD4 (b) – retreinamento – Caso 2B.

Os gráficos para esses quatro poços mostram que houve melhora no ajuste dos poços.

Os gráficos da Figura 6.34 mostram as curvas de produção de água dos poços PROD5 (a), PROD6 (b), PROD7 (b) e PROD8 (b), referente ao retreinamento.

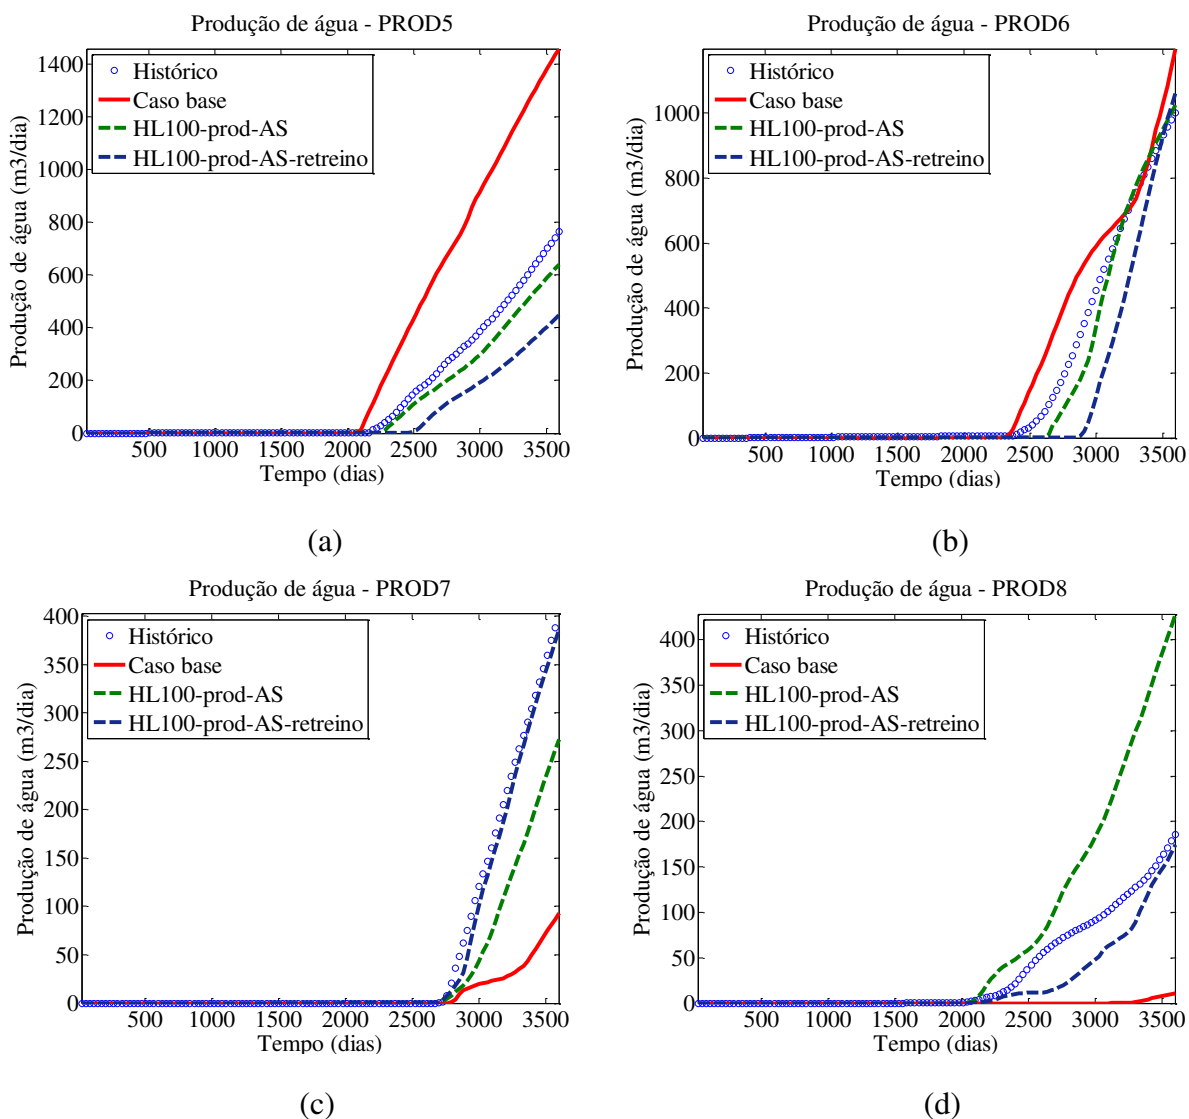


Figura 6.34 – Simulação dos mínimos encontrados com a otimização utilizando os metamodelos para os poços PROD5 (a), PROD6 (b), PROD7 (b) e PROD8 (b) – retreinamento – Caso 2B.

Pela Figura 6.34 (b) pode-se observar que a curva para o poço PROD6 não ficou tão desajustada quanto mostra o resultado da Tabela 6.18 (-120%). Já as curvas dos poços PROD7 e PROD8 melhoraram significativamente.

Em relação aos poços PROD7 e PROD8 pode-se observar que, apesar de seus coeficientes de correlação linear resultarem em valores menores, as curvas de produção ficaram bem ajustadas. Uma explicação para esse fato é que, ao utilizar uma rede para representar os oito poços produtores, é possível que o metamodelo tenha conseguido captar eventuais interdependências que podem existir entre os poços. Além disso, o fato de o processo de

otimização consistir em otimizar a média de produção dos oito poços, os poços com valores elevados de afastamento acabaram influenciando mais nos resultados, comparativamente aos poços com valores de afastamento menores, como nos poços PROD7 e PROD8. Dessa maneira, uma avaliação do processo de otimização também pode contribuir para melhorar os resultados, o que pode ser feito em trabalhos futuros, pois não era o foco desse trabalho.

6.8 Comentários gerais dos casos de reservatório.

O estudo dos casos de reservatório (Caso 2A e Caso 2B) possibilitou validar os resultados obtidos com os casos teóricos (Casos 1A a 1D) e estendê-los a casos complexos.

Com o aumento da dificuldade de modelagem do problema, ou seja, à medida que o espaço de soluções a qual se deseja modelar se torna mais irregular e o número de atributos aumenta, a obtenção de um metamodelo capaz de modelar esse espaço se torna mais difícil.

Os resultados obtidos indicam que, para o caso estudado nesse trabalho (Caso 2B), a utilização do metamodelo para substituir o simulador de escoamento em todo o processo de ajuste não é recomendável. Para casos com muitos atributos incertos, a melhor utilização é como ferramenta auxiliar, para ajudar em etapas que demandam maior esforço computacional, sendo a etapa de varredura do espaço de soluções uma das que deve agregar mais valor aos resultados. Dessa maneira, em situações em que o número de simulações de escoamento é um fator limitante, como no caso de ajuste de histórico, a utilização do metamodelo é indicada em etapas que não exigem muita precisão nos resultados.

Quando a quantidade de amostras se torna um fator limitante para o problema, o espaço a ser modelado também se torna um fator limitante. Com o aumento do número de variáveis, se o espaço a ser modelado for muito grande, a amostragem eficiente do espaço de busca dos parâmetros se torna difícil, e às vezes até inviável, e, conseqüentemente, a geração de um metamodelo capaz de modelar o espaço de soluções precisamente também se torna difícil. Uma sugestão para essas situações é realizar a adição gradativa de amostras à medida que se gera e valida o metamodelo com o simulador. Outra sugestão seria realizar um estudo preliminar para

simplificar o problema, como por exemplo, realizar uma otimização rápida, a fim de determinar uma região menor do espaço de soluções para treinar as redes.

Conforme mostrado nos resultados, a avaliação do coeficiente de correlação linear e erro médio serviram apenas para uma análise preliminar, não sendo possível chegar a conclusões precisas se os metamodelos gerados são adequados para representar o problema em questão. Dessa maneira, um metamodelo que possivelmente tenha sido capaz de modelar com mais precisão a região de mínimo de interesse pode não ter sido escolhido. Assim, recomenda-se utilizar diversos metamodelos com coeficiente de correlação bom e posteriormente realizar a validação deles com a resposta do simulador para verificar qual metamodelo melhor representou o problema. Pelo fato do problema de ajuste de histórico possuir múltiplas soluções não se deve realizar a escolha dos metamodelos apenas através do coeficiente de correlação linear.

Mesmo amostrando valores extremos dos atributos, as técnicas de amostragem dificilmente amostram condições extremas, de modo que se o mínimo se encontrar na região próxima de uma condição extrema o metamodelo não será capaz de detectá-lo. Para esses casos, uma solução seria realizar novo treinamento, porém amostrando novamente todo o espaço de busca dos parâmetros forçando a inclusão das condições extremas, para garantir a varredura, mesmo que superficial de todo o espaço de soluções.

A respeito do Hipercubo Latino, foi adotada uma distribuição uniforme para todos os atributos. Porém, caso se tenha conhecimento da função de distribuição de probabilidade dos atributos, a técnica permite que essa informação seja incluída no processo de amostragem, o que pode contribuir para melhorar a qualidade dos dados de treinamento, pois o conjunto de treinamento estaria englobando atributos com valores mais prováveis.

A escolha de uma região adequada para retreinamento (que contenha o mínimo de interesse) está diretamente relacionada com a qualidade do metamodelo gerado, de modo que, se o metamodelo não for capaz de identificar a região do mínimo de interesse, há grandes chances de que esse mínimo não seja encontrado com o retreinamento (refinamento). Nesse aspecto a característica de suavização da superfície de resposta se torna fator limitante para utilização de metamodelos gerados por RNA, pois, se informações suficientes não forem amostradas na região do mínimo de interesse, a RNA irá suavizar essa região e ela dificilmente será encontrada.

Isso mostra a grande importância que a técnica de amostragem tem sobre o desempenho do metamodelo gerado. Se a técnica de amostragem for capaz de coletar informações suficientes da região do mínimo de interesse, essa região será identificada e um refinamento posterior identificará o mínimo, porém, se na amostragem inicial essas informações não forem coletadas o metamodelo dificilmente irá identificar essa região. Um procedimento que poderia ser adotado, caso não se tenha informações da região de interesse, consiste em utilizar a rede após uma pré-otimização com alguma técnica que demande menos simulações.

Lima *et al.*(2009) realizaram um procedimento diferente, avaliando os resultados em duas regiões distintas: uma região macro, englobando todo o espaço de soluções, e uma região micro, mais específica, possivelmente englobando o mínimo. A realização de uma avaliação em uma região específica possibilita identificar um metamodelo que, mesmo que não proporcione uma representação satisfatória quando avaliado globalmente, possa ter sido capaz de modelar melhor a região de mínimo. Assim, a utilização desse tipo de procedimento pode ajudar na etapa de análise de desempenho das RNA treinadas e na escolha dos melhores metamodelos gerados.

7 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Nesse trabalho foi avaliada a aplicação de metamodelos gerados por redes neurais artificiais (RNA) para serem utilizados no lugar do simulador de escoamento no processo de ajuste de histórico. Por ser tratar de uma estrutura simplificada, já era esperado que o metamodelo não fosse capaz de reproduzir o comportamento do simulador com 100% de precisão. Apesar disso, através do estudo do Caso 2B foi possível concluir que a ferramenta pode ser uma opção viável para ser aplicada ao processo de ajuste de histórico para casos práticos.

Casos teóricos

O objetivo dos casos teóricos foi avaliar as características do metamodelo através de uma análise visual do espaço de soluções (superfície de resposta), o que é impossível de se obter para casos práticos de reservatório, que tipicamente possuem bem mais que duas variáveis incertas. Essa análise permitiu identificar e avaliar as qualidades e limitações que o modelo de RNA escolhido possui. As principais características identificadas foram:

- Amostragem: para casos simples a diferença na característica de espaçamento entre as amostras não exerceu grande influência. Para casos com irregularidades, porém, as diferenças apareceram. No entanto, quando se aumentaram o número de amostras, a diferença entre as técnicas se tornou irrelevante, além de melhorar a qualidade da resposta.
- Retreinamento: mesmo se no conjunto de treinamento não houver informações suficientes para detectar o mínimo, mas apresentar boas informações sobre a região na qual ele se situa a RNA será capaz de identificar essa região e um refinamento posterior, poderá ter grandes possibilidades de identificar com boa precisão o mínimo de interesse. Esse aspecto foi comprovado através do estudo do Caso 1B.

- Suavização do espaço de soluções: a característica em que nas áreas do espaço de soluções para a qual não há dados de treinamento (não há informações) a RNA tende a suavizar a curvatura da superfície pôde ser observada em todos os casos, na ocasião de comparar as superfícies de resposta geradas.
- Superfície irregular: quando o espaço de busca dos parâmetros é muito grande e irregular, o metamodelo necessita de uma quantidade maior de amostras que descrevam o padrão de comportamento da superfície nessas regiões para obter resultados confiáveis, conforme constatado pelo estudo do Caso 1C.
- Indicadores: o indicador de erro utilizado nos casos teóricos não foi eficaz em situações em que o mínimo se localizava perto da origem, pois o erro tendia a ficar muito grande. Como esse indicador era apenas um complemento para os resultados não houve problemas, porém isso mostra que a escolha de um indicador adequado ao problema é importante para avaliar os resultados corretamente.

Casos de reservatório

Através do Caso 2B foi possível avaliar a aplicabilidade do metamodelo gerado através de RNA em situações práticas. O Caso 2A mostrou que em casos mais simples a RNA encontra bons resultados facilmente. Porém com o aumento da complexidade do problema (Caso 2B), fica mais difícil encontrar uma configuração de rede capaz de representar o problema.

Algumas conclusões que foram realizadas através dos casos de reservatório foram:

- Técnica de amostragem: a técnica do Hipercubo Latino (HL) proporcionou melhores resultados comparativamente ao Box Behnken (BB). Uma possível explicação vem do fato do HL realizar amostragem em um intervalo contínuo de valores, ao passo que o BB amostra apenas valores normalizados (mínimo, médio e máximo).
- Quantidade de amostras: no Caso 2B, houve melhora nos resultados com o aumento de 100 para 250 pontos, porém, o mesmo não foi observado ao se aumentar de 250 para 396 pontos. Duas possíveis explicações são: ou o metamodelo gerado com 396 pontos memorizou os resultados ou a qualidade dos resultados não segue uma relação linear com a quantidade de amostras, ou seja, seria necessário aumentar ainda mais a quantidade de amostras para observar melhora nos resultados.

- Indicador de qualidade do metamodelo: foi utilizado o valor do coeficiente de correlação linear para escolher um dado metamodelo após o treinamento para ser submetido ao processo de otimização. A avaliação da sua capacidade de representar o simulador de escoamento, no entanto, deve ser realizada através da validação com o simulador, executando a simulação da resposta encontrada pelo metamodelo e comparando as curvas de produção e pressão simuladas com o histórico, pois, dependendo do conjunto de teste, um metamodelo com coeficiente de correlação linear bom pode não proporcionar bons resultados.
- Configuração da RNA: nesse trabalho, mais especificamente no Caso 2B, foi testada a utilização de um metamodelo para representar cada poço produtor e um metamodelo para representar todos os poços produtores. Os resultados mostraram que a utilização de um metamodelo para representar todos os poços produtores é a melhor opção. O motivo, conforme explicado no Subitem 6.7, reside principalmente no fato de que a utilização de um metamodelo possibilita que possíveis interações que possam existir entre os poços sejam captadas.
- Atributos de entrada: a utilização dos atributos escolhidos segundo a análise de sensibilidade proporcionou resultados mais precisos, comparativamente à utilização de todos os dezesseis atributos do reservatório previamente escolhidos. Conforme mostrado no Subitem 6.7.1, a análise de sensibilidade possibilitou a eliminação de atributos que não estavam exercendo grandes influências na produção de água.
- Metamodelo como substituto do simulador: foi mostrado que é possível utilizar o metamodelo como substituto do simulador em partes do processo em que não se requer grande precisão dos resultados, sendo que o controle de qualidade da resposta (validação) pode dar mais confiabilidade aos resultados.
- Retreinamento: os resultados do retreinamento com HL100 pontos mostraram que a utilização de menos pontos no treinamento e um refinamento posterior pode ser uma boa opção. Com um total de 200 pontos foi possível obter índice de qualidade de ajuste semelhante ao obtido com o treinamento utilizando 250 pontos.

A partir dos resultados obtidos conclui-se que a ferramenta pode ser utilizada em conjunto com o simulador de escoamento no processo de ajuste de histórico, porém, não é recomendável a

sua utilização como substituta do simulador no processo inteiro, pois por se tratar de um modelo simplificado sempre há uma margem de erro envolvida. Assim, a ferramenta pode contribuir em etapas do processo que não demandem grande precisão dos resultados. Para avaliar a confiabilidade dos resultados gerados pelo metamodelo deve-se realizar a validação da resposta encontrada com o mesmo utilizando o simulador de escoamento.

Sugestões para trabalhos futuros

Segue abaixo algumas sugestões que surgiram durante o desenvolvimento do trabalho, que podem contribuir para o prosseguimento da pesquisa:

- Ferramenta de otimização: nesse trabalho foi utilizado o Algoritmo Genético (AG) apenas como ferramenta complementar ao estudo, sem se preocupar em obter a melhor configuração ou a melhor forma de aplicação da ferramenta. Assim, a etapa de otimização dos atributos utilizando o AG pode ser melhorada através de um estudo mais detalhado da ferramenta. Existem ainda diversas ferramentas que podem ser utilizadas no processo de otimização, que podem ser testadas e, possivelmente, ajudar a melhorar os resultados.
- Utilização de pesos: a utilização de uma Função Objetivo (FO) com peso para cada saída ou a utilização de algum critério que torne a influência maior dos poços com melhor desempenho pode contribuir para obtenção de melhores ajustes.
- Pré-otimização: uma opção interessante seria a realização de uma pré-otimização antes de amostrar os dados. O procedimento consistiria em realizar uma otimização rápida, com poucas simulações, de forma que se reduza o espaço de busca dos atributos. Esse resultado poderia ser utilizado para formação do conjunto de entrada para treinamento das RNA.
- Coeficiente de correlação: conforme discutido no Capítulo 6 de resultados, são necessários critérios mais consistentes para escolha dos melhores metamodelos gerados para serem utilizados na otimização. A utilização apenas do coeficiente de correlação linear entre saídas do simulador e do metamodelo não foi capaz de refletir com precisão os resultados obtidos a partir da validação com o simulador, ou seja, mesmo um metamodelo com coeficiente de correlação bom pode não proporcionar

bons resultados na região do mínimo. Uma opção seria utilizar o procedimento descrito por Lima *et al.* (2009) de avaliar os resultados em regiões específicas.

- Outros tipos de RNA: existem ainda outros tipos de RNA que podem ser utilizadas para gerar os metamodelos, sendo uma delas as redes radiais. Mesmo sobre as redes do tipo direta (*FeedForward*) existem ainda diversas configurações, como por exemplo, ao invés de representar o afastamento do modelo com relação ao histórico, poderia gerar na saída, os valores de produção do poço (curva).
- Retreinamento: outra metodologia para retreinamento poderia ser utilizada, que consistiria em gerar o metamodelo com poucos pontos, realizar a otimização utilizando o metamodelo, validar o resultado, e ir adicionando mais pontos aos poucos iterativamente, repetindo o processo (geração do metamodelo, otimização e validação). A escolha por adicionar mais pontos pode ser, ou em todo o espaço de busca dos parâmetros ou em regiões específicas, a variar de acordo com o resultado obtido na validação. Através dessa metodologia pode-se chegar a uma quantidade reduzida de amostras que proporcionem o desempenho desejado do metamodelo sobre o problema em estudo.
- Escolha dos melhores metamodelos após o treinamento: nesse trabalho foi escolhido um entre diversos metamodelos que resultaram em coeficiente de correlação linear bom. Outra possibilidade, contudo, seria utilizar diversos metamodelos com coeficientes de correlação linear bom e validá-los com o simulador, após a otimização.

REFERÊNCIAS BIBLIOGRÁFICAS

AI-THUWAINI, J. S., SAUDI ARAMCO, ZANGL, G. e PHELPS, R., **Innovative Approach to Assist History Matching Using Artificial Intelligence**. SPE Intelligent Energy Conference and Exhibition, paper number SPE99882, Amsterdam, Netherlands, 11 – 13 April, 2006.

AVANSI, G. D., **Uso de Metamodelos na Seleção de Estratégias de Produção e Avaliação Econômica de Campos de Petróleo**. Campinas, 2008. 156pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

AZIZ, K. e SETTARI, A., **Petroleum Reservoir Simulation**. Applied Science Publishers LTD, London, 1979.

BISHOP, C. M., **Neural Networks for Pattern Recognition**. Oxford University Press Inc., New York, 1995.

BOX, G. E. P. e BEHNKEN, D. W., **Some New Three Level Design for the Study of Quantitative Variables**. Technometrics, Vol. 2, No. 4, p.455-475, 1960.

BRATLEY, P. e FOX, B. L., **Algorithm 659 Implementing Sobol's Quasirandom Sequence Generator**. ACM Transactions on Mathematical Software, Vol. 14, No. 1, p. 88-100, 1988.

CARVALHO, C. P. V., MASCHIO, C. E SCHIOZER, D., **Aplicação da Técnica de Hipercubo Latino na Integração do Ajuste de Histórico com a Análise de Incertezas**. 5º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás, Fortaleza, Ceará, Brasil, 15 a 22 de Outubro, 2009.

CONSENTINO, L., **Integrated Reservoir Studies**. Editions Technip, Paris, 2001.

CULLICK, A. S., JOHNSON, D. e SHI, G., **Improved and More-Rapid History Matching with a Nonlinear Proxy and Global Optimization**. SPE Annual Technical Conference and Exhibition, paper number SPE101933, San Antonio, Texas, U. S. A., 24-27 September, 2006.

DEMUTH, F., BEALE, M. e HAGAN, M., **Neural Network Toolbox™ 6 – User's Guide**. The MathWorks Inc., 2010.

DORAISAMY, H., ERTEKIN, T. e GRADER, A. S., **Field Development Studies by Neuro-Simulation: an Effective Coupling of Soft and Hard Computing Protocols**. Science Direct, Computer & Geosciences 26, p.963-973, 2000.

ELPHICK, R. Y., **Facies**. Reservoir Characterization Module, Schlumberger Oilfield Glossary, <http://www.glossary.oilfield.slb.com/search.cfm>, acesso em 01/06/2012, às 22h21min.

ERTEKIN, T., ABOU-KASSEM, J. H. e KING, G. R., **Basic Applied Reservoir Simulation**. Society of Petroleum Engineering Inc., Texas, USA, 2001.

FERREIRA, S. L. C., BRUNS, R. E., FERREIRA, H. S., MATOS, G. D., DAVID, J. M., BRANDÃO, G. C., da SILVA, E. G. D., PORTUGAL, L. A., dos REIS, P. S., SOUZA, A. S. e dos SANTOS W. N. L., **Box-Behnken: An Alternative for the Optimization of Analytical Methods**. Science Direct, Analytica Chimica Acta 597, p179-186, 2007.

FORESEE, F. D. e HAGAN, M. T., **Gauss-Newton Approximation to Bayesian Learning**. Proceedings of the International Joint Conference on Neural Networks, 1997.

FROTA, A. E. F., **Aplicação de Opções Americanas Tradicionais e Complexas**. Rio de Janeiro, 2003. Dissertação (mestrado em Engenharia de Produção: Finanças e Análise de Investimentos). Departamento de Engenharia Industrial, Pontifícia Universidade Católica.

HAGAN, M. T., DEMUTH, H. B. e BEALE M., **Neural Network Design**. PWS Publishing Company, a division of Thompson Learning, United States of America, 1996.

HAGAN, M. T. e MENHAJ, M. B., **Training Feedforward Networks with the Marquardt Algorithm**. IEEE Transactions on Neural Networks, Vol.5, No. 6, p.989-993, November 1994.

HIRSCHEN, K. e SCHÄFER, M., **Bayesian Regularization Neural Networks for Optimizing Fluid Flow Processes**. Science Direct , Comput. Methods Appl. Mech. Engrg. 195, p.481-500, 2006.

LEITÃO, H. C. e SCHIOZER, D. J., **Ajuste de Histórico Automatizado Através de Otimização Multivariada e Paralelização Direta**. Rio Oil & Gas Conference, paper número IBP25498, Rio de Janeiro, Rio de Janeiro, Brasil, 05 a 08 de Outubro, 1998.

LIMA, A., RISSO, F. V. A. e SCHIOZER, D. J., **Uso de Meta-Modelos Gerados por Planejamento Estatístico no Ajuste de Histórico de Produção de Campos de Petróleo**. 5º Congresso Brasileiro de P&D em Petróleo e Gás, Fortaleza, Ceará, Brasil, 15 a 22 de Outubro, 2009.

MASCHIO, C., dos SANTOS, A. A. e SCHIOZER, D. J., **Aplicação do Método Simplex no Processo de Ajuste de Histórico Assistido**. Rio Oil & Gas Expo and Conference, paper número IBP1343_06, Rio de Janeiro, Rio de Janeiro, Brasil, 11 a 14 de Setembro, 2006.

MASCHIO, C., NAKAJIMA, L. e SCHIOZER, D. J., **Uso de Redes Neurais Artificiais no Processo de Ajuste de Histórico de Produção**. Rio Oil & Gas 2008 Expo and Conference, paper número IBP2444_08, Rio de Janeiro, Rio de Janeiro, Brasil, 15 a 18 de Setembro, 2008.

MASCHIO, C. e SCHIOZER, D. J., **Ajuste de Histórico Assistido Usando Métodos de Otimização de Busca Direta**. Rio Oil & Gas Expo and Conference, paper número IBP06204, Rio de Janeiro, Rio de Janeiro, Brasil, 04 a 07 de Outubro, 2004.

MASCHIO, C. e SCHIOZER, D. J., **Comparação entre Metodologia de Otimização Global e Método de Gradientes para Ajuste de Histórico Assistido**. 3º Congresso Brasileiro de P&D em Petróleo e Gás, Salvador, Bahia, Brasil, 02 a 05 de Outubro, 2005.

MASON, R. L., GUNST, R. F. e HESS, J. L., **Statistical Design and Analysis of Experiments With Application to Engineering and Science. Second edition, John Wiley & Sons Inc., Hoboken, New Jersey, 2003.**

MCKAY, M. D., BECKMAN, R. J. e CONOVER, W. J., **A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code.** Technometrics, Vol. 21, No. 2, 1979.

MOHAGHEGH, S., **Virtual-Intelligence Applications in Petroleum Engineering: Part I – Artificial Neural Networks.** Society of Petroleum Engineers, SPE58046, September, 2000.

MONTGOMERY, D. C., **Design and Analysis of Experiments.** 4th Ed. John Wiley & Sons Inc., U.S.A., 1996.

NGUYEN, D. e WIDROW, B., **Improving the Learning Speed of 2-Layer Neural Networks by Choosing Initial Values of the Adaptive Weights.** Proceedings of the IJCNN, Vol. 3, p. 21-26, Julho, 1990.

PINHEIRO, J. M., **Redes Neurais Artificiais.** <http://www.din.uem.br/~jmpinhei/IA-CC/08Redes%20Neurais%20Artificiais.pdf>, acesso em 27 de Abril de 2011 às 15h20.

RAMGULAM, A., ERTEKIN, T. e FLEMINGS, P., **Utilization of Artificial Neural Networks in the Optimization of History Matching.** SPE Latin American and Caribbean Petroleum Engineering Conference, paper number SPE107568, Buenos Aires, Argentina, 15-18 April, 2007.

RISSO, F. V. A., RISSO, V. F. e SCHIOZER, D. J., **Estudo de Influência de Tratamento de Atributos em Análise de risco usando Planejamento Estatístico e Superfície de Resposta.** XXVII CILAMCE, Belém, Pará, Brasil, 03-06 Setembro, 2006.

RISSO, F. V. A., RISSO, V. F. e SCHIOZER, D. J., **A Influência do Tipo de Distribuição dos Atributos Críticos na Obtenção da Curva de Risco Utilizando Planejamento Estatístico** . XXVII CILAMCE, Porto, Portugal, 13-15 junho, 2007.

SAMPAIO, T. P., FERREIRA FILHO, V. J. M. e de SA NETO, A., **An Application of Feed Forward Neural Network as Nonlinear Proxies for the Use During the History Matching Phase**. SPE Latin American and Caribbean Petroleum Engineering Conference, paper number SPE122148, Cartagena, Colombia, 31 May-3 June April, 2009.

SANTOS, J. P. M. e SCHIOZER, D. J., **Determinação de Metodologia de Ajuste Automatizado de Histórico**. Rio Oil & Gas Conference, paper número IBP19300, Rio de Janeiro, Rio de Janeiro, Brasil, 16 a 19 de Outubro, 2000.

SCHIOZER, D. J., SOUSA, S. H. G. e MASCHIO, C., **Ajuste de Histórico de Produção Assistido**. Boletim Técnico da Produção de Petróleo, volume 3, nº 1, p. 63-82, Rio de Janeiro, Rio de Janeiro, Brasil, 2009.

SCHULZE-RIEGERT, R. E GHEDAN, S., **Modern Techniques for History Matching**. 9th International Forum on Reservoir Simulation, Abud Dhabi, United Arab Emirates, 9-13 December, 2007.

SILVA, P. C., MASCHIO, C. e SCHIOZER, D. J., **Use of Neuro-Simulation Techniques as Proxies to Reservoir Simulation: Application in Production History Matching**. Science Direct, Journal of Petroleum Science and Engineering 57, p.273-280, 2006.

SILVA, E. e OLIVEIRA, A. C., **Dicas para a Configuração de Redes Neurais**. Universidade Federal do Rio de Janeiro - NCE, 2004.

THE MATHWORKS, MATLAB7 - **Data Analysis**. The MathWorks Inc., 2007.

VON ZUBEN, F. J., **Algoritmos Genéticos (AG's)**.
ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia707_01/topico6_01.pdf,
DCA/FFEC/UNICAMP, acesso em 28 de Maio de 2011, às 13h44.

ZANGL, G., GRAF, T. e Al-Kinani, A., **Proxy Modeling in Production Optimization**. SPE Europec/EAGE Annual Conference and Exhibition, paper number SPE100131, Vienna, Austria, 12-15 June, 2006.

ZUBAREV, D. I., **Pros and Cons of Applying Proxy-Models as a Substitute for Full Reservoir Simulations**. SPE Annual Technical Conference and Exhibition, paper number SPE124815, New Orleans, Louisiana, USA, 4-7 October, 2009.

APÊNDICE

I. Capacidade de extrapolação da rede neural artificial – Caso 2A

Para avaliar a capacidade de extrapolação foi utilizado o metamodelo Caso2A_HL50_novo (resultante do retreinamento do metamodelo gerado com HL50 pontos) e, como entrada, o conjunto de 25 pontos utilizados no novo treinamento e o conjunto de teste utilizado para treinamento das RNA para todo o espaço de busca dos atributos. O resultado é indicado na Figura I.1, que mostra o gráfico de dispersão entre valores de afastamentos obtidos com a saída do simulador e valores de afastamentos gerados pelo metamodelo, sendo os pontos em azul relativos aos dados que respeitam a faixa de variação dos atributos (conjunto utilizado no retreinamento) e os pontos em vermelho relativos aos dados que ultrapassam os limites de variação dos atributos (utilizados para treinar a RNA em todo o espaço de busca dos atributos). Na Figura I.1 (a) é mostrado o gráfico para todos os pontos e na Figura I.1 (b) é mostrado o gráfico numa área mais próxima do mínimo.

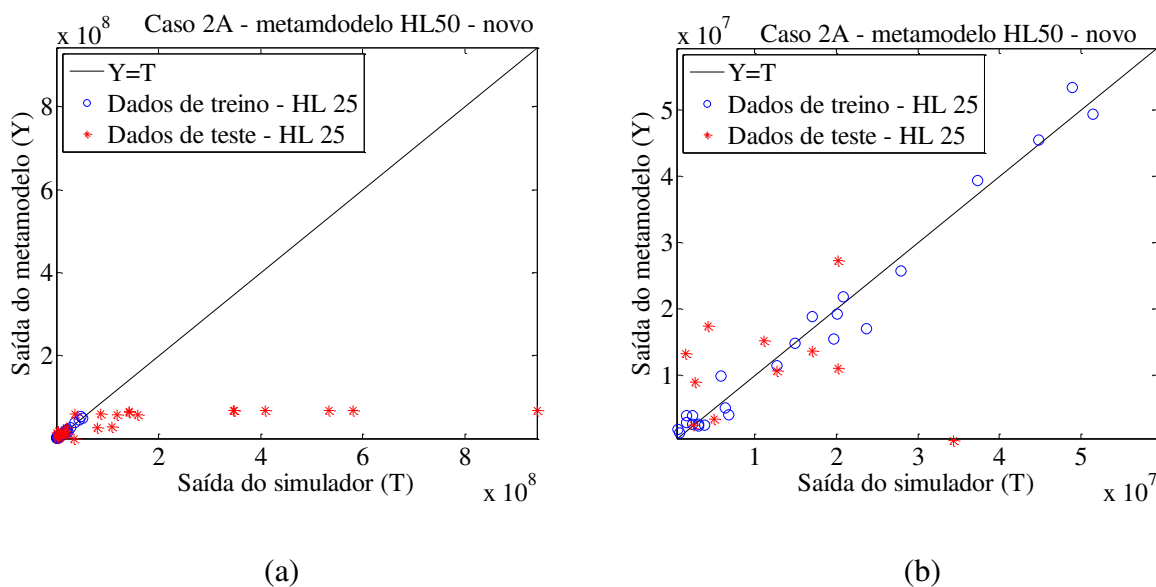


Figura I.1– Exemplo sobre capacidade de extrapolação da RNA. Em (a) são mostrados todos os pontos; em (b) é mostrada uma área menor, mais próxima do mínimo.

Como pode ser observado, quando inseridos atributos de entrada fora dos limites de variação do treinamento o metamodelo não extrapola os resultados, saturando em um valor

próximo ao máximo e mínimo contidos no conjunto de treinamento. Dessa maneira, pode-se deduzir que esse tipo de RNA não possui a capacidade de extrapolar os resultados em regiões para as quais ela não foi treinada.

Ao definir um novo conjunto de treinamento, reduziu-se a região de busca dos atributos e, conseqüentemente, o intervalo de variação da saída do metamodelo. Com isso, o metamodelo gerado com o novo treinamento se limita a representar apenas a nova região específica para o qual foi gerado, não sendo capaz de extrapolar os resultados para variáveis de entrada e saída fora dos limites de variação.

Dessa maneira caso se deseje utilizar o metamodelo para realizar uma tarefa diferente da qual ele foi gerado é necessário realizar novamente o treinamento para o propósito específico.

II. Melhor configuração de rede neural artificial obtida – Caso 2B

Após gerar os metamodelos e realizar a otimização com cada um deles, o modelo de simulação resultante de cada otimização foi simulado utilizando o simulador de escoamento, de forma a obter uma validação final da qualidade do metamodelo gerado. Através dessa validação pôde-se identificar qual foi o melhor metamodelo obtido através dos diversos treinamentos de RNA realizados.

A Tabela II.1 mostra a média dos afastamentos dos oito poços produtores, obtidos através da simulação do modelo resultante da otimização utilizando os metamodelos com BB396, HL396, HL250 e HL100 pontos com as configurações PROD (um único metamodelo representando todos os poços, ou seja, com oito saídas), PP (um metamodelo para representar um poço, ou seja, oito metamodelos), SAS (utilização de todos os dezesseis atributos incertos como entrada) e AS (utilização apenas dos atributos que impactam mais na produção de água, definidos de acordo com a análise de sensibilidade). A linha “Metamodelo” mostra o afastamento obtido com a simulação utilizando o metamodelo, e a linha “Simulador” mostra o afastamento obtido com a simulação utilizando o simulador de escoamento.

Tabela II.1–Média dos afastamentos para os modelos de simulação encontrados através da otimização utilizando o metamodelo – Caso 2B.

Média dos afastamentos dos oito poços ($\times 10^6$)					
Nome		Tipo de metamodelo			
		PP_AS	PP_SAS	PROD_AS	PROD_SAS
BB396	Metamodelo	1.140	0.735	2.094	1.744
	Simulador	3.306	2.480	1.395	1.345
HL396	Metamodelo	1.006	1.097	2.059	1.811
	Simulador	2.580	1.991	2.172	3.248
HL250	Metamodelo	1.406	1.112	2.448	2.092
	Simulador	1.314	3.063	0.851	2.742
HL100	Metamodelo	1.865	0.966	2.397	1.888
	Simulador	1.647	2.616	1.632	1.278

De acordo com a Tabela II.1, o metamodelo que proporcionou a menor média dos afastamentos após simular o modelo no simulador de escoamento foi o metamodelo HL250 com configuração PROD_AS (destacada em negrito). Isso significa que ele foi o que conseguiu conduzir a otimização para mais perto do mínimo.

O procedimento de análise de sensibilidade possibilitou eliminar atributos com pouca influência sobre a Função Objetivo (FO), de forma a reduzir o número de atributos de entrada que contribuem apenas para aumentar o nível de dificuldade do processo de treinamento. Além disso, a utilização de um metamodelo para representar as oito saídas fez com que possíveis inter-relações existentes entre os poços fossem captadas, pois com essa configuração qualquer alteração realizada nos parâmetros da rede interfere em todas as saídas. Em contrapartida, com a utilização de um metamodelo para representar cada poço não é possível captar eventuais inter-relações.