

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

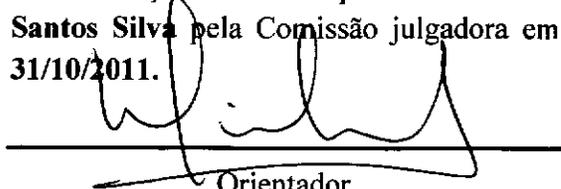
LUCIANA DOS SANTOS SILVA

# **Integração de Análise de Incertezas e Ajuste de Histórico: Aplicação em um Caso Complexo**

CAMPINAS

2011

Este exemplar corresponde à redação final da dissertação defendida por **Luciana dos Santos Silva** pela Comissão julgadora em **31/10/2011**.

  
Orientador

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

# **Integração de Análise de Incertezas e Ajuste de Histórico: Aplicação em um Caso Complexo**

Autor: **Luciana dos Santos Silva**

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, 2011  
SP – Brasil.

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

Silva, Luciana dos Santos  
Si38i Integração de análise de incertezas e ajuste de  
histórico: aplicação em um caso complexo / Luciana dos  
Santos Silva. --Campinas, SP: [s.n.], 2011.

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

1. Reservatórios (Simulação). 2. Análise de  
incerteza. 3. Mitigação de risco. 4. Engenharia de  
reservatório de óleo. I. Schiozer, Denis José. II.  
Universidade Estadual de Campinas. Faculdade de  
Engenharia Mecânica. III. Título.

Título em Inglês: Integration of uncertainty analysis with history matching: application  
in a complex case

Palavras-chave em Inglês: Reservoirs (Simulation), Analysis of uncertainty, Mitigation  
of risk, Oil reservoir engineering

Área de concentração: Reservatórios e Gestão

Titulação: Mestre em Ciências e Engenharia de Petróleo

Banca examinadora: Rosângela Barros Zanoni Lopes Moreno, Leandro Costa Reis

Data da defesa: 31-10-2011

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

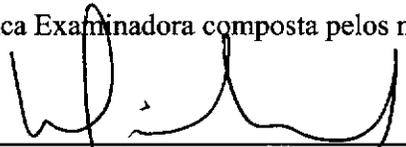
DISSERTAÇÃO DE MESTRADO ACADÊMICO

## **Integração de Análise de Incertezas e Ajuste de Histórico: Aplicação em um Caso Complexo**

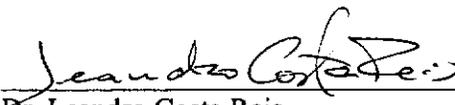
Autor: **Luciana dos Santos Silva**

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. Rosângela Zanoni Lopes Moreno  
DEP/FEM/UNICAMP

  
\_\_\_\_\_  
Dr. Leandro Costa Reis  
Petrobras SA

Campinas, 31 de outubro de 2011.

## **DEDICATÓRIA**

Dedico esse trabalho a meus pais Cristina e Silvio, meus irmãos Juliana, Livia e Guilherme, meus avós Shirley e Ivo e meu padrinho Ivan.

Aos meus pais e ao meu padrinho pelo exemplo de perseverança, pela contribuição na minha formação pessoal e profissional e pelo apoio ao longo de todos esses anos.

Aos meus irmãos e avós pelo carinho, compreensão e companheirismo em todos os momentos.

## **AGRADECIMENTOS**

Em primeiro lugar, agradeço a Deus pela família que tenho e por ter me dado saúde e força para vencer os obstáculos da vida.

A toda minha família, em especial à minha irmã Juliana e minha mãe Cristina, pelo carinho, incentivo e apoio tanto nas horas fáceis como nas difíceis.

Ao Professor Denis José Schiozer pela atenção, compreensão, estímulo e orientação para a elaboração deste trabalho.

À Petrobras e aos gerentes do Campo de Roncador, especialmente Mauro Mihaguti e Eduardo Bordieri pela oportunidade e apoio para a realização deste mestrado. Aos amigos do ATP-RO/RES e da Petrobras pelo aprendizado proporcionado.

Aos pesquisadores e funcionários do UNISIM pelo suporte, em especial ao pesquisador Célio Maschio pela colaboração neste trabalho e ao Guilherme Tonin pela grande ajuda ao longo do curso.

Aos professores do DEP pelo conhecimento adquirido nestes anos.

Aos funcionários do DEP, em especial, à Giselle, Alice, Sônia, Michelle e Dêlcio pela ajuda direta ou indireta na realização deste trabalho.

Aos amigos Rodrigo Amaral, Marcos Sebastião, Brunno Guimarães, Lisbet Greenup, Nara Policarpo, João Hermes e Alexandre Milagres que me auxiliaram sempre que precisei e me proporcionaram grandes momentos durante o mestrado. Aos amigos que mesmo de longe me deram grande apoio e torceram por mim: Lara, Paulinha, Carol, Patrícia, Bernardo, Camila, Flávia, Michele e tantos outros.

Aos demais colegas do curso de Ciências e Engenharia de Petróleo do DEP pelo convívio, companheirismo e troca de informações.

*“A mente que se abre a uma nova idéia jamais voltará ao seu tamanho original”*

Albert Einstein

## RESUMO

SILVA, Luciana dos Santos. *Integração de Análise de Incertezas com Ajuste de Histórico: Aplicação em um Caso Complexo*. Campinas, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2011. 136 p. Dissertação de Mestrado.

A grande quantidade de incertezas presente na modelagem de reservatórios gera riscos na previsão de comportamento de um campo de petróleo. Assim, torna-se imprescindível o ajuste de histórico, que é a calibração do modelo de simulação do reservatório com os dados dinâmicos observados, aproximando o modelo da realidade e gerando previsões mais confiáveis. Diversas metodologias surgiram para integrar a análise de incertezas com o ajuste de histórico, mas devido à complexidade do processo, algumas delas só se aplicam a casos simples. A proposta deste trabalho é aplicar os métodos desenvolvidos por Moura Filho (2006), Becerra (2007) e Maschio et al. (2010) em um caso complexo sintético, similar a um modelo real de um reservatório de petróleo e avaliá-los para propor melhorias na metodologia. A técnica consiste em utilizar as diferenças entre os dados de produção observados e os simulados para reduzir as incertezas do reservatório, calculando as probabilidades dos níveis dos parâmetros incertos. Para isso, os atributos incertos são discretizados em três níveis e é feita uma análise de sensibilidade para escolher os atributos críticos, os quais são combinados através da árvore de derivação para gerar os diferentes modelos de simulação. Com os dados históricos (medidos) e simulados destes modelos, é feita a redistribuição das probabilidades dos níveis utilizando e comparando dois métodos: o de Moura Filho e Becerra (Método 1) e o de Maschio et al. (Método 2). Os resultados deles não mostraram boa eficiência na redução das incertezas para o caso estudado, pois as curvas continuaram muito espalhadas com relação ao histórico. Sendo assim, foram criados o Método 3, utilizando as melhores práticas da formulação dos dois estudados com o objetivo de tornar a metodologia mais robusta para uso em casos reais, e o Método 4, que é uma reaplicação



do Método 3 após a redefinição dos valores dos níveis dos atributos. Uma comparação dos resultados dos quatro métodos mostra a evolução da redução das incertezas. Além disso, consegue-se diminuir a dispersão dos modelos representativos, centralizando-os com relação ao histórico de produção, o que permite uma melhor previsão de produção e maior confiabilidade na análise de risco de projetos futuros.

*Palavras-Chave*

Ajuste de Histórico, Simulação de Reservatórios, Mitigação de Incertezas, Árvore de Derivação.

## ABSTRACT

SILVA, Luciana dos Santos. *Integration of Uncertainty Analysis with History Matching: Application in a Complex Case*. Campinas, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2011. 136 p. Dissertação de Mestrado.

The large amount of uncertainties in reservoir modeling increases petroleum production forecast risks. Therefore, the history matching, which refines the simulation model to closely reproduce production data, is a vital procedure once it approximates numerical models to reality providing reliable predictions. Many methodologies were developed to integrate uncertainty analysis and history matching in order to mitigate the reservoir uncertainties by using the observed data, but due to the process complexity, some of them are applicable only in simple cases. In this context, the present work aims to evaluate the application of existing methods, developed by Moura Filho (2006), Becerra (2007) and Maschio et al. (2010), in a synthetic complex model (i.e. similar to a real field) and propose new methods with some improvements to be applied in real cases of the petroleum industry. The main characteristic of these methods is the use of differences between observed and simulated data to recalculate the probabilities distribution of uncertain parameters with the purpose of reducing reservoir uncertainties. To apply the methods, the uncertainty attributes are discretized in three levels and a sensibility analysis is done to select the critical attributes, which are combined by a derivative tree generating different simulation models. With history and simulated data of these models, the redistribution of occurrence probabilities is made with different formulas: Moura Filho e Becerra (Method 1) and Maschio et al. (Method 2). These two methods are compared and their results don't show good efficiency in uncertainty reduction of the studied case, because the final curves remain widely scattered around history data. Then, two methods are proposed, Method 3, which combines the best practices of the two reviewed ones, making it robust to be used in real cases with a great number of wells and production functions to be adjusted such as water production and pressure. The second proposed one, Method 4, is a reapplication of the third method with a

redefinition of attribute values in order to refine the results. A comparison of the results of the four methods shows an evolution in the uncertainty reduction. Besides that, there is a decrease in the dispersion of the representative curves, which are centralized around the history data, providing a better production forecast and greater reliability in risk analysis of future projects.

*Key Words*

History Matching, Reservoir Simulation, Uncertainty Mitigation, Derivative Tree Technique.

# SUMÁRIO

DEDICATÓRIA .....	v
AGRADECIMENTOS.....	vii
RESUMO .....	xi
ABSTRACT.....	xiii
LISTA DE FIGURAS .....	xix
LISTA DE TABELAS .....	xxvii
LISTAS DE NOMENCLATURAS .....	xxix
1. INTRODUÇÃO.....	1
1.1 Motivação.....	3
1.2 Objetivos.....	4
1.3 Organização da Dissertação.....	4
2. CONCEITOS E FUNDAMENTAÇÃO TEÓRICA .....	7
2.1 Ajuste de Histórico .....	7
2.2 Análise de Incertezas .....	11
2.2.1 Análise de Sensibilidade .....	13
2.2.2 Árvore de Derivação .....	15
2.2.3 Curva de Incerteza.....	16
2.3 Redução de Incertezas a partir dos Dados de Histórico de Produção .....	18
3. REVISÃO BIBLIOGRÁFICA.....	21
3.1 Integração da Análise de Incertezas com o Ajuste de Histórico .....	21

3.2	Linha de Pesquisa de Referência .....	28
4.	METODOLOGIA.....	33
4.1	Metodologia geral.....	33
4.2	Método 3.....	36
4.3	Método 4.....	40
5.	APLICAÇÃO .....	43
5.1	Modelo do Reservatório .....	43
5.2	Incertezas do Modelo.....	50
5.3	Modelo de Histórico e Casos tratados .....	54
5.4	Modelo Inicial (Base).....	55
6.	RESULTADOS E DISCUSSÃO .....	63
6.1	Análise de Sensibilidade.....	63
6.2	Caso A .....	66
6.2.1	Método 1 .....	66
6.2.2	Método 2 .....	74
6.2.3	Método 3 .....	81
6.2.3.1	Método 3.1 .....	84
6.2.3.2	Método 3.2 .....	87
6.2.4	Método 4 .....	96
6.2.5	Comparação dos Métodos.....	107
6.3	Caso B .....	110
6.3.1	Método 3 .....	110
6.3.1.1	Método 3.2 .....	110
6.3.2	Método 4 .....	116

6.3.3	Comparação dos Métodos.....	128
6.4	Discussão Geral.....	129
7.	CONCLUSÕES E SUGESTÕES FUTURAS.....	131
7.1	Conclusões gerais.....	131
7.1.1	Caso A.....	132
7.1.2	Caso B.....	134
7.2	Recomendações.....	135
	REFERÊNCIAS BIBLIOGRÁFICAS.....	137

## LISTA DE FIGURAS

Figura 1.1 – Produção acumulada de óleo de cenários antes e depois da redução de incertezas. ....	3
Figura 2.1 – Exemplo hipotético de multiplicidade de soluções do ajuste de histórico.....	10
Figura 2.2 – Exemplos de distribuições probabilísticas. ....	12
Figura 2.3 – Discretização da função densidade de probabilidade em 3 níveis de incerteza (adaptada de Moura Filho, 2006). ....	13
Figura 2.4 – Gráfico <i>tornado</i> para análise de sensibilidade. ....	14
Figura 2.5 – Exemplo esquemático de uma árvore de derivação. ....	15
Figura 2.6 – Exemplo de curva de incerteza antes e após um processo de mitigação de incertezas. ....	17
Figura 2.7 – Seleção dos modelos representativos iniciais e finais para traçar o gráfico tipo “bastão” (adaptado de Vasconcelos, 2011). ....	18
Figura 2.8 – Aspectos gerais da redução de incertezas a partir dos dados de histórico de produção (adaptada de Moura Filho, 2006). ....	20
Figura 3.1 – Exemplo de redistribuição de probabilidades (adaptada de Moura Filho, 2006). ....	31
Figura 4.1 – Fluxograma com as etapas do trabalho. ....	33
Figura 4.2 – Exemplo teórico 1 para mostrar a importância da simetria.....	37
Figura 4.3 – Exemplo teórico 2 para mostrar as diferenças na aplicação dos 3 Métodos quanto a ordem de grandeza das funções. ....	38
Figura 4.4 – Exemplo teórico 3 para mostrar as diferenças na aplicação dos 3 Métodos com funções de crescimento diferentes. ....	39
Figura 4.5 – Fluxograma para refinamento dos resultados – Método 4. ....	41

Figura 4.6 – Exemplo de redefinição dos valores dos níveis dos atributos (adaptado de Moura Filho, 2006). .....	42
Figura 5.1 – Topo do reservatório do Modelo Base. ....	43
Figura 5.2 – Divisão do modelo em três blocos nas zonas superior e inferior. ....	44
Figura 5.3 – Mapa 3 D da porosidade do modelo de simulação .....	45
Figura 5.4 – Histograma com a distribuição dos valores de porosidade do modelo base. ....	45
Figura 5.5 – Mapa de permeabilidade horizontal das camadas 1 (zona superior) e 10 (zona inferior). ....	46
Figura 5.6 – Seção transversal J mostrando a razão <i>NTG</i> . ....	47
Figura 5.7 – Seção transversal I ilustrando a permeabilidade horizontal. ....	47
Figura 5.8 – Mapa da espessura porosa das zonas superior e inferior. ....	48
Figura 5.9 – Mapa 3D com a pressão original do reservatório. ....	49
Figura 5.10 – Diagrama ternário mostrando as fases óleo e água. ....	49
Figura 5.11 – Três modelos de falhas internas utilizados. ....	52
Figura 5.12 – Curvas de Permeabilidade relativa à água de cada nível. ....	53
Figura 5.13 – Vazões de Óleo e Água do campo para o caso base e histórico. ....	56
Figura 5.14 – Pressão Média do campo para o caso base e histórico. ....	56
Figura 5.15 – Vazões de Óleo e Água do poço PROA-6 para o caso base e histórico. ....	57
Figura 5.16 – Vazões de Óleo e Água do poço PROC-4 para o caso base e histórico. ....	58
Figura 5.17 – Vazões de Óleo e Água do poço PROB-1 para o caso base e histórico. ....	58
Figura 5.18 – Diferenças entre PRF do modelo base e do histórico para o poço PROA-6. ....	59
Figura 5.19 – Diferenças entre PRF do modelo base e do histórico para o poço PROC-4. ....	60
Figura 5.20 – Diferenças entre PRF do modelo base e do histórico para o poço PROB-1. ....	60
Figura 5.21 – RGO do caso base comparada com o histórico do poço PROA-1. ....	61
Figura 5.22 – RGO do caso base comparada com o histórico do poço PROB-5. ....	61



Figura 6.1 – Análise de sensibilidade para o Campo. ....	64
Figura 6.2 – Análise de sensibilidade para o Bloco A.....	65
Figura 6.3 – Análise de sensibilidade para o Bloco B.....	65
Figura 6.4 – Análise de sensibilidade para o Bloco C.....	66
Figura 6.5 – Redistribuição de probabilidades pelo Método 1 – Caso A.....	67
Figura 6.6 - Curvas de produção de água (esquerda) e pressão do campo para os diferentes níveis do atributo FAB (0- vermelho, 1- verde, 2- azul).....	68
Figura 6.7 - Gráfico da soma dos afastamentos quadráticos ( $K_n$ ) para cada nível dos atributos.....	69
Figura 6.8 - Afastamento quadrático dos modelos dos cinco atributos por nível. ....	70
Figura 6.9 - Independência da FO do Bloco C com relação ao atributo PhiA e redistribuição da probabilidade de PhiA pelo Método 1 com esta FO.....	71
Figura 6.10 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 1 – Caso A. ....	71
Figura 6.11 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 1 – Caso A.....	72
Figura 6.12 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 1 – Caso A.....	73
Figura 6.13 – Curvas de $Q_w$ do PROA-4 e $PRF$ do PROC-4 para os modelos entre P10 e P90, resultantes do Método 1 – Caso A.....	73
Figura 6.14 - Redistribuição de probabilidades pelo Método 2 – Caso A.....	74
Figura 6.15 - Gráfico da soma dos afastamentos quadráticos invertidos ( $K_{in}$ ) para cada nível dos atributos.....	75
Figura 6.16 – Independência da FO do Bloco C com relação ao atributo PhiA e redistribuição da probabilidade de PhiA pelo Método 2 com esta FO.....	76
Figura 6.17 – Curvas de incerteza da vazão de água e pressão dos poços – Método 2 – Caso A. ....	76

Figura 6.18 – Comparativo da FO de produção de água e de pressão dos poços antes e depois da aplicação do Método 2 (Caso A).....	77
Figura 6.19 - Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 2 – Caso A.....	78
Figura 6.20 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 2 – Caso A.....	79
Figura 6.21 – Curvas de $Q_w$ do PROA-4 e $PRF$ do PROC-4 para os modelos entre P10 e P90, resultantes do Método 2 – Caso A.....	79
Figura 6.22 – Redistribuição de probabilidades de $\Phi_A$ , utilizando a $Q_w$ do PROA-1 – Caso A.....	82
Figura 6.23 – Redistribuição de probabilidades de $\Phi_A$ , utilizando a $PRF$ do PROB-3 – Caso A. ....	83
Figura 6.24 – Redistribuição de probabilidades de $\Phi_A$ , a partir da $Q_w$ do PROC-3 – Caso A...	83
Figura 6.25 – Redistribuição de probabilidades pelo Método 3.1 – Caso A.....	85
Figura 6.26 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 3.1 – Caso A. ....	85
Figura 6.27 – Curvas de produção de água do campo para os modelos entre P10 e P90 resultantes do Método 3.1 – Caso A.....	86
Figura 6.28 – Curvas de pressão do campo para os modelos entre P10 e P90 resultantes do Método 3.1 – Caso A.....	87
Figura 6.29 – Redistribuição de probabilidades pelo Método 3.2 – Caso A.....	88
Figura 6.30 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 3.2 – Caso A. ....	89
Figura 6.31 – Comparativo da FO de $Q_w$ inicial e após aplicação do Método 3 – Caso A. ....	90
Figura 6.32 – Comparativo da FO de $PRF$ dos poços antes e depois da aplicação do Método 3 – Caso A. ....	91

Figura 6.33 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.....	92
Figura 6.34 – Curvas de produção de água dos poços PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.....	92
Figura 6.35 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.....	93
Figura 6.36 – Curvas de pressão de fundo dos poços PROB-2 e PROC-4 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.....	93
Figura 6.37 – Valores iniciais do atributo PhiA.....	96
Figura 6.38 – Modelos novos de falhas internas – Caso A.....	97
Figura 6.39 – Novas curvas de permeabilidade relativa à água – Caso A.....	97
Figura 6.40 – Probabilidades após aplicação do Método 4 – Caso A.....	98
Figura 6.41 – Comparação entre as curvas de incerteza para vazão de água inicial e dos Métodos 3 e 4.....	99
Figura 6.42 – Comparação entre as curvas de incerteza para pressão inicial e dos Métodos 3 e 4.....	100
Figura 6.43 – Comparativo da FO de vazão de água e de pressão dos poços – Caso A.....	101
Figura 6.44 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 4 – Caso A.....	102
Figura 6.45 – Curvas de pressão do campo dos modelos entre P10 e P90, resultantes do Método 4 – Caso A.....	102
Figura 6.46 – Curvas de produção de água dos poço PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 4 – Caso A.....	103
Figura 6.47 – Curvas de pressão de fundo dos poços PROB-2 e PROC-4 para os modelos entre P10 e P90, resultantes do Método 4 – Caso A.....	103
Figura 6.48 – Modelos representativos da vazão de água do campo antes e depois da aplicação do Método 4 – Caso A.....	104

Figura 6.49 – Modelos representativos da pressão do campo antes e depois da aplicação do Método 4 – Caso A.....	105
Figura 6.50 – Modelos representativos iniciais e finais da vazão de água dos poços PROA-4, PROA-7, PROB-8 e PROC-3 – Caso A.....	106
Figura 6.51 – Modelos representativos iniciais e finais da pressão de fundo dos poços PROA-1, PROB-2, PROB-7 e PROC-4 – Caso A. ....	107
Figura 6.52 – Comparação das curvas de incerteza da vazão de água dos métodos – Caso A. ...	108
Figura 6.53 – Comparação das curvas de incerteza da pressão de todos os Métodos – Caso A.	109
Figura 6.54 – Redistribuição de probabilidades pelo Método 3.2 – Caso B.....	111
Figura 6.55 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 3.2 – Caso B. ....	112
Figura 6.56 – Comparação da FO de vazão de água dos poços entre os Casos A e B – Método 3.2. ....	113
Figura 6.57 – Comparação da FO de pressão dos poços entre os Casos A e B – Método 3.2. ...	113
Figura 6.58 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B.....	114
Figura 6.59 – Curvas de produção de água dos poços PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B.....	115
Figura 6.60 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B.....	116
Figura 6.61 – Curvas de pressão de fundo dos poços PROB-2 e PROC-4 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B.....	116
Figura 6.62 – Modelos novos de falhas internas – Caso B. ....	117
Figura 6.63 – Novas curvas de permeabilidade relativa à água – Caso B.....	118
Figura 6.64 – Probabilidades após aplicação do Método 4 – Caso B. ....	119

Figura 6.65 – Comparação entre as curvas de incerteza para vazão de água inicial e dos Métodos 3 e 4 – Caso B.....	120
Figura 6.66 – Comparação entre as curvas de incerteza para pressão inicial e dos Métodos 3 e 4 – Caso B. ....	121
Figura 6.67 – Comparativo da FO de vazão de água e de pressão dos poços – Caso B. ....	121
Figura 6.68 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 4 – Caso B.....	122
Figura 6.69 – Curvas de produção de água dos poços PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 4 – Caso B.....	123
Figura 6.70 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 4 – Caso.....	124
Figura 6.71 – Curvas de <i>PRF</i> dos poços PROB-2, PROC-4, PROA-1 e PROA-8 para os modelos entre P10 e P90, resultantes do Método 4 – Caso B.....	124
Figura 6.72 – Modelos representativos da vazão de água do campo antes e depois da aplicação do Método 4 – Caso B. ....	125
Figura 6.73 – Modelos representativos da pressão do campo antes e depois da aplicação do Método 4 – Caso B. ....	126
Figura 6.74 – Modelos representativos iniciais e finais da vazão de água dos poços PROA-4, PROA-7, PROB-8 e PROC-3 – Caso B. ....	127
Figura 6.75 – Modelos representativos iniciais e finais da pressão de fundo dos poços PROA-1, PROB-2, PROB-7 e PROC-4 – Caso B. ....	128

## LISTA DE TABELAS

Tabela 4.1 – Resultados dos três métodos para o exemplo teórico 1. ....	37
Tabela 4.2 – Resultados da distribuição de probabilidades para o exemplo teórico 2. ....	39
Tabela 4.3 – Resultados da distribuição de probabilidades para o exemplo teórico 3. ....	40
Tabela 5.1 - Volume de óleo <i>in situ</i> e quantidade de poços por bloco. ....	50
Tabela 5.2 - Atributos incertos do reservatório. ....	51
Tabela 5.3 – Dados de PVT utilizados. ....	53
Tabela 5.4 - Valores dos atributos incertos utilizados para gerar o histórico de produção. ....	54
Tabela 6.1 - Resultados da aplicação do Método 1 – Caso A. ....	67
Tabela 6.2 – Resultados da aplicação do Método 2 – Caso A. ....	74
Tabela 6.3 – Redistribuição de probabilidade para diferentes valores do fator $F$ . ....	80
Tabela 6.4 – Resultados da aplicação do Método 3.1 – Caso A. ....	84
Tabela 6.5 – Resultados da aplicação do Método 3.2 – Caso A. ....	88
Tabela 6.6 – Redistribuição de probabilidades pelo Método 3.2 para diferentes valores de $F$ – Caso A. ....	94
Tabela 6.7 – Redistribuição de probabilidades pelo Método 3.2 para diferentes valores de $1/ S_n _{máximo}$ – Caso A. ....	95
Tabela 6.8 – Novos níveis dos atributos – Caso A. ....	96
Tabela 6.9 – Resultados da aplicação do Método 4 – Caso A. ....	98
Tabela 6.10 – Resultados da aplicação do Método 3.2 – Caso B. ....	111
Tabela 6.11 – Novos níveis dos atributos – Caso B. ....	117
Tabela 6.12 – Resultados da aplicação do Método 4 – Caso B. ....	118

## LISTAS DE NOMENCLATURAS

### Subscritos

AD	Árvore de derivação
i	inversão
n	nível
q	quadrático

### Siglas

AS	Análise de sensibilidade
$At$	Número de atributos
F	Fator de ponderação para inversão do afastamento
E&P	Exploração e produção na indústria do petróleo
FAB	Transmissibilidade da falha A-B
FBC	Transmissibilidade da falha B-C
FO	Função-objetivo de ajuste
$f_{dp}$	Função densidade de probabilidade
$H_t$	Dados observados
IS	Índice de sensibilidade
$K$	Afastamento simples entre os dados observados e simulados
kA	Permeabilidade horizontal do Bloco A
kB	Permeabilidade horizontal do Bloco B
kC	Permeabilidade horizontal do Bloco C

$k_i$	Permeabilidade da zona inferior
$K_{iq}$	Inverso do afastamento quadrático ponderado por $F$
$K_n$	Afastamento quadrático do nível $n$
$K_{in}$	Inverso do afastamento quadrático do nível $n$
$K_q$	Afastamento quadrático entre os dados observados e simulados
krw	Permeabilidade relativa à água
kv	Permeabilidade vertical
MGR	Modelos geológicos representativos
$M_n$	Número de modelos do nível $n$
NS	Número de simulações
NTG	Espessura porosa
$P_n$	Probabilidade do nível $n$ de um atributo
PhiA	Porosidade do bloco A
PhiB	Porosidade do bloco B
PhiC	Porosidade do bloco C
$PRF$	Pressão de fundo de poço
$Q_o$	Vazão de produção de óleo
$Q_w$	Vazão de produção de água
RGO	Razão gás-óleo
$S_t$	Dados simulados
$S_n$	Simetria do nível $n$
VOIS	Volume de óleo <i>in situ</i>
VPL	Valor presente líquido



$W$

Peso atribuído a uma função

# 1. INTRODUÇÃO

Na exploração e produção (E&P) da indústria de petróleo, onde há investimentos de grande porte, a previsão de comportamento do reservatório é de fundamental importância para as tomadas de decisões no desenvolvimento e gerenciamento de campos de petróleo. No entanto, há um elevado número de incertezas no reservatório, fazendo-se necessária uma análise de risco para avaliar o impacto de tais incertezas no desempenho do campo. Assim, procedimentos vêm sendo desenvolvidos com o objetivo de minimizar os riscos envolvidos, maximizando a produção e o lucro das empresas.

Os simuladores de fluxo são indispensáveis para realizar a previsão de produção de um reservatório de petróleo. Para se obter modelos fieis à realidade, utilizam-se técnicas avançadas de modelagem estática do reservatório, incorporando dados sísmicos, coletados em perfis elétricos e amostras de rocha. Porém, mesmo com todos os avanços existentes no processo de caracterização, o número de incertezas associadas ainda é elevado, uma vez que muitos dados geológicos e petrofísicos são obtidos de forma indireta. Os atributos incertos do reservatório podem ser representados por uma distribuição de probabilidade, a qual pode ser discretizada em níveis. A combinação dos níveis dos atributos gera diversos modelos, resultando em curvas de produção distintas. Portanto, considerando as incertezas presentes nos problemas, um campo não deve ser representado por um modelo único, mas por um conjunto de modelos associados a uma distribuição de probabilidade de ocorrência (abordagem estocástica).

Com o início da produção do campo, novos dados são obtidos e estes devem ser utilizados para a calibração dos modelos de simulação, no processo conhecido como ajuste de histórico que consiste na alteração dos atributos incertos do reservatório, tais como porosidade, permeabilidade, transmissibilidade de falhas e outros, para honrar os dados observados de produção. Assim, modelos bem ajustados geram previsões futuras mais confiáveis, ou pelo menos com maior probabilidade de gerar previsões mais próximas da realidade.

O processo de ajuste de histórico tradicional é um problema inverso, em que se conhece a resposta, mas não as entradas; assim, diferentes soluções podem gerar bons ajustes com previsões totalmente distintas, tornando o ajuste de histórico trabalhoso e bastante difícil. Quando há muitas incertezas e poucos dados observados (campos em início de produção), a calibração pode levar a diferentes soluções.

Em geral, na indústria, os modelos são complexos, com muitos poços e, conseqüentemente, com um grande número de dados de produção (vazões e pressões) a serem ajustados. Essa complexidade faz com que o ajuste, projetos de desenvolvimento complementar e análises futuras da produção sejam feitas em um modelo único. Na prática, ocorrem, então, dois processos separados: o primeiro, a análise de risco, no qual as incertezas do modelo são quantificadas, obtendo-se uma previsão probabilística de produção, com diversos modelos gerando previsões diferentes com uma probabilidade de ocorrência associada. E, desta análise, escolhe-se o modelo determinístico de comportamento intermediário entre os possíveis, iniciando-se, posteriormente, a segunda etapa, onde é feito o ajuste de histórico somente no modelo escolhido, que também é usado para a avaliação de projetos futuros.

Neste trabalho, os dois processos citados acima são tratados em conjunto, fazendo-se a redução das incertezas do modelo de forma integrada com o ajuste de histórico. As diferenças entre os dados de histórico e simulados são utilizadas para redistribuir as probabilidades dos níveis dos atributos incertos, assim modelos com resposta mais próxima do histórico passam a ter maior probabilidade de ocorrência. A Figura 1.1 mostra um exemplo de produção acumulada de óleo dos modelos representativos de um reservatório antes (curvas vermelhas) e depois (curvas azuis) dessa redistribuição das probabilidades, indicando a redução das incertezas existentes.

Diversas metodologias vêm sendo desenvolvidas nessa linha de pesquisa, como as propostas apresentadas por Moura Filho (2006), Becerra (2007), Schaaf et al. (2008), Busby et al. (2009) e Maschio et al. (2010). Algumas destas metodologias de integração da análise de incertezas com o ajuste de histórico foram inicialmente aplicadas em casos simples, e aos poucos, vêm sendo melhoradas para aplicações em casos mais complexos. Este trabalho avalia a aplicação de algumas delas em um caso complexo sintético (adaptado de um caso real), Moura Filho e Becerra (Método 1 deste trabalho) e Maschio et al. (Método 2 deste trabalho). Em

seguida, são avaliadas as dificuldades e problemas encontrados, propondo-se novos métodos (Métodos 3 e 4), mais adequados para o uso em casos práticos.

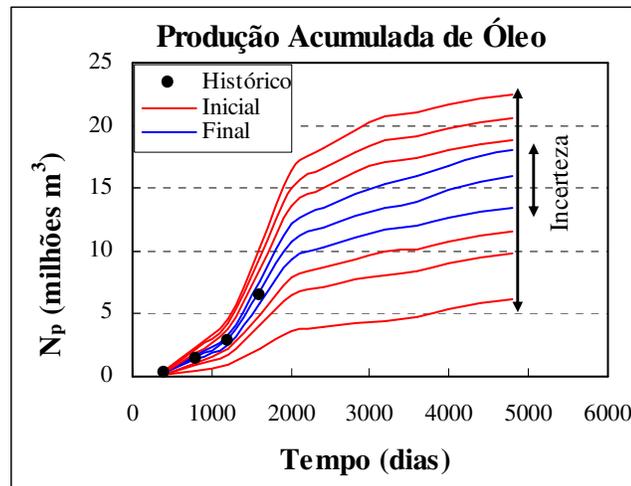


Figura 1.1 – Produção acumulada de óleo de cenários antes e depois da redução de incertezas.

## 1.1 Motivação

O ajuste de histórico de reservatórios de petróleo, em geral, é feito de forma manual utilizando-se apenas um único modelo do campo. Como não há uma metodologia bem definida, pois a complexidades dos modelos, em geral, é grande, o tempo demandado para realizar o ajuste torna-se demasiadamente longo e depende bastante do conhecimento do reservatório pelo engenheiro. Contudo, quanto maior a complexidade dos modelos e a quantidade de dados a ser tratada, mais difícil a obtenção de um bom ajuste dessa forma.

Tal problema tem sido minimizado com o desenvolvimento de novas técnicas e metodologias, como o ajuste assistido utilizando algoritmos de otimização e a integração da análise de incertezas com o ajuste de histórico. A primeira, em geral, leva a uma única boa solução para o ajuste de histórico, não avaliando de forma probabilística as incertezas. Já a segunda, gera como resultado múltiplas soluções para o ajuste que podem ser utilizadas para fazer previsões probabilísticas e avaliar projetos futuros.

A motivação principal deste trabalho é a validação e melhoria de metodologias desenvolvidas para a redução das incertezas a partir dos dados de histórico de produção, procurando aumentar a confiança nos métodos para serem utilizados na indústria.

## **1.2 Objetivos**

Este trabalho tem como objetivo principal aplicar a metodologia de redução de incertezas através do ajuste de histórico desenvolvida por Moura Filho (2006) e aprimorada por Becerra (2007), Método 1, e Maschio et al. (2010), Método 2, num caso complexo, bastante similar a um modelo real, com um grande número de poços a serem ajustados. Nos trabalhos anteriores, foram utilizados casos sintéticos, com foco principal de aplicação no ajuste global do campo, sendo que, nesta dissertação, é analisado o ajuste poço a poço. O método proposto utiliza os dados de histórico de produção de cada poço isoladamente para a redistribuição de probabilidades dos atributos incertos e, em seguida, combina estes resultados para a obtenção de uma redistribuição global, permitindo a escolha dos modelos com melhor ajuste tanto para o campo como para os poços.

A partir das dificuldades e problemas encontrados na aplicação destes métodos num caso com muitas heterogeneidades e com ajustes localizados, são propostas melhorias, gerando um novo método que seja mais adequado ao uso nos campos reais, mesmo aqueles com uma grande quantidade de variáveis a serem ajustadas. Desta forma, busca-se chegar a um conjunto de modelos com bom ajuste de histórico que possa gerar diferentes curvas de previsão de comportamento associadas a probabilidades de ocorrência, aumentando a confiança na avaliação do risco de projetos futuros.

## **1.3 Organização da Dissertação**

Este trabalho está estruturado em sete capítulos. No Capítulo 1, é apresentada uma breve introdução sobre o ajuste de histórico e a análise de incertezas, mostrando a importância da associação desses dois processos no desenvolvimento de um campo de petróleo. Além disso, a motivação e os objetivos da dissertação são descritos.

No Capítulo 2, é abordada a fundamentação teórica e alguns conceitos relativos ao tema proposto que são necessários para o entendimento do texto, como ajuste de histórico, análise de incertezas, árvore de derivação, curva de risco e análise de sensibilidade.

O Capítulo 3 mostra uma revisão bibliográfica da integração da análise de incertezas com o ajuste de histórico, destacando os trabalhos de Moura Filho (2006), Becerra (2007) e Maschio et al. (2010), cujas metodologias serão aplicadas nesse trabalho.

O Capítulo 4 é destinado a apresentação do fluxograma geral da dissertação e dos métodos propostos neste trabalho, ressaltando as principais diferenças com os existentes na literatura.

No Capítulo 5, é feita uma descrição do modelo de reservatório usado na aplicação da metodologia, destacando seus atributos incertos e as características dos modelos base e de histórico.

No Capítulo 6 são apresentados os resultados e discussões da aplicação dos métodos existentes e propostos no caso selecionado.

Por fim, o Capítulo 7 destaca as conclusões relativas à aplicação dos diversos métodos e as recomendações sugeridas para os trabalhos futuros.



## **2. CONCEITOS E FUNDAMENTAÇÃO TEÓRICA**

Neste capítulo, são apresentados e discutidos diversos conceitos importantes para o entendimento do trabalho desenvolvido: ajuste de histórico, análise de incertezas, sensibilidade, árvore de derivação e curva de incerteza. Além disso, é introduzido o conceito da redução de incertezas a partir dos dados de histórico de produção, que é o tema principal da presente dissertação.

### **2.1 Ajuste de Histórico**

O ajuste de histórico, em linhas gerais, consiste na alteração dos atributos incertos de um modelo de simulação de um campo, respeitando seus limites de incerteza, visando honrar os dados de produção incorporados. A construção de um modelo num simulador numérico é bastante complexa, integrando informações provenientes de diferentes áreas, como dados sísmicos, geológicos, de rocha, de fluido, de perfis e alguns parâmetros de elevação e de superfície. Esta multidisciplinaridade, aliada a medições indiretas e interpretações subjetivas de alguns dados faz com que a caracterização do reservatório envolva um grande número de incertezas. Sendo assim, podem ser gerados diversos modelos numéricos para a representação de um único campo.

A calibração desses modelos com novas informações, obtidas da perfuração de outros poços e da produção do campo, ajudam a reduzir as incertezas existentes, num processo contínuo. Isto quer dizer que até o fim da vida útil do reservatório, novos dados são utilizados para alimentar cada modelo, principalmente os provenientes da produção dos poços. Em seguida, alterando-se os atributos incertos do reservatório, ele é ajustado; diminuindo-se aos poucos, as incertezas e, com isso, representando-se melhor a realidade do campo, o que propicia previsões de comportamento mais confiáveis. A ferramenta fundamental para a criação do modelo, ajuste e previsão de produção é o simulador numérico de fluxo.



Nele, a inserção dos dados observados de produção para o ajuste de histórico é feita da seguinte forma: é informada a vazão de óleo ou líquido observada nos poços, que constitui uma entrada, e os demais parâmetros da produção (por exemplo, vazão de água, pressão e RGO) são simulados, gerando saídas dos modelos possíveis, as quais são comparadas com os valores medidos para indicar o grau de ajuste. Modelos bem ajustados são aqueles que apresentam os resultados mais próximos dos reais, tendo maior probabilidade de produzir melhores previsões de desempenho.

O principal objetivo do ajuste, segundo Sousa (2007), é calibrar os dados de entrada de modo que a saída fornecida pelo simulador de reservatórios reflita, da melhor maneira possível, os dados observados. Neste caso, os dados de entrada referem-se aos atributos incertos do modelo (porosidade, permeabilidades absoluta e relativa, transmissibilidade de falhas, contato óleo/água e outros) e a saída são as variáveis de ajuste, como vazão de água e pressão dos poços e do campo, que são comparadas com os dados reais a fim verificar a qualidade do ajuste do modelo.

A avaliação, tanto quantitativa como qualitativa, do ajuste é feita através de uma função-objetivo (FO), a qual quantifica a diferença entre os dados simulados e medidos (observados). A FO pode ser definida pela diferença simples ou quadrática entre o dado observado e o dado simulado ao longo do tempo. O afastamento simples identifica, através do sinal, se os valores simulados estão acima ou abaixo dos observados, auxiliando a decidir se os atributos incertos precisam ser reduzidos ou aumentados. Porém, ao se combinar diferentes variáveis de ajuste, por exemplo, pressão de diversos poços, valores negativos de alguns deles podem anular os positivos de outros. Por isso, utiliza-se mais frequentemente, a distância quadrática no cálculo da FO para o ajuste, eliminando o problema do sinal, já que todos os afastamentos tornam-se positivos.

De acordo com Becerra (2007), não existe uma metodologia universal para fazer o ajuste de histórico. Na análise convencional e mais comum na indústria, é utilizado um único modelo do reservatório, cujos parâmetros incertos são alterados num processo de tentativa e erro até que a diferença entre os dados observados e simulados (FO) esteja dentro de uma tolerância estabelecida. Deste modo, o processo é manual e bastante demorado, sendo considerado ineficiente para casos mais complexos (Leitão, 1997). Um objetivo almejado por todos os profissionais envolvidos em atividades de ajuste de histórico, segundo Sousa (2007), é o ajuste totalmente automático, que consiste em fornecer um ou mais modelos de simulação a um

programa de computador juntamente com os dados de histórico que precisam ser ajustados e, ao término da execução, tem-se um conjunto de modelos ajustados como resultado. Porém, trata-se de uma impossibilidade prática devido ao grande número de possibilidades que se apresentam.

Destas dificuldades, surgiu a proposta de automatização de algumas etapas do processo, constituindo o ajuste de histórico assistido que combina o ajuste de histórico manual e o automático. De acordo com Maschio e Schiozer (2004), ele ainda depende da análise de um engenheiro para escolha de que atributos alterar e da melhor solução de acordo com os objetivos do estudo. Neste processo, são utilizados algoritmos automatizados para a minimização de uma função-objetivo (FO) e para avaliar rapidamente a qualidade de cada tentativa de ajuste.

A principal dificuldade do ajuste de histórico é a não unicidade das soluções. Por ser um problema inverso, com muitos atributos incertos e diversas funções-objetivo, há múltiplas respostas, ou seja, diferentes combinações de atributos podem fornecer respostas semelhantes para o mesmo histórico de produção (Moura Filho, 2006). É importante salientar que os diversos modelos próximos do histórico resultam, na maioria das vezes, em previsões de produção bastante distintas. A não unicidade de soluções implica na existência de incertezas no problema; portanto, torna-se importante não se analisar somente um único modelo do reservatório, mas diversos modelos gerados pela combinação das incertezas existentes e associados a uma probabilidade de ocorrência, obtendo-se múltiplas previsões. Se as probabilidades de ocorrência puderem ser associadas aos modelos ajustados, é possível gerar previsões probabilísticas.

Para um melhor entendimento da multiplicidade de soluções foram criados os gráficos teóricos da Figura 2.1, que ilustra duas calibrações diferentes do modelo para a produção de água de um reservatório. Os atributos do modelo base hipotético (curva vermelha) foram alterados de duas formas distintas, gerando diferentes ajustes do histórico de produção (curva preta). A curva do Ajuste 1 (azul) apresenta comportamento similar ao histórico até cerca da metade do tempo analisado, porém nos tempos finais, seus valores estão acima dos observados. Já a curva do Ajuste 2 (verde) mostra um comportamento contrário, diferente da vazão de água observada no início e com valores bem próximos a vazão histórica no final do tempo em análise. Portanto, não é possível afirmar qual dos dois casos representa um melhor ajuste, pois, na média, eles proporcionam um ajuste semelhante. A análise dos gráficos deixa claro que nenhum dos dois resultados está excelente, mostrando a fragilidade na consistência do modelo. A Figura 2.1

destaca também que os dois resultados obtidos podem apresentar projeções futuras de produção bastante diferentes (extrapolação), evidenciando a necessidade da utilização de mais de um modelo para a representação do campo e obtenção de uma previsão com incertezas.

Além disso, é importante salientar, que ajustes muito bons podem ser conseguidos com modelos de simulação bem diferentes, provenientes de modelagens geológicas distintas, ou seja, há incertezas associadas a qual modelo geológico é o melhor, além dos atributos modificados dentro de uma mesma realização da geologia. Desta forma, é possível que duas combinações diferentes dos atributos incertos em dois modelos geológicos distintos dêem resultados similares para o ajuste de histórico com previsões de produção diferentes.

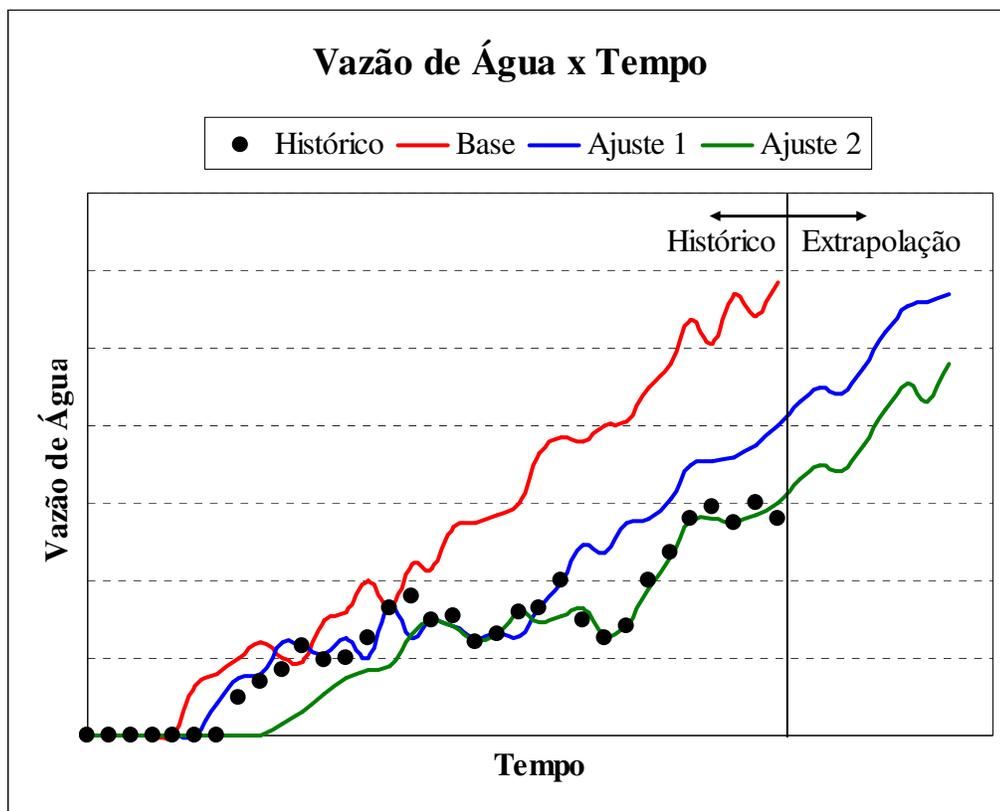


Figura 2.1 – Exemplo hipotético de multiplicidade de soluções do ajuste de histórico.

O ajuste de histórico é uma das etapas mais longas do gerenciamento de um campo de petróleo, tendo início logo após a perfuração dos poços e só terminando quando o campo é abandonado. Ele também é de suma importância para as tomadas de decisões, pois os modelos de simulação bem ajustados representam de forma consistente o passado, apresentando maior

confiabilidade para se prever o futuro. Por se tratar de um problema com uma grande quantidade de parâmetros de entrada incertos e que possuem interdependências, e com inúmeras saídas a serem analisadas, exige um grande esforço computacional, além de um elevado tempo de análise por parte dos profissionais envolvidos no processo.

## **2.2 Análise de Incertezas**

A incerteza está associada à falta de conhecimento nos atributos que caracterizam os reservatórios. Os dados geológicos e petrofísicos disponíveis, por exemplo, são insuficientes para caracterizar precisamente as propriedades do reservatório (porosidade, permeabilidade, curvas de permeabilidade relativa e outros), as quais se tornam atributos incertos. Estes podem afetar significativamente os resultados de uma previsão de produção ou de um projeto, gerando o risco, que é definido como o grau de impacto das incertezas no modelo (Becerra, 2007). Nem toda incerteza é uma fonte de risco visto que alguns atributos podem ser incertos, mas ter baixo impacto na previsão de produção.

A utilização das incertezas e da análise de risco nas previsões de produção tem crescido nas áreas de exploração e produção da indústria de petróleo desde o final da década de 90, principalmente por causa dos elevados investimentos envolvidos em projetos de grande porte. Desta forma, a modelagem do reservatório deixa de ter uma abordagem determinística, passando a ter uma interpretação estocástica, onde é possível a incorporação das incertezas. A aproximação determinística, tradicional na indústria, considera os parâmetros geológicos livres de erros, ou seja, obtém-se um único modelo para representar o campo. Já a modelagem estocástica utiliza distribuições nas propriedades dos reservatórios, que estão condicionadas a informações obtidas através de outros meios de pesquisa (Cosentino, 2001). Sua vantagem é integrar os conhecimentos alcançados pelos trabalhos dos geocientistas e engenheiros: informações geológicas e petrofísicas, dados de sísmica e dados dinâmicos (produção e pressão dos poços e dados de saturação obtidos da sísmica 4D), incorporando suas incertezas.

Assim, os parâmetros de entrada da caracterização do campo são representados por distribuições de probabilidade, gerando diversos modelos de simulação; e, as saídas (exemplo: produção acumulada de óleo) passam a ser uma faixa de valores associados às suas respectivas

probabilidades de ocorrência, não assumindo um valor único (determinístico). As distribuições de probabilidade que representam os atributos incertos podem ser de diversos tipos, normal, log-normal, uniforme ou triangular, honrando os limites físicos estabelecidos pela caracterização de rocha e fluidos. Os tipos de distribuições mais comuns estão mostrados na Figura 2.2.

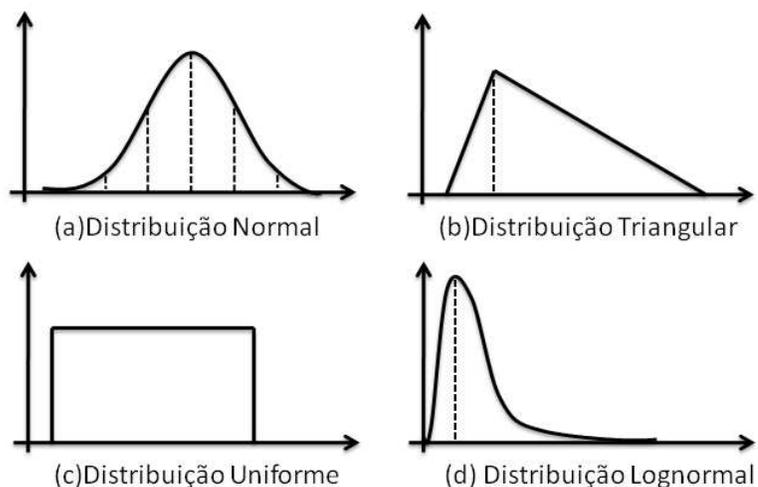


Figura 2.2 – Exemplos de distribuições probabilísticas.

Para a modelagem do reservatório, cada atributo incerto pode ser discretizado em níveis de incerteza, de acordo com a sua função densidade de probabilidade (*fdp*), como mostrado na Figura 2.3, onde se define a quantidade de níveis e a probabilidade associada a cada nível para uma *fdp* normal (Moura Filho, 2006). Alguns trabalhos da literatura sugerem a utilização de três níveis de incerteza (Ovreberg et al., 1990; Jensen, 1998) e outros até cinco níveis (Ballin et al., 1993). Segundo Loschiavo (1999) a discretização da *fdp* em três níveis gera resultados compatíveis com as condições reais.

As combinações dos diferentes níveis dos diversos atributos incertos constituem os cenários. A quantidade de cenários a ser simulada está diretamente ligada ao número de atributos incertos e à quantidade de níveis. Quanto mais atributos incertos e quanto maior o número de níveis associados a eles, maior o número de simulações. Loschiavo (1999) sugere o uso apenas dos atributos críticos para gerar os cenários, escolhidos por um processo de análise de sensibilidade.

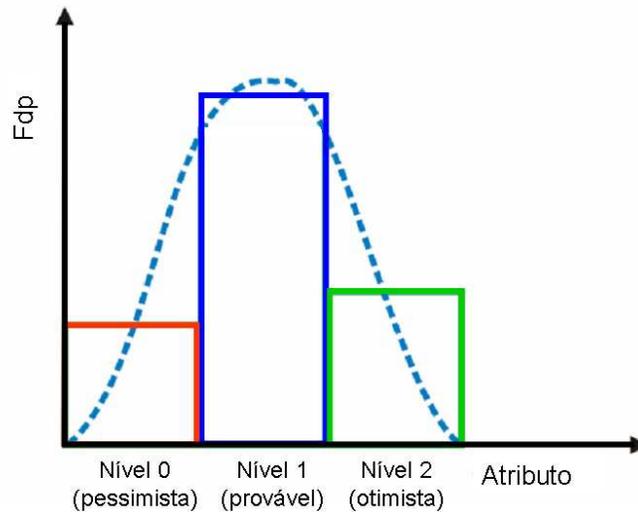


Figura 2.3 – Discretização da função densidade de probabilidade em 3 níveis de incerteza (adaptada de Moura Filho, 2006).

### 2.2.1 Análise de Sensibilidade

A finalidade principal da análise de sensibilidade (AS) é verificar a influência de cada atributo na função-objetivo (FO) em estudo, identificando aqueles mais influentes, os atributos críticos. Como nem toda incerteza é geradora de risco, alguns parâmetros podem ser simplificados ou suas faixas de variação ignoradas, desde que suas incertezas gerem pouca ou nenhuma variação na FO (Becerra, 2007).

Para realizar a análise de sensibilidade simples, primeiro simula-se o caso base, com todas as incertezas no valor mais provável; em seguida, duas novas rodadas do simulador são realizadas para cada atributo incerto, variando-se o atributo para outros dois valores que representam a variabilidade do atributo (muitas vezes chamados de pessimista e otimista). Portanto, o número de simulações necessárias nesta etapa pode ser representado pela equação:

$$NS = 2 * At + 1, \tag{2.1}$$

onde  $At$  é o número de atributos incertos. O  $NS$  é pequeno quando comparado com o total de modelos possíveis.

Na fase seguinte, são calculadas as diferenças quadráticas e simples do caso base com relação ao caso em análise para cada função (vazões e pressões); a primeira é utilizada para a

obtenção do índice de sensibilidade (IS) e a segunda indica o sinal do índice, ou seja, se está deslocando a curva para baixo ou para cima do caso base. O IS é dado pela normalização da distância quadrática do modelo em questão pela distância quadrática máxima de uma determinada FO, possuindo valores entre -1 e 1, sendo que os extremos indicam maior influência do atributo na FO. O valor zero indica que determinada FO é insensível ao atributo em questão. Sendo feita conforme descrito acima, a AS avalia um parâmetro incerto por vez, investigando todo o seu intervalo de incerteza com relação ao caso base. Seu ponto fraco é o fato de não analisar a influência das combinações dos atributos incertos (Alpak et al., 2009).

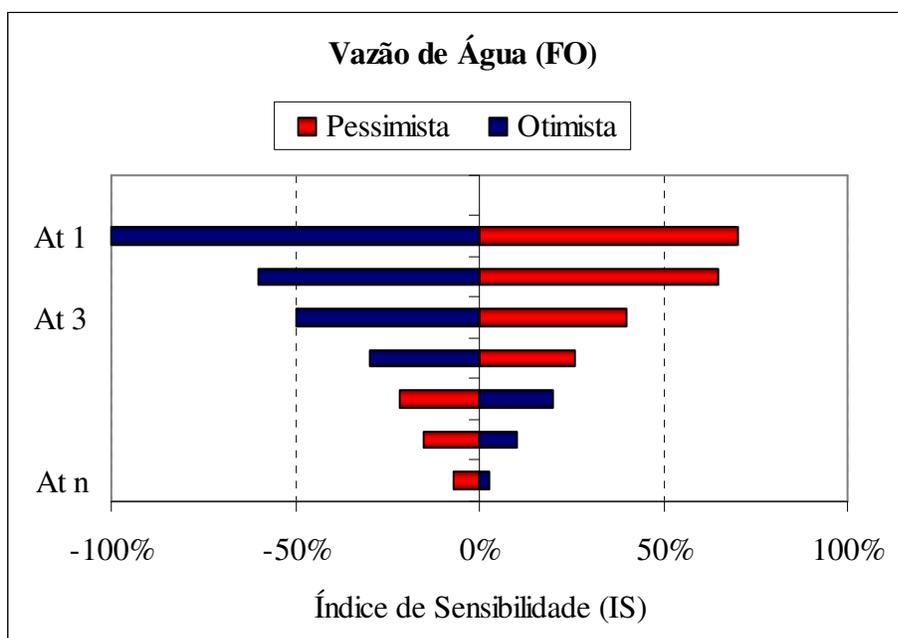


Figura 2.4 – Gráfico *tornado* para análise de sensibilidade.

Os resultados de uma AS são visualizados tradicionalmente em um gráfico *tornado* (Figura 2.4 – atributos discretizados em três níveis), ordenado dos parâmetros de maior impacto para os de menor impacto na FO. A partir de gráficos como o mostrado na Figura 2.4, é possível eliminar os atributos de menor influência na função-objetivo, selecionando-se somente os atributos críticos. Com isso, o número de modelos de reservatório a serem simulados é reduzido, diminuindo, conseqüentemente, o esforço computacional e o tempo total de simulação.

### 2.2.2 Árvore de Derivação

De posse dos atributos críticos, estes podem ser combinados utilizando-se a metodologia da árvore de derivação, sendo cada ramo da árvore um cenário gerado (modelo simulado) associado a uma probabilidade de ocorrência, a qual depende das probabilidades dos níveis, conforme ilustrado na Figura 2.5. Tal método permite discretizar as composições das variáveis de incerteza e as probabilidades dos diversos modelos de reservatório resultantes, os quais serão submetidos ao simulador (Loschiavo, 1999).

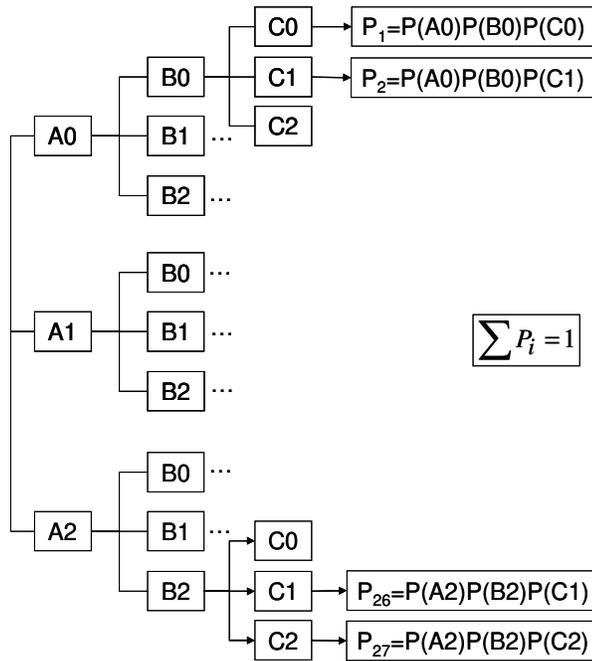


Figura 2.5 – Exemplo esquemático de uma árvore de derivação.

O número total de simulações é função da quantidade de atributos críticos e do número de níveis em que eles foram discretizados e, é dado pela Equação 2.2:

$$NS_{AD} = \prod_{i=1}^N (n_i)^{At_i}, \quad (2.2)$$

sendo  $At_i$  é o número de atributos do grupo discretizado em  $n_i$  níveis e  $N$  é o número de grupos de atributos. Assim, para um caso com 5 atributos discretizados em 3 níveis, o número de simulações é dado por  $3^5 = 243$  simulações e, caso se agregue mais um atributo esse número já sobe para 729 simulações, daí a importância de seleção dos atributos mais críticos.



A Figura 2.5 mostra um exemplo com 3 atributos, discretizados em três níveis (0, 1 e 2), tendo-se um total de 27 simulações. A primeira linha da árvore é a combinação do nível 0 dos três atributos, A0B0C0, sendo a probabilidade de ocorrência deste modelo igual ao produto das probabilidades dos níveis selecionados de cada um dos atributos,  $P(A_0)P(B_0)P(C_0)$ . De forma similar, a linha seguinte combina A0, B0 e C1, sendo sua probabilidade  $P(A_0)P(B_0)P(C_1)$ , e assim por diante, como exemplificado na Figura 2.5. A soma das probabilidades dos 27 modelos é igual a unidade.

Algumas limitações da árvore de derivação, que é a forma mais simples de combinação estatística, são: o aumento do número de níveis considerados e o aumento do número de atributos críticos, que é bastante comum em casos complexos. Uma alternativa é o uso de técnicas de amostragem para sortear cenários representativos, não sendo necessário simular todas as combinações dos atributos (métodos de Monte Carlo e Hipercubo Latino) para gerar resultados confiáveis.

O método de Monte Carlo representa uma amostragem aleatória dos atributos, seguindo determinadas distribuições de probabilidade (Cosentino, 2001). Nesse caso, para representar bem uma determinada distribuição, em geral, é necessário um número elevado de sorteios. Já o Hipercubo Latino, realiza sorteios aleatórios em faixas de valores; ele consiste em dividir as distribuições de probabilidades em intervalos e realizar sorteios dentro de cada uma destas faixas (Maschio et al, 2009). A quantidade de valores amostrados dentro de cada intervalo é diretamente proporcional à probabilidade de cada faixa. Assim, independente do número de sorteios realizados, garante-se amostragens ao longo de toda a faixa, mesmo que o intervalo tenha uma probabilidade pequena, o que o método de Monte Carlo só consegue com um número muito grande de sorteios.

### **2.2.3 Curva de Incerteza**

A partir dos resultados das simulações dos diversos cenários (modelos) criados pela combinação dos atributos críticos, é possível obter uma curva de incerteza, que representa as funções-objetivo de cada modelo associadas a uma probabilidade acumulada de ocorrência. No caso de uma análise de risco, tal curva é chamada de curva de risco e a FO pode ser o VPL (valor

presente líquido) associado a cada cenário. Para o ajuste de histórico, Moura Filho (2006) mostrou que o mesmo conceito pode ser usado, sendo a FO da curva de incerteza dada pelas diferenças entre os dados simulados e os observados.

Para traçar tal curva, os valores da FO dos modelos (diferença quadrática do dado simulado em relação ao histórico, acrescido do sinal dado pela distância simples) são ordenados de forma decrescente, e suas probabilidades associadas são acumuladas. A curva de incerteza é utilizada para avaliar a qualidade do ajuste de histórico, analisando-se a dispersão da curva com relação ao eixo vertical (linha zero), que representa o ajuste perfeito, isto é, curva simulada idêntica aos dados observados (histórico de produção).

Após a aplicação de um método de redução de incertezas, espera-se que a dispersão em torno do valor zero diminua em relação à curva inicial, o que está ilustrado na Figura 2.6. No gráfico são mostradas as curvas de incerteza inicial (vermelha) e final (azul), bem como os percentis  $P10$ ,  $P50$  e  $P90$  representativos da variabilidade das respostas obtidas. Sabendo-se que a estimativa  $Pn$  significa que há  $n\%$  de probabilidade que certo valor real da FO seja maior ou igual ao valor estimado, a dispersão é dada pela distância entre as FO de  $P10$  e  $P90$  e sua redução implica em expectativas de produção menos incertas.

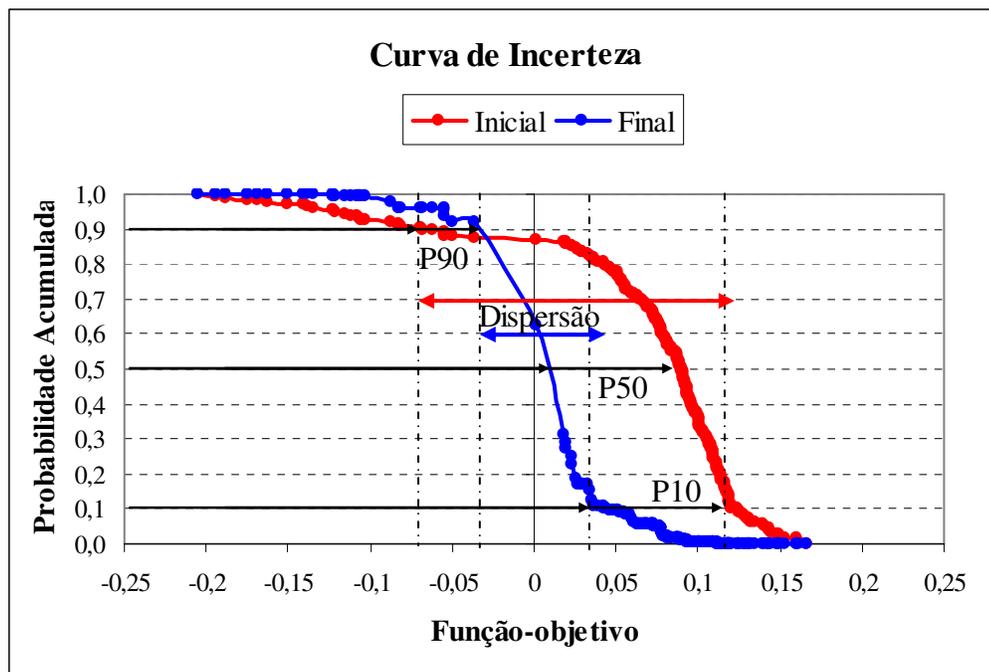


Figura 2.6 – Exemplo de curva de incerteza antes e após um processo de mitigação de incertezas.

Além disso, das curvas de incertezas geradas podem ser selecionados modelos representativos do caso em estudo (P1, P10, P90 e P99), conforme explicado por Vasconcelos (2011). Esses modelos são utilizados para apresentar um resumo da dispersão inicial e final da FO para o caso avaliado e a proporção dessa dispersão em relação ao indicador de ajuste “perfeito”, em um gráfico tipo “bastão” (Figura 2.7). Para traçar o gráfico situado à direita na Figura 2.7, os valores dos percentis 10 e 90 são lidos no gráfico da esquerda, formando o corpo do “bastão”. Quanto menor a espessura deste “bastão”, melhor a redução das incertezas com base nos dados de histórico. Os valores dos percentis 1 e 99 também podem ser extraídos do gráfico da esquerda, mostrando os extremos da curva de incerteza, ou seja, maiores diferenças com relação ao histórico.

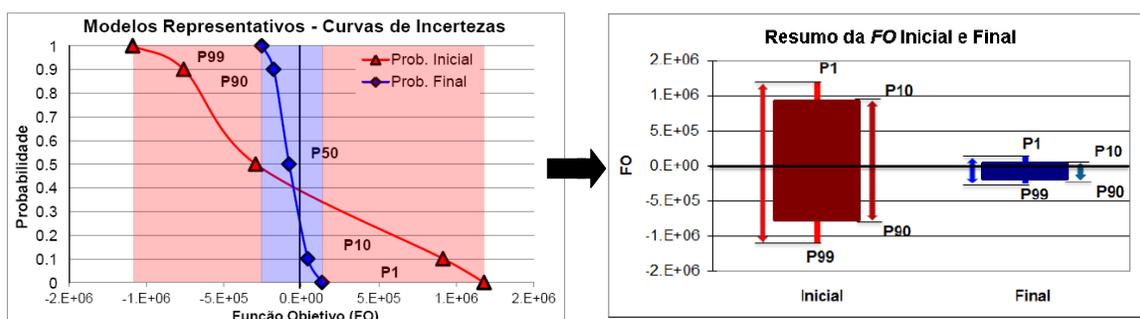


Figura 2.7 – Seleção dos modelos representativos iniciais e finais para traçar o gráfico tipo “bastão” (adaptado de Vasconcelos, 2011).

### 2.3 Redução de Incertezas a partir dos Dados de Histórico de Produção

Os processos de redução de incertezas atuam de forma a alterar as curvas de densidade de probabilidade dos atributos incertos, diminuindo, com isso, os riscos presentes no desenvolvimento e produção de um campo e evitando gastos desnecessários que resultem em desvantagens financeiras. A maior quantidade de dados disponíveis para o campo deve ser utilizada para alcançar o objetivo de minimização das incertezas, e uma dessas fontes de dados é o histórico de produção dos poços.

Neste contexto, as probabilidades de ocorrência de cada nível dos atributos incertos do modelo podem ser alteradas em função das diferenças entre os dados simulados e de histórico, com o objetivo de reproduzir na simulação o comportamento real do campo da maneira mais fiel

possível. Dessa forma, os cenários com resultados mais próximos do real (melhor ajuste) passam a ter maior probabilidade de ocorrência e os modelos pouco representativos têm suas chances diminuídas, reduzindo assim, as incertezas na previsão.

A Figura 2.8 ilustra um aspecto geral do procedimento descrito, o qual será mais detalhado nos capítulos posteriores por ser a base deste trabalho. O quadro superior esquerdo mostra um exemplo de função densidade de probabilidade discretizada em três níveis: 0 (mínimo), 1 (provável) e 2 (máximo) e sua redistribuição (linha tracejada azul), após a aplicação da metodologia. Já à direita representa-se a redefinição das distribuições de um atributo se fosse considerada sua forma contínua de distribuição. O quadro inferior à esquerda exemplifica as curvas de incerteza do afastamento em relação ao histórico de produção antes (vermelha) e depois (azul) da aplicação da metodologia. O gráfico situado à direita na parte inferior exemplifica o efeito obtido sobre os períodos de histórico de produção e de previsão, ao se traçar as curvas de produção dos modelos compreendidos em uma faixa em torno do P50 (considerado o melhor ajuste) extraídos das curvas de incerteza antes e depois da aplicação da metodologia (por exemplo, P10-P90, P30-P70), mostrando a redução das incertezas na previsão de produção.

É importante salientar que o histórico deve estar localizado dentro do envelope das curvas geradas pelos modelos possíveis (preferencialmente entre o P10 e P90), pois, assim, as previsões são realizadas com maior grau de confiabilidades (Moura Filho, 2006). Logo, a mitigação de incertezas é alcançada quando novas distribuições de probabilidade são definidas, caracterizando de forma mais coerente as condições reais dos atributos e aumentando a probabilidade dos modelos com resultados mais próximos dos modelos do histórico para diminuir a incerteza na previsão de produção.

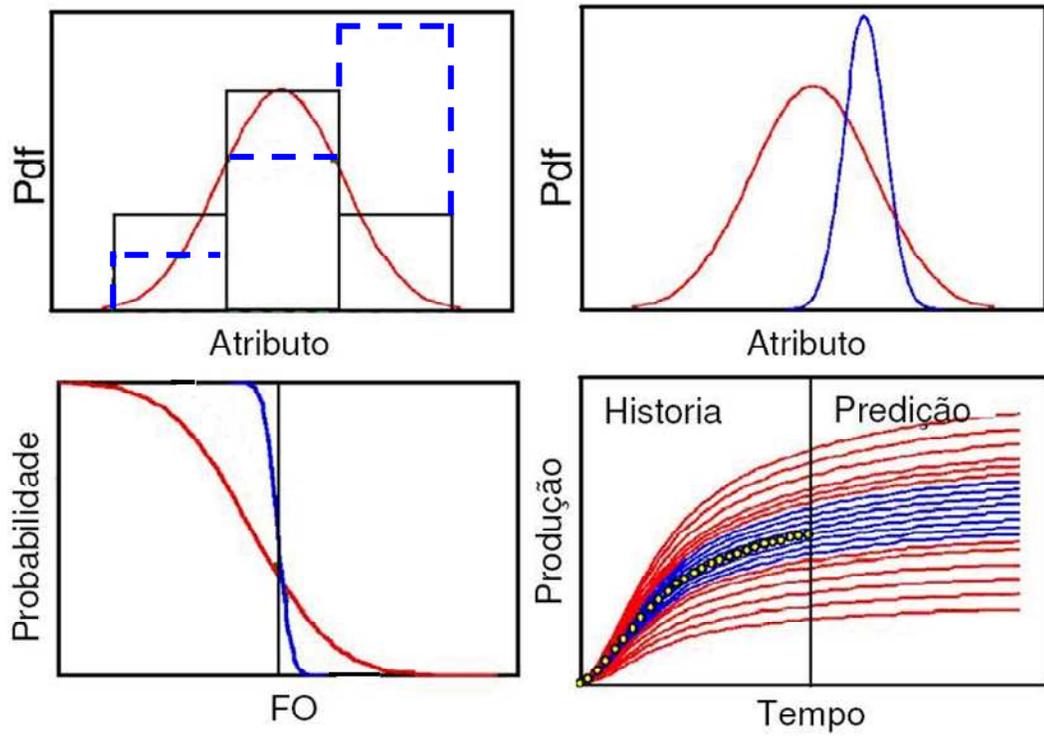


Figura 2.8 – Aspectos gerais da redução de incertezas a partir dos dados de histórico de produção (adaptada de Moura Filho, 2006).

### **3. REVISÃO BIBLIOGRÁFICA**

Este capítulo apresenta uma revisão bibliográfica com o objetivo de mostrar alguns trabalhos desenvolvidos integrando o ajuste de histórico com a análise de incertezas. Os dois temas, que de início eram tratados isoladamente, passaram a ser analisados em conjunto por alguns autores. Além disso, são destacados os trabalhos de Moura Filho (2006) e Becerra (2007) e de Maschio et al. (2010) que constituem os Métodos 1 e 2 do trabalho e são a base desta dissertação.

#### **3.1 Integração da Análise de Incertezas com o Ajuste de Histórico**

A maioria dos projetos desenvolvidos na linha de pesquisa que integra a análise de incertezas com o ajuste de histórico é recente. Um dos trabalhos pioneiros no tema é o de Lépine et al. (1999) que estima a incerteza na performance futura de reservatórios já em produção. Ele afirma que uma vez modificados os parâmetros de um modelo de reservatório para se obter um bom ajuste, é possível perturbá-los um pouco e ainda assim obter um ajuste aceitável; e, aplicando-se as mesmas perturbações na predição, um conjunto de perfis de previsão de produção futura é obtido. A metodologia foi aplicada em dois campos reais, um situado no Oeste da África e outro, no Mar do Norte, fazendo-se uma análise linear das perturbações de forma a gerar um intervalo de confiança para a previsão futura do reservatório. Vale salientar que nem sempre o conjunto de atributos escolhidos para a análise de incerteza da previsão coincide com aqueles usados no ajuste de dados históricos.

Portella e Prais (1999) apresentam um trabalho que combina o ajuste de histórico com a modelagem geoestatística para gerar imagens equiprováveis do reservatório levando em consideração os dados de produção. Primeiramente, é feito um ajuste de histórico automatizado usando dados de produção existentes; em seguida, o modelo resultante desta técnica é utilizado para gerar realizações geoestatísticas, usando valores de pontos piloto e de dados originais existentes. Por fim, estas imagens são usadas para obter o intervalo de confiança de previsões de

produção através da simulação de fluxo de cada uma delas. Foi escolhido o método de otimização *Simulated Annealing* (Ouenes et al., 1993) por ser de fácil implementação, não necessitando acessar os códigos do simulador de fluxo.

Na mesma linha, Hu et al. (1999) desenvolvem uma ferramenta baseada no método de deformação gradual (descrita por Roggero e Hu, 1998), para gerar realizações geoestatísticas que obedecem tanto os dados geológicos como os dinâmicos (exemplo: produção e pressão dos poços). Ela é combinada com um método de otimização não-linear para restringir às realizações aos dados dinâmicos, através da minimização de uma função-objetivo que mede a diferença entre os dados observados e simulados.

O trabalho de Hegstad e Omre (2001) avalia a contribuição das observações de poços (perfis de porosidade, permeabilidade e impedância acústica), dos dados de amplitude sísmica e histórico de produção na redução de incertezas na previsão de comportamento de reservatório. Devido à não linearidade do modelo de fluxo, o condicionamento imposto pelo histórico de produção constitui um grande desafio

Manceau et al. (2001) apresenta uma metodologia integrada para gerenciamento de incertezas durante o ajuste de histórico, a previsão de produção e a otimização da estratégia de produção. A teoria de planejamento de experimentos combinada com a metodologia de superfície de resposta (uso de um polinômio para representar a resposta do simulador de fluxo) permite a quantificação do impacto das incertezas “determinísticas” (dados petrofísicos e de produção) na produção de óleo. Já a técnica inovadora de *Joint Modeling Method*, é utilizada para quantificar o impacto das incertezas “estocásticas” (diferentes realizações geoestatísticas e modelos de reservatórios ajustados equiprováveis). O trabalho conclui que a integração de métodos estatísticos, como o planejamento de experimentos, as superfícies de resposta e o *Joint Modeling Method*, permite um tratamento eficiente das incertezas na engenharia de reservatórios, sendo uma ferramenta apropriada para uso em tomada de decisões num ambiente propício ao risco.

Combinando técnicas de geoestatística e método dos gradientes, Bennett e Graf (2002) examinam diversos parâmetros que afetam a pressão de fundo e o corte de água. A partir desta análise, selecionam modificadores dos atributos incertos, como por exemplo, multiplicadores de permeabilidade absoluta e variações do ponto final da curva de permeabilidade relativa da água,

para estimar as incertezas de produção através de ajuste de histórico para um reservatório localizado na Venezuela.

Christie et al. (2002) aplicam, pela primeira vez, o algoritmo de vizinhança (*neighborhood algorithm*) determinando um conjunto de casos ajustados, os quais são avaliados quantitativamente através da técnica Bayesiana. Este grupo de modelos resolve de forma probabilística o problema inverso existente na simulação numérica, mas também permite a quantificação da incerteza na previsão de produção, a partir das diferentes alternativas de desenvolvimento. Tal metodologia foi aplicada tanto para modelos sintéticos como para casos reais. Os resultados atingidos são muito promissores, embora requeiram uma grande experiência, especialmente na determinação dos parâmetros de controle de reservatório no caso de campos complexos (presença de falhas, interconexão de blocos, orientação de canais, mudanças na mobilidade dos fluidos etc.) e de suas respectivas distribuições de probabilidade.

Almeida Netto (2003) sugere uma metodologia de redução das incertezas na previsão de comportamento de reservatórios, utilizando o ajuste de histórico de produção e a simulação numérica. A proposta é gerar cenários de previsão de produção, com suas respectivas avaliações econômicas, em modelos com combinações dos atributos incertos que apresentam bons ajustes das vazões de produção e pressões observadas do campo como um todo e de cada poço. Desta forma, o autor usa o histórico de produção como condicionante para a escolha do cenário de previsão.

A técnica de *Joint Modeling Method* é novamente utilizada por Feraille *et al.* (2003) para quantificar o impacto das incertezas na previsão de produção de um campo real. O trabalho manipula parâmetros de produção dentro de uma determinada faixa de valores a fim de minimizar a incerteza devido à existência de várias soluções para o ajuste de histórico. A comparação das incertezas na previsão de produção obtidas antes e depois do ajuste de histórico com parâmetros de produção fixos para a solução ótima do *Joint Modeling Method* é utilizada para validar o trabalho. O resultado é uma redução de 75% da incerteza na previsão quando se levam em consideração modelos ajustados.

Landa e Guyaguler (2003) utilizam técnicas de gradiente para avaliação das incertezas associadas com a previsão de fluxo. Nesta aproximação, são construídos meta-modelos (superfícies de resposta) com o auxílio de técnicas de iteração de *kriging* para o período histórico,



honrando os valores exatos e gradientes para as combinações de parâmetros escolhidas. A precisão destas superfícies aumenta com as simulações adicionais guiadas pelo planejamento experimental e como consequência do progresso do algoritmo. O meta-modelo gerado no final do processo de ajuste de histórico é utilizado para estimar a incerteza associada com a previsão de desempenho do reservatório, obtida a partir da variação dos parâmetros sem ultrapassar os valores extremos definidos previamente e da seleção de novos parâmetros não avaliados na etapa anterior. O método proposto é aplicado a dois casos, um sintético e um real, sendo um passo inicial para uma metodologia que avalia a não-unicidade do processo de ajuste de histórico e as incertezas associadas à previsão de produção do reservatório. Uma desvantagem do método gradiente é sua dificuldade de implementação, pois requer acesso aos códigos do simulador.

Uma nova abordagem, denominada *Top-Down Reservoir Modelling* (TDRM), é apresentada por Williams et al. (2004). Ela incorpora incertezas do reservatório na construção do modelo e na previsão de desempenho de produção. TDRM usa um algoritmo genético para ajuste de histórico assistido por ser considerado o método mais robusto para encontrar soluções ótimas. Esta metodologia tem sido aplicada com sucesso em campos que se encontram desde a fase de avaliação até a fase de declínio, tanto para reservatório de óleo como para reservatório de gás.

Gu e Oliver (2004) aplicam com sucesso o método de filtro de Kalman estendido para o ajuste de histórico automático, permitindo a determinação e redução da incerteza no desempenho futuro de reservatório simultaneamente. O filtro de Kalman, também utilizado na meteorologia e sismografia de terremotos, surge como uma solução prática ao problema de elevado tempo computacional e alta frequência de amostragem de dados de reservatório. Este método é uma derivação do método de Monte Carlo no qual um conjunto de modelos de reservatório é utilizado, simultaneamente, para atingir o ajuste em cada tempo.

Nicotra et al. (2005) também utilizaram o algoritmo da vizinhança (*neighborhood algorithm*), desenvolvido para solução de problemas de inversão em sismologia de terremoto, no ajuste de histórico e avaliação de incertezas de um reservatório real. O trabalho mostra uma aplicação prática na obtenção de múltiplos modelos para ajuste de histórico num campo marítimo com três anos de histórico de produção. Como principal resultado encontrado, cita-se uma redução significativa no tempo computacional necessário para obter um ajuste de alta qualidade.

Alvarado et al. (2005) salientam que a quantificação da incerteza nas previsões de produção é crítica para fazer decisões apropriadas no gerenciamento do reservatório. A abordagem proposta gera previsões de produção preliminares no início do estudo associadas a uma incerteza, em seguida, usa o grau de ajuste com respeito ao histórico de produção para os cálculos dos pesos correspondentes a cada previsão. A metodologia foi aplicada com sucesso para o estudo de um reservatório complexo no Golfo do México, sendo observado que à medida que a precisão do modelo aumenta durante o ajuste do histórico, a incerteza nas previsões diminui e as distribuições das reservas se estabilizam. O procedimento inclui também a determinação da função de densidade de probabilidade da produção de fluidos futura, enquanto o ajuste de histórico está sendo desenvolvido.

Reis (2005) apresenta uma metodologia impondo restrições de forma a garantir que somente os modelos ajustados sejam computados na atribuição de probabilidades de uma análise de risco. As restrições são feitas através da minimização da derivada de uma função-objetivo com relação à variável dinâmica dependente. Faz-se o uso de técnicas de planejamento de experimentos e do método de superfície de respostas, sendo o método simples e de fácil aplicação. Entretanto, comprova-se que o risco calculado pode não compreender todas as combinações possíveis devido às restrições da construção dos polinômios das superfícies de resposta.

Schiozer *et al.* (2005) propõem um procedimento de integração do ajuste de histórico com a análise de incertezas, que começa com a definição dos atributos incertos, uma análise de sensibilidade dinâmica e posterior avaliação das incertezas do reservatório, na qual vários modelos de simulação são gerados. Em seguida, aqueles que não reproduzem o comportamento do reservatório no período histórico são descartados, diminuindo o nível de incerteza na produção. Algumas vantagens são um melhor tratamento do comportamento dinâmico do ajuste de histórico e a obtenção de múltiplas soluções, devido às dúvidas ainda presentes no modelo, que são tratadas numa abordagem de análise de incertezas, proporcionando uma maior confiança no processo. Uma aparente desvantagem é o aumento do número de simulações iniciais quando a quantidade de atributos incertos é elevada. A maior justificativa desse procedimento é baseada na não garantia de previsões confiáveis de um modelo único.

Na mesma linha de obtenção de múltiplos modelos para a previsão de comportamento, que sejam consistentes com os dados geológicos e de produção, Landa et al. (2005) desenvolvem um método baseado em simulação de Monte Carlo. Nele, são sorteadas combinações dos parâmetros incertos, gerando os modelos que são simulados para o cálculo de uma função-objetivo relacionada com a probabilidade Bayesiana. Novas amostragens são realizadas seguindo um esquema associado a um algoritmo de interpolação que funciona como um meta-modelo do simulador de reservatórios, estimando-se suas funções-objetivo. Os resultados deste passo são utilizados para gerar novos esquemas de amostragem para a simulação numérica real, e para aumentar a confiança nos algoritmos de interpolação, sucessivos sorteios são realizados até que um ponto de parada seja atingido. Com isso, obtém-se um grande número de soluções “aceitáveis”, que são aumentadas com realizações de parâmetros com baixo impacto no ajuste de histórico, para gerar as previsões de produção.

Kashib e Srinivasam (2006) usam um método baseado em probabilidades condicionais, onde novas distribuições espaciais de permeabilidade são obtidas levando em conta as informações contidas nas respostas dinâmicas do modelo e as observações registradas. As realizações geoestatísticas geradas conduzem a um conjunto de modelos que honram os dados históricos e respeitam a estrutura geológica. Neste trabalho, postula-se que a previsão do comportamento do campo pode ser mais realista que aquela obtida a partir de um modelo geologicamente consistente, mas construído sem considerar os dados de produção.

Costa et al. (2006) desenvolvem um trabalho aplicando a metodologia de modelos geológicos representativos (MGR) com o objetivo de utilizar a quantificação do impacto das incertezas geológicas para melhorar o ajuste de histórico de produção num campo terrestre do Brasil com 17 anos de produção. A maior vantagem desse processo é fornecer um conjunto de modelos ajustados globalmente, ou seja, para as vazões do campo, permitindo a seleção do melhor modelo a ter o ajuste refinado poço a poço. Os MGR são selecionados com base em funções-objetivo previamente definidas para representar todas as combinações de modelos que compõem a curva de risco. O trabalho mostra que os MGR obtidos da análise de risco tornam o processo mais viável e rápido, sendo um método efetivo de reduzir o tempo gasto e melhorar as tomadas de decisão.

Schaaf et al. (2008) propõem um fluxo de trabalho combinando diferentes metodologias para reduzir as incertezas de subsuperfície usando múltiplos modelos ajustados ao histórico e, com isso, inferir as previsões de produção futuras com confiabilidade. A metodologia consiste de uma análise de sensibilidade através da técnica de planejamento de experimentos com o uso de meta-modelos que avalia todos os parâmetros de incerteza estáticos e dinâmicos, selecionando os mais críticos com relação à função-objetivo que quantifica as diferenças entre os dados simulados e observados. Em seguida, ferramentas de ajuste de histórico assistido são utilizadas para obter um conjunto de modelos ajustados e a técnica Bayesiana é usada para gerar uma nova distribuição dos parâmetros críticos com base na distribuição inicial e no meta-modelo da função de probabilidade. Por fim, os modelos ajustados e a nova distribuição dos parâmetros são combinados numa técnica de *Joint Modeling* para gerar os perfis de previsão de produção probabilísticos.

Busby et al. (2009) propõem um fluxograma para reduzir a incerteza inicial presente no reservatório incorporando os dados de produção. Diversas metodologias avançadas como análise de sensibilidade global, emuladores de processos Gaussianos, planejamento de experimentos, uso de meta-modelos e deformação gradual são combinadas para gerar uma abordagem eficaz na assimilação de dados de produção para a redução das incertezas. O uso da deformação gradual permite incluir parâmetros estocásticos na análise (como permeabilidade e porosidade), além dos parâmetros contínuos e discretos já utilizados na análise de incertezas com planejamento experimental e superfícies de resposta. Em geral, as técnicas citadas requerem um número elevado de simulações de fluxo e, por isso, a não utilização de meta-modelos inviabiliza sua aplicação prática. O método é aplicado a um campo de óleo real e os autores mostram que uma correta caracterização das incertezas do reservatório é fundamental para a obtenção de modelos que reproduzam os dados de histórico. Na aplicação, a incerteza inicial foi sensivelmente reduzida com uma boa qualidade de ajuste, por causa da alteração das distribuições de probabilidade dos parâmetros incertos e, além disso, foi gerada uma previsão probabilística de produção.

Para recalcular as probabilidades dos níveis dos atributos incertos de um reservatório podem ser utilizadas as diferenças entre os resultados obtidos dos diversos cenários simulados e os dados de histórico (produção de água e pressão, por exemplo), como proposto nas

metodologias desenvolvidas por Moura Filho (2006), Becerra (2007) e Maschio et al. (2010). Este processo, integrando o ajuste de histórico com a análise de incertezas, tem por objetivo tornar maiores as probabilidades de ocorrência dos cenários com melhor ajuste e diminuir as chances de ocorrência de modelos pouco representativos, reduzindo assim, as incertezas na previsão. Estes métodos serão detalhados a seguir por serem a base deste trabalho.

### **3.2 Linha de Pesquisa de Referência**

Neste trabalho, busca-se a aplicação da metodologia proposta por Moura Filho (2006) e aperfeiçoada por Becerra (2007) e Maschio et al. (2010) em um caso complexo e real, analisando as dificuldades e propondo alterações na formulação. Conforme citado no item anterior, a proposta é a alteração das probabilidades de ocorrência de cada nível dos atributos incertos do modelo, em função das diferenças dos dados simulados em relação aos de histórico. Dessa forma, os cenários com resultados mais próximos do real (histórico) passam a ter maior probabilidade de ocorrência.

Os diversos cenários são obtidos a partir das combinações dos níveis dos atributos incertos mais importantes, que são resultado de uma análise de sensibilidade prévia. Tal combinação é realizada pela técnica da árvore de derivação, sendo que cada ramo é um modelo de simulação (cenário). A quantificação e a redução das incertezas são feitas a partir dos resultados da simulação numérica de fluxo de cada modelo em comparação com os dados de produção.

A função-objetivo (FO) utilizada para a redistribuição das probabilidades entre os níveis dos atributos incertos é a diferença quadrática entre os dados observados e os dados simulados. A FO usada por Moura Filho (2006) e Becerra (2007) foi a produção de água do campo, porém, neste trabalho, é utilizada uma combinação das produções e pressões dos poços, conforme descrito no Capítulo 4.

$$FO = \frac{K}{|K|} K_q, \quad (3.1)$$

onde

$$K = \sum_{t=1}^N AS_t = \sum_{t=1}^N (H_t - S_t) \quad (3.2)$$

e

$$K_q = \sum_{t=1}^N AQ_t = \sum_{t=1}^N (H_t - S_t)^2. \quad (3.3)$$

Nas Equações 3.2 e 3.3,  $N$  é o número de dados ao longo do tempo para cada modelo,  $AS$ , o afastamento simples,  $AQ$ , o afastamento quadrático,  $H$  e  $S$  são os dados de histórico e os dados simulados respectivamente. Sendo assim,  $K$  representa o somatório dos afastamentos e  $K_q$ , o somatório dos afastamentos quadráticos de um modelo, ambos no tempo. Na Equação 3.1, o quociente  $\frac{K}{|K|}$  define o sinal do afastamento entre os dados simulados e o histórico. Se este for positivo, significa que a curva simulada está abaixo do histórico.

A nova probabilidade de acordo com Moura Filho e Becerra (Método 1) para cada nível é dada por:

$$P_n = \frac{\left( \frac{1}{|S_n|} \right) |K_n^{-1}|}{\sum_{n=0}^k \left( \frac{1}{|S_n|} \right) |K_n^{-1}|}, \quad (3.4)$$

onde o subscrito  $n$  assume os valores 0, 1 ou 2, representando os níveis discretizados do atributo e  $k$  é o valor máximo de  $n$ .

Os termos  $K_n$  e  $S_n$  são calculados por:

$$K_n = \left( \sum_{j=1}^{Mn} K_{q_j} \right) \quad (3.5)$$

$$S_n = \frac{\sum_{j=1}^{M_n} FO_j}{\sum_{j=1}^{M_n} |FO|_j}, \quad (3.6)$$

sendo  $M_n$  o número de modelos associado a determinado nível de um atributo, que depende do número de atributos incertos considerados e da quantidade de níveis de cada um deles. O termo  $K_n$  é o somatório dos afastamentos quadráticos dos cenários relacionados a um determinado nível do atributo e  $S_n$  é a simetria destes com relação ao histórico de produção.

O fator  $S_n$  propicia um maior valor de probabilidade para o nível com os modelos melhor distribuídos em volta da curva de histórico (Becerra, 2007). O valor de  $S_n$  varia entre -1 e +1, sendo que  $S_n = 0$  indica uma distribuição das curvas de determinado nível de um atributo com os dados observados situados no centro,  $S_n = -1$  significa que todas as curvas encontram-se acima do histórico, e, portanto,  $S_n = +1$  indica que todas elas encontram-se abaixo do mesmo. Na Equação 3.4, o termo  $1/|S_n|$  é um peso para as curvas de um determinado nível, que foi limitado a um valor máximo de 5 para não atribuir pesos muito elevados a modelos com simetria próxima de zero, ou seja, bem centralizados no histórico. Portanto, com a Equação 3.4 obtêm-se os novos valores de probabilidades de ocorrência de cada nível em função somente dos afastamentos e da distribuição das curvas simuladas com relação ao histórico.

O lado esquerdo da Figura 3.1 exemplifica a distribuição do histórico em relação às curvas dos possíveis modelos do reservatório para um atributo incerto, de um caso com dois atributos discretizados em três níveis. Os pontos em amarelo representam o histórico de produção e as curvas vermelhas, verdes e azuis os 3 níveis do referido atributo. As curvas azuis e vermelhas estão todas localizadas abaixo do histórico, portanto o  $S_n$  desses dois níveis vale +1. Já o nível das curvas verdes possui  $S_n$  entre -1 e +1, pois elas estão distribuídas em torno do histórico de produção. A intenção do método é ilustrada no lado direito da Figura 3.1, onde o nível das curvas em verde recebe a maior probabilidade devido aos modelos correspondentes estarem mais próximos dos dados observados. No sentido oposto, o nível das curvas em vermelho tem sua

probabilidade diminuída; sendo que a linha tracejada representa o valor inicial da probabilidade e a linha cheia, seu valor final para cada nível.

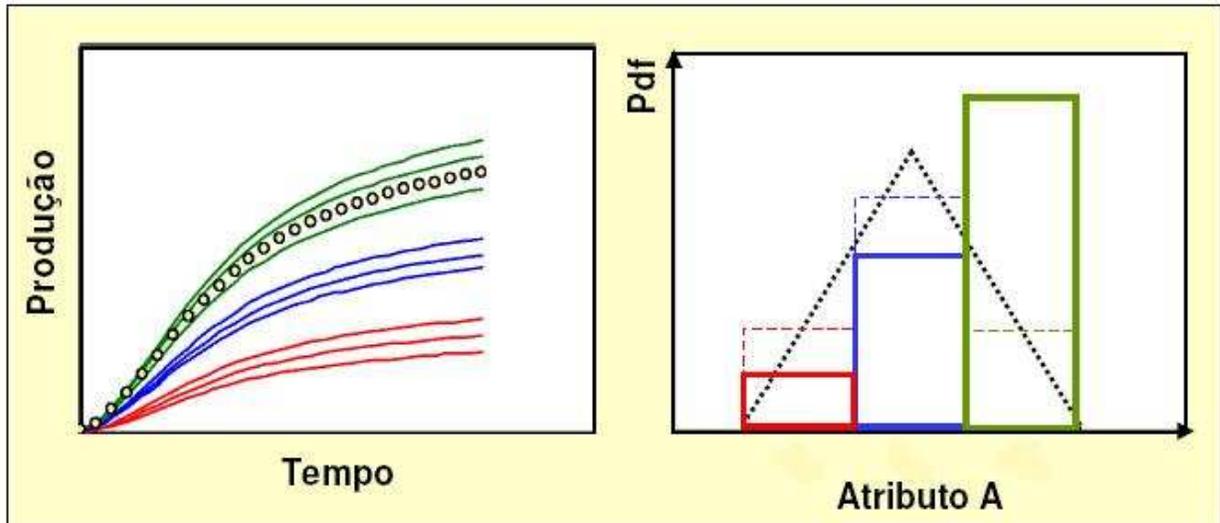


Figura 3.1 – Exemplo de redistribuição de probabilidades (adaptada de Moura Filho, 2006).

Maschio et al. (2010) propõem uma alteração na formulação descrita acima para o cálculo das novas probabilidades, em que os afastamentos quadráticos de cada modelo são invertidos antes de serem somados para constituir o  $K_n$  e o termo da simetria não é utilizado, constituindo o Método 2. Dessa forma, a nova metodologia, utiliza a Equação 3.3 para o cálculo de  $K_q$  e, em seguida, os inverte:

$$K_{iq} = (K_q)^{-F}. \quad (3.7)$$

O fator  $F$  da Equação 3.7 é apenas um ponderador, utilizado para dar maior importância aos modelos com menores afastamentos, ou seja, mais bem ajustados. No trabalho original o valor utilizado foi 2,5.

Para fazer a redistribuição das probabilidades dos atributos é necessário calcular o somatório dos inversos dos afastamentos quadráticos para cada nível ( $K_{in}$ ):

$$K_{in} = \sum_{j=1}^{Mn} (K_{iq})_j, \quad (3.8)$$

sendo  $n = 0, 1$  ou  $2$ , representando os níveis do atributo, respectivamente.



As novas probabilidades para cada nível dos atributos são calculadas pela Equação 3.9 do Método 2:

$$P_n = \frac{|K_{in}|}{\sum_{n=0}^k |K_{in}|}. \quad (3.9)$$

De posse das novas distribuições de probabilidade, os resultados são analisados mediante o uso da curva de incerteza (Figura 2.6). O objetivo é que a curva aproxime-se do eixo central, o qual representa o histórico, centralizando-se em torno dele e diminuindo a dispersão. Os procedimentos explicados acima e que serão aplicados neste trabalho, abordam, de forma prática, um tema complexo.

Outra alteração proposta por Maschio et al. (2010), mas que não é analisada neste trabalho, é a utilização da técnica de Hipercubo Latino para sortear os modelos a serem simulados de acordo com a distribuição de probabilidade do atributo. Isso possibilita a utilização de um número maior de atributos incertos ou de níveis, bem como a incorporação de novos atributos sem a necessidade de simular todas as combinações como na árvore de derivação. A implementação desta técnica é uma recomendação futura, visto que o foco do trabalho foi a melhoria da formulação da metodologia para a aplicação em casos similares a campos reais.

## 4. METODOLOGIA

### 4.1 Metodologia geral

A metodologia para a utilização dos dados de produção observados na redução das incertezas presentes no reservatório está resumida no fluxograma da Figura 4.1, que mostra as etapas realizadas no trabalho.

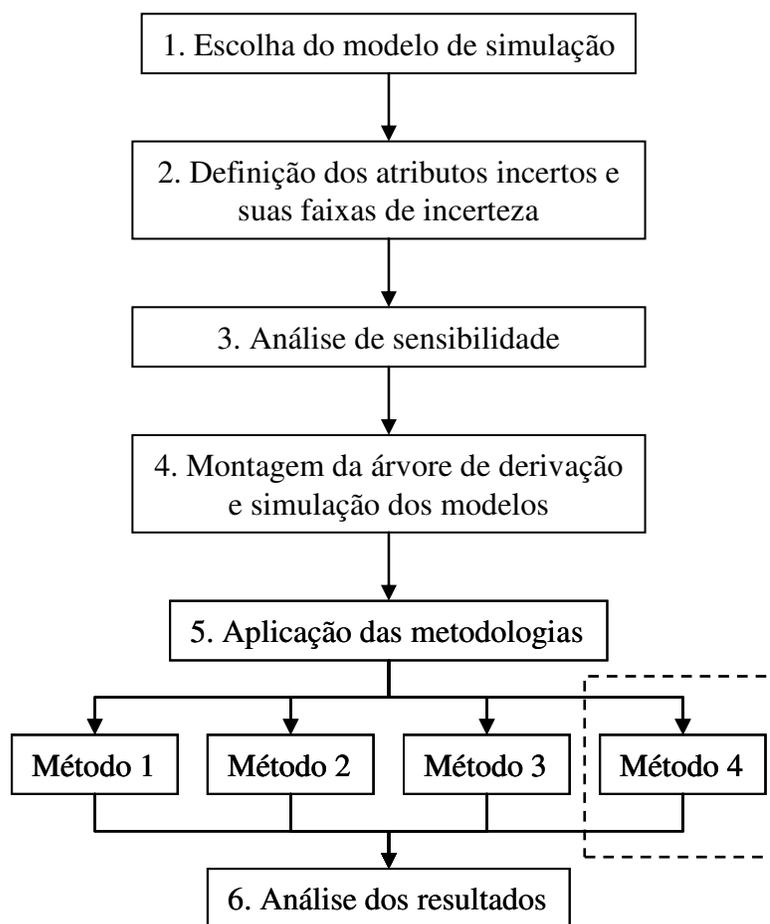


Figura 4.1 – Fluxograma com as etapas do trabalho.

A Etapa 1 consiste na escolha do modelo de reservatórios que é utilizado para a aplicação da metodologia. O caso escolhido é uma adaptação de um caso real, com uma grande quantidade

de poços, muitas falhas e heterogeneidades, sendo bastante similar a um modelo utilizado na indústria.

Na Etapa 2, são mapeados os atributos incertos do campo, os quais são descritos por funções de distribuição de probabilidade, discretizadas em três níveis de incerteza (0, 1 e 2), respeitando suas faixas de variação, conforme mostrado na Figura 2.3. O modelo constituído por todos os atributos no nível 1 (“provável”) é conhecido como o caso base, aquele que se deseja ajustar.

Na Etapa 2 também é gerado o histórico de produção, visto que o modelo é sintético, adaptado de um caso real e não se tem seu histórico medido. Sendo assim, uma combinação dos atributos foi escolhida para gerar o caso de histórico, que, na prática, é desconhecida. O uso de um modelo sintético com resposta conhecida é uma forma de se avaliar melhor a metodologia.

A Etapa 3 resume-se a uma análise de sensibilidade com base no descrito no Item 2.2.1, na qual são estudadas as influências de todos os atributos incertos mapeados na FO considerada, escolhendo-se os atributos críticos. Isto é necessário para viabilizar a aplicação da árvore de derivação, na qual todas as combinações de atributos críticos (cenários) são simuladas.

A Etapa 4 consiste na montagem dos modelos de simulação através da combinação dos diversos níveis dos atributos críticos utilizando-se a técnica de árvore de derivação, explicada no Item 2.2.2 e exemplificada na Figura 2.5. Em seguida, estes diversos cenários criados são simulados no software comercial IMEX® da CMG.

De posse das curvas de produção de todos os modelos criados, inicia-se a Etapa 5 do fluxograma, que é a aplicação dos procedimentos de alteração das probabilidades de ocorrência dos níveis dos atributos em função dos afastamentos entre o histórico e os dados simulados. Os três métodos utilizados, após a aplicação da árvore de derivação, são:

- Método 1: procedimento desenvolvido por Moura Filho (2006) e Becerra (2007), detalhado no Item 3.2.
- Método 2: utilização da formulação proposta por Maschio et al. (2010), descrita no Item 3.2. É feita também uma análise de sensibilidade ao fator  $F$ .

- Método 3: procedimento proposto com o objetivo de eliminar dificuldades encontradas na aplicação dos outros dois métodos num caso complexo e que será melhor detalhado no Item 4.2.
- Método 4: proposta de reaplicação da formulação do Método 3 para refinamento dos resultados, detalhado no Item 4.3.

Para os Métodos 1 e 2, o cálculo do afastamento quadrático do modelo é feito combinando-se diversas funções de ajuste, como por exemplo, vazão de óleo ( $Q_o$ ), vazão de água ( $Q_w$ ) e pressão de fundo ( $PRF$ ) para todos os poços. Estes, em seguida, são combinados formando os conjuntos de poços (blocos) que, por fim, são agrupados, constituindo o afastamento para o campo (módulo da FO), que é a entrada das Equações 3.5 e 3.7 ( $K_q$ ). Isto é feito a partir da seguinte equação:

$$K_{q_{poço, grupo}} = \frac{\sum_{j=1}^m \sum_{t=1}^N (H_t - S_t)_j^2 \cdot W_j}{\sum_{j=1}^m W_j} . \quad (4.1)$$

Para um poço,  $m$  é igual ao número de funções de ajuste a serem combinadas e  $W$  é o peso associado a cada uma delas. Como exemplo, pode-se ter  $m=3$  ( $Q_o$ ,  $Q_w$  e  $PRF$ ) e  $W=1$ , isto é, mesmo peso para todas as variáveis. Dessa forma, o afastamento para um poço é dado pela média aritmética entre os afastamentos das três funções de ajuste consideradas. Já para um grupo de poços (bloco) ou para o campo, o  $m$  equivale à quantidade de poços existente no bloco.

O mesmo raciocínio é utilizado para a obtenção do sinal da FO e da simetria, porém, combinando-se os afastamentos simples:

$$K_{poço, grupo} = \frac{\sum_{j=1}^m \sum_{t=1}^N (H_t - S_t)_j \cdot W_j}{\sum_{j=1}^m W_j} . \quad (4.2)$$

Os procedimentos de cálculo dos diversos métodos foram implementados no programa Matlab® da Mathworks de forma a facilitar a aplicação em outros casos no futuro. O fluxograma da Figura 4.1 foi aplicado a dois casos montados a partir do modelo de simulação escolhido, A e B, os quais são explicados detalhadamente no Capítulo 5.

A Etapa 6 contempla uma comparação das distribuições finais de probabilidade dos atributos para cada método, uma avaliação das curvas de incerteza geradas e do ajuste obtido no campo e poços, uma análise dos principais problemas e dificuldades encontradas, bem como a proposta de melhorias para a adequação do método a qualquer caso. Além disso, também são analisados gráficos de produção e pressão dos poços e do campo dos modelos situados entre os percentis P10 e P90 da curva de incerteza inicial e final avaliando-se a redução do espalhamento das curvas e centralização em torno do histórico (similar a Figura 1.1).

Dentre as curvas presentes nos gráficos anteriores, escolhem-se os modelos representativos, os quais serão utilizados para análises futuras. Para isso, uma faixa ao redor do P50 das curvas de incerteza inicial e final tanto da pressão quanto da vazão de água é filtrada, selecionando-se os modelos comuns as duas curvas. Utiliza-se o P50 como ponto central da faixa escolhida porque a metodologia busca fazer com que a curva de incerteza fique centralizada em torno do histórico, ou seja, que no ponto médio (P50) ela passe pelo eixo nulo. A comparação dos modelos representativos antes e depois da aplicação do método mostra uma diminuição da dispersão das curvas devido à redução das incertezas.

## **4.2 Método 3**

A fórmula proposta para o Método 3 busca combinar o melhor dos dois métodos analisados (Métodos 1 e 2). Ela utiliza a simetria com relação ao histórico do primeiro (Equação 3.6) e a inversão do afastamento quadrático do segundo (Equação 3.7). Neste contexto, as novas probabilidades são calculadas utilizando o somatório dos inversos dos afastamentos quadráticos para cada nível (Equação 3.8) da seguinte forma:

$$P_n = \frac{\left(\frac{1}{|S_n|}\right)^{|K_{in}|}}{\sum_{n=0}^k \left(\frac{1}{|S_n|}\right)^{|K_{in}|}}, \quad (4.3)$$

sendo o subscrito  $n$  igual a 0, 1 ou 2, representando os níveis discretizados do atributo.

A inversão do afastamento quadrático antes de somá-los (proposta do Método 2) é uma forma de dar um peso maior a modelos bem próximos do histórico, porém, a não utilização da simetria pode acabar aumentando a probabilidade de um nível que não englobe o histórico. A importância da simetria está mostrada no exemplo teórico 1 da Figura 4.2, em que os níveis n2 e n3 apresentam afastamentos similares, porém somente o nível n3 engloba o histórico de produção, e, portanto, sua probabilidade deve ser aumentada. Os resultados de cada um dos métodos estão na Tabela 4.1, indicando que o Método 2 apresenta um resultado inconsistente, porém ao combiná-lo com a simetria (Método 3), os resultados ficam coerentes. Isso mostra que a formulação do Método 3 é mais robusta que os demais.

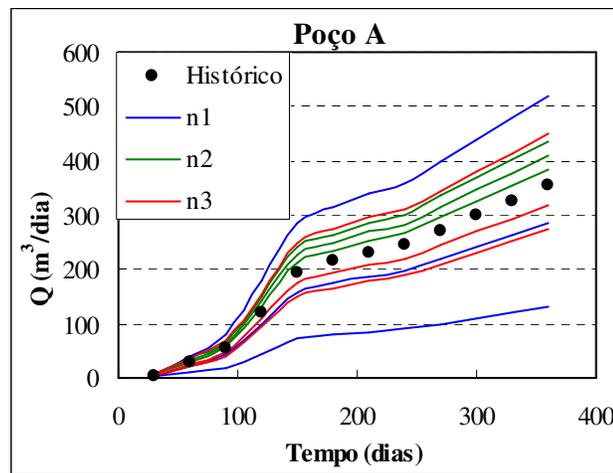


Figura 4.2 – Exemplo teórico 1 para mostrar a importância da simetria.

Tabela 4.1 – Resultados dos três métodos para o exemplo teórico 1.

Método	Probabilidade		
	n1	n2	n3
1	8,7%	21,7%	69,6%
2	1,1%	68,8%	30,1%
3	1,6%	30,9%	67,5%

Outra alteração proposta em relação aos métodos anteriores é não combinar diversas funções de ajuste para o cálculo dos afastamentos e da nova probabilidade, pois isto pode ocasionar problemas ao combinar funções com ordens de grandeza diferentes ou com sinais do afastamento distintos por apresentarem sentidos de crescimento opostos.

Para o primeiro problema, o exemplo teórico 2, com dois poços produzindo vazões de água em níveis bastante diferentes, mostra as diferenças no resultado da redistribuição de probabilidade para os três Métodos. De acordo com a Figura 4.3, o Poço A produz uma maior quantidade de água que o B e o nível do atributo que melhor descreve seu histórico é o n1. Já para o Poço B, o nível n2 é o que representa bem os dados de produção.

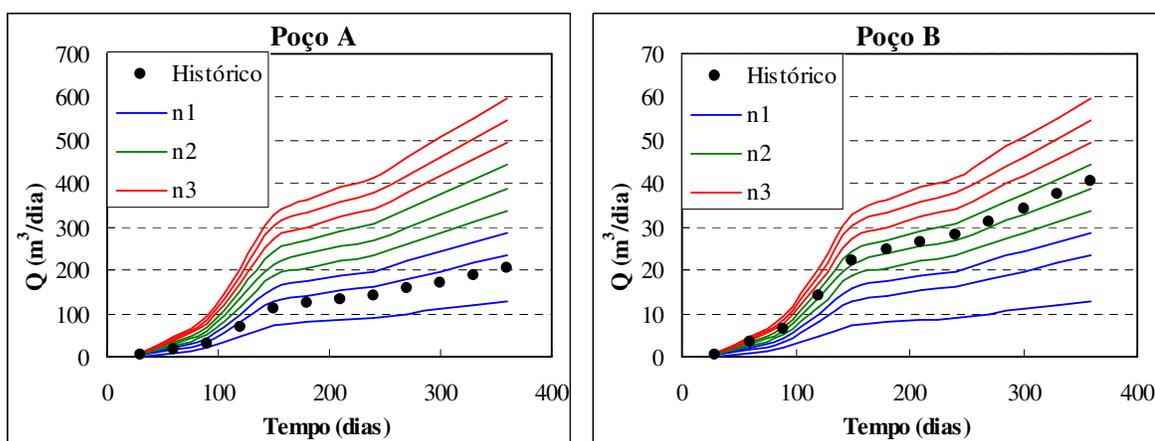


Figura 4.3 – Exemplo teórico 2 para mostrar as diferenças na aplicação dos 3 Métodos quanto a ordem de grandeza das funções.

Os resultados para a aplicação dos Métodos estão na

Tabela 4.2, sendo que os Métodos 1 e 2, que combinam os afastamentos dos dois poços para gerar as novas probabilidades, dão prioridade ao nível que melhor representa o Poço A (n1), pois sua produção é bem superior a do Poço B. Já o Método 3, que combina através de uma média as redistribuições individuais de cada um dos poços, gera como resultado uma distribuição em que os níveis n1 e n2 têm a mesma probabilidade de ocorrência, o que é mais coerente com os gráficos da Figura 4.3. Neste caso, foi utilizada a média aritmética.

Tabela 4.2 – Resultados da distribuição de probabilidades para o exemplo teórico 2.

Método	Probabilidade		
	n1	n2	n3
1	96,7%	2,5%	0,8%
2	99,8%	0,2%	0,0%
3	50%	50%	0,0%

O segundo problema citado acima é mostrado no exemplo teórico 3 em que são combinadas a produção de água e a pressão de um poço (Figura 4.4) para recalculer a probabilidade de um atributo. No caso da pressão, o nível n2 é o que melhor representa o histórico e no caso da vazão, os níveis n2 e n3 apresentam a mesma simetria, sendo que o n2 possui afastamentos um pouco menores. Desta forma, ao se combinar as duas funções, o nível que deve ter a probabilidade aumentada é o n2.

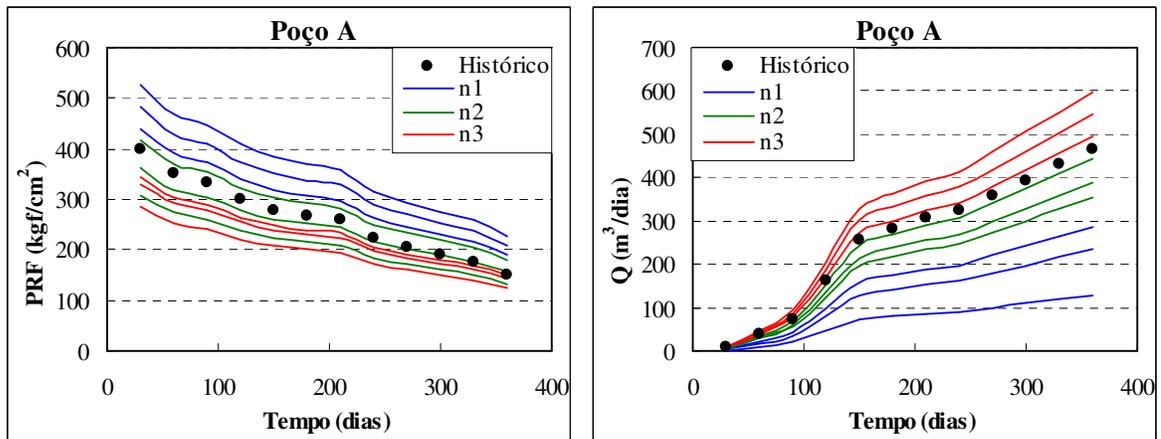


Figura 4.4 – Exemplo teórico 3 para mostrar as diferenças na aplicação dos 3 Métodos com funções de crescimento diferentes.

A Tabela 4.3 apresenta os resultados para a aplicação dos três Métodos no exemplo teórico 3. Observa-se que os Métodos 1 e 2 geram resultados bastante diferentes, sendo que o primeiro não gera respostas consistentes. Isto acontece porque ao se combinar as funções, a simetria não fica bem representada. Já o Método 3, mesmo utilizando a simetria, resulta em uma redistribuição de probabilidades adequada, coerente com a Figura 4.4. Isso acontece porque ele faz a redistribuição de probabilidade para cada função, ou seja, calcula os afastamentos, simetria e a nova probabilidade dos atributos usando cada uma das funções de forma independente e, em seguida, combina as redistribuições de probabilidade, o que o torna mais robusto. No trabalho, as funções utilizadas são a vazão de água ( $Q_w$ ) e a pressão de fundo ( $PRF$ ) dos poços, visto que a



vazão de óleo ( $Q_o$ ) é a condição imposta para a realização do ajuste de histórico, a qual deve ser honrada pelo modelo.

Tabela 4.3 – Resultados da distribuição de probabilidades para o exemplo teórico 3.

Método	Probabilidade		
	n1	N2	n3
1	4,8%	24,6%	70,6%
2	0,0%	70,7%	29,3%
3	0,7%	78,4%	20,9%

Conforme descrito acima, as redistribuições das probabilidades dos atributos para o reservatório como um todo são obtidas combinando-se as redistribuições individuais de cada uma das funções através de uma média, gerando duas variações do método:

- Método 3.1: utiliza a média aritmética simples das redistribuições individuais.
- Método 3.2: utiliza uma média aritmética ponderada pela sensibilidade da função ao atributo incerto considerado, dessa forma, as funções mais influenciadas pela variação do atributo terão maior peso no cálculo da probabilidade dele. Para isso, são calculados os índices de sensibilidade (IS) das funções de ajuste com relação a cada atributo incerto, conforme descrito no Item 2.2.1. Estes índices são os pesos usados na média ponderada em questão. Dessa forma, são obtidos valores de IS para  $Q_w$  e  $PRF$  de cada poço.

Além disso, é feita uma análise da influência dos parâmetros  $F$  (fator de inversão do afastamento) e  $1/|S_n|_{máximo}$  (valor máximo de simetria aceitável) no cálculo da distribuição de probabilidades com base nos dados observados, com o objetivo de calibrar a fórmula proposta.

### 4.3 Método 4

A fim refinar os resultados, propõe-se o Método 4, que é simplesmente uma aplicação iterativa do Método 3, até a obtenção de resultados adequados de acordo com os critérios do engenheiro responsável pela análise. Isto é feito com base no fluxograma da Figura 4.5 (que é uma ampliação da área tracejada da Figura 4.1), sendo feita uma redefinição dos valores dos níveis dos atributos para a nova aplicação do método, a fim de melhorar os resultados obtidos. No trabalho em questão, foi feita somente uma iteração a mais para cada um dos casos, exibindo a

melhoria na resposta. Este método só necessita ser aplicado quando os resultados pelo Método 3 não são satisfatórios.

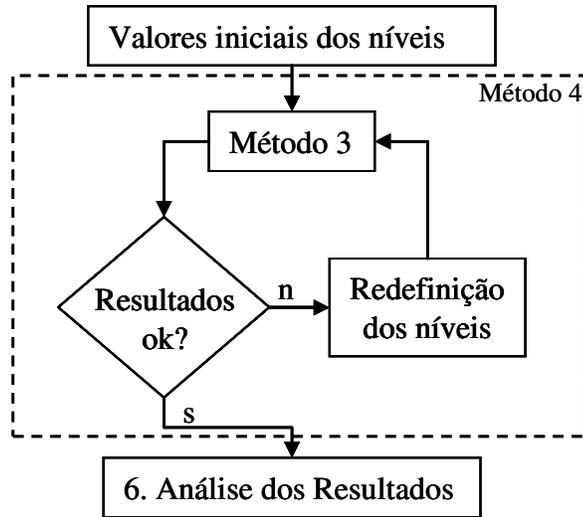


Figura 4.5 – Fluxograma para refinamento dos resultados – Método 4.

A redefinição dos níveis dos atributos incertos para aplicação do Método 4 é feita com base nas probabilidades obtidas da aplicação anterior e nos níveis iniciais de forma similar a mostrada por Becerra (2007). Um exemplo do que é feito para os atributos cujos níveis são valores numéricos está mostrado na Figura 4.6 sendo o novo nível provável calculado por:

$$A_1^N = \frac{A_0 \cdot P[A_0] + A_1 \cdot P[A_1]}{P[A_0] + P[A_1]} \quad (4.4)$$

Os novos limites superior e inferior são obtidos conforme mostrado abaixo (Equações 4.5 e 4.6). Com o cálculo do novo nível mais provável e dos limites, o novo nível pessimista e o otimista  $(A_0^N \text{ e } A_2^N)$  podem ser calculados em conformidade com a distribuição triangular.

$$L_s^N = A_0 + (A_1 - A_0) \cdot P[A_0] \quad (4.5)$$

$$L_i^N = L_i + (A_0 - L_i) \cdot (1 - P[A_0]) \quad (4.6)$$

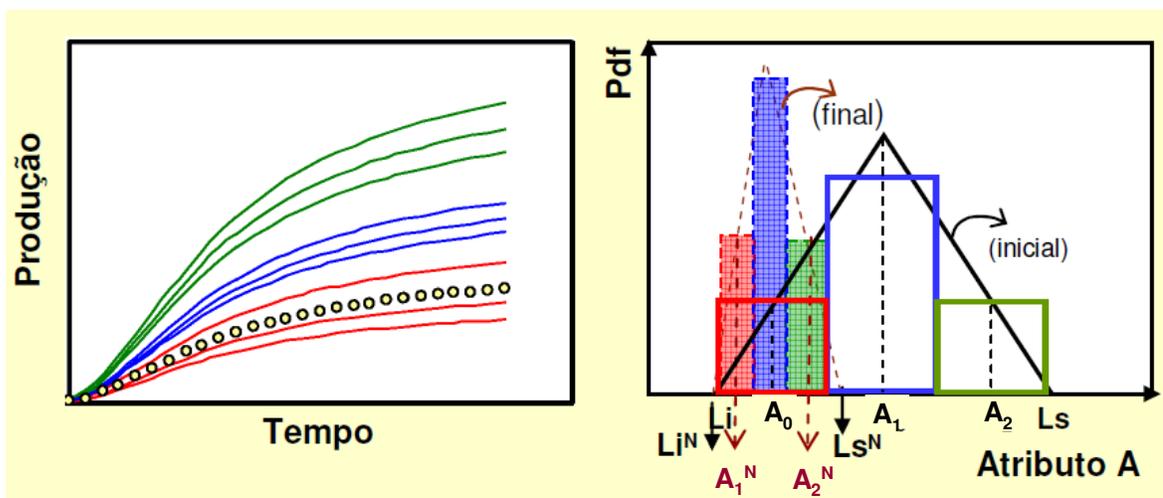


Figura 4.6 – Exemplo de redefinição dos valores dos níveis dos atributos (adaptado de Moura Filho, 2006).

O Anexo 1 do trabalho de Becerra (2007) exemplifica as diferentes situações encontradas para o cálculo dos novos valores dos níveis. Para atributos com valores discretos como diferentes modelos de falhas e tabelas de permeabilidade relativa e PVT, os novos níveis são definidos de forma a se aproximarem do nível com maior probabilidade da etapa anterior através de interpolações. Além disso, atributos podem ser eliminados ou acrescentados na etapa de redefinição dos níveis. Um exemplo disso ocorre quando um dos níveis de um atributo discreto tem sua probabilidade aumentada para valores bem altos, significando que ele deve ser o nível correto e, portanto, os demais níveis podem ser descartados. Isso pode ocorrer com o atributo PVT, onde cada nível é uma tabela diferente proveniente de análises de laboratório, não sendo muito coerente criar tabelas por não fazer sentido físico.

Com a redefinição dos níveis, ao aplicar novamente a formulação do Método 3, os resultados encontrados ficam melhores, com curvas mais próximas e similares ao histórico de produção, englobando-o. A replicação do Método 3 pode ser feita diversas vezes, a critério do engenheiro responsável pela análise, pois cabe a ele julgar se os resultados já estão adequados ou não para o trabalho a ser realizado. A única desvantagem é o grande aumento da quantidade de simulações, exigindo uma maior demanda computacional.

## 5. APLICAÇÃO

A metodologia de redução de incertezas a partir dos dados de histórico foi aplicada a um modelo sintético, adaptado de um caso real de um típico campo marinho da Bacia de Campos. O campo possui três blocos, com um desenvolvimento em módulos de produção independentes, cada um com sua própria plataforma. O modelo escolhido, por ser complexo e bastante heterogêneo permite a validação das metodologias para seu posterior uso em casos reais da indústria.

### 5.1 Modelo do Reservatório

O caso complexo utilizado para a aplicação dos métodos descritos anteriormente consiste de um modelo numérico de simulação constituído por uma malha do tipo *corner point*, possuindo 63910 células (83 x 55 x 14) com 49346 células ativas. A parte mais alta do reservatório está situada na região central conforme pode ser visto na Figura 5.1.

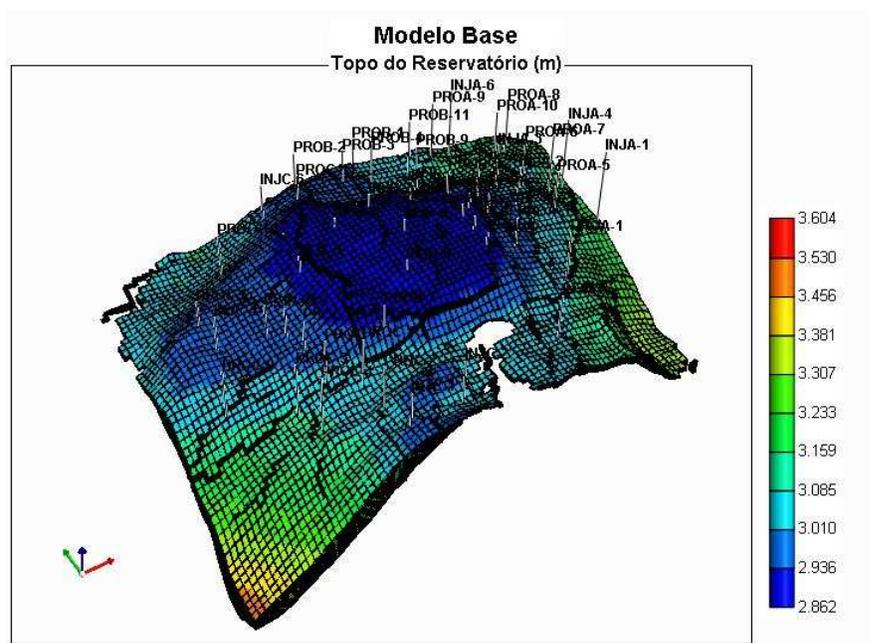


Figura 5.1 – Topo do reservatório do Modelo Base.

O modelo base é composto por três blocos (A, B e C) separados por duas falhas norte-sul, cujas transmissibilidades são incertezas, como ilustrado na Figura 5.2. Na vertical, ele está dividido em duas zonas: superior, até a camada 9 e inferior da camada 10 em diante. O mapa 3D da Figura 5.3 mostra a porosidade do modelo de fluxo. O valor médio da porosidade do reservatório é 21% e sua distribuição é dada pelo histograma da Figura 5.4.

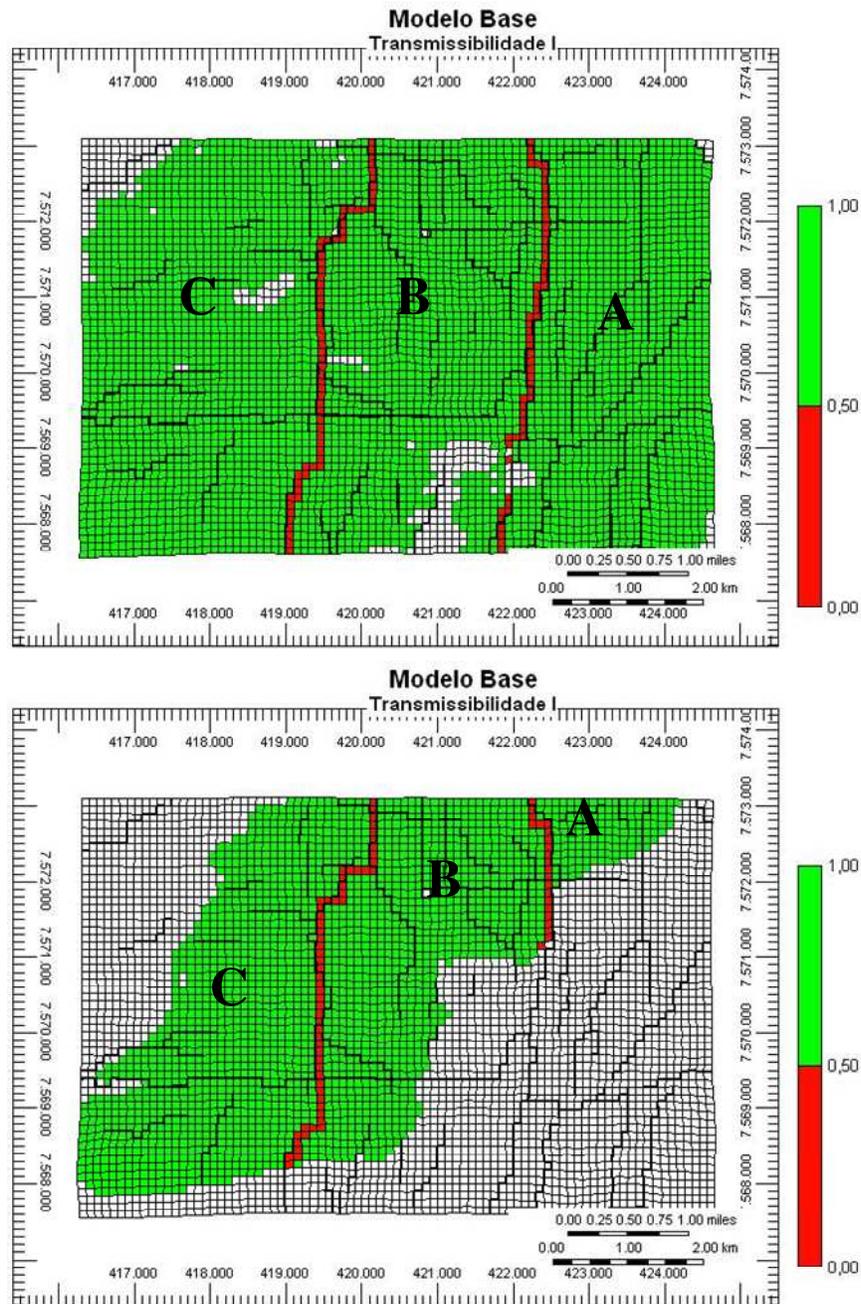


Figura 5.2 – Divisão do modelo em três blocos nas zonas superior e inferior.

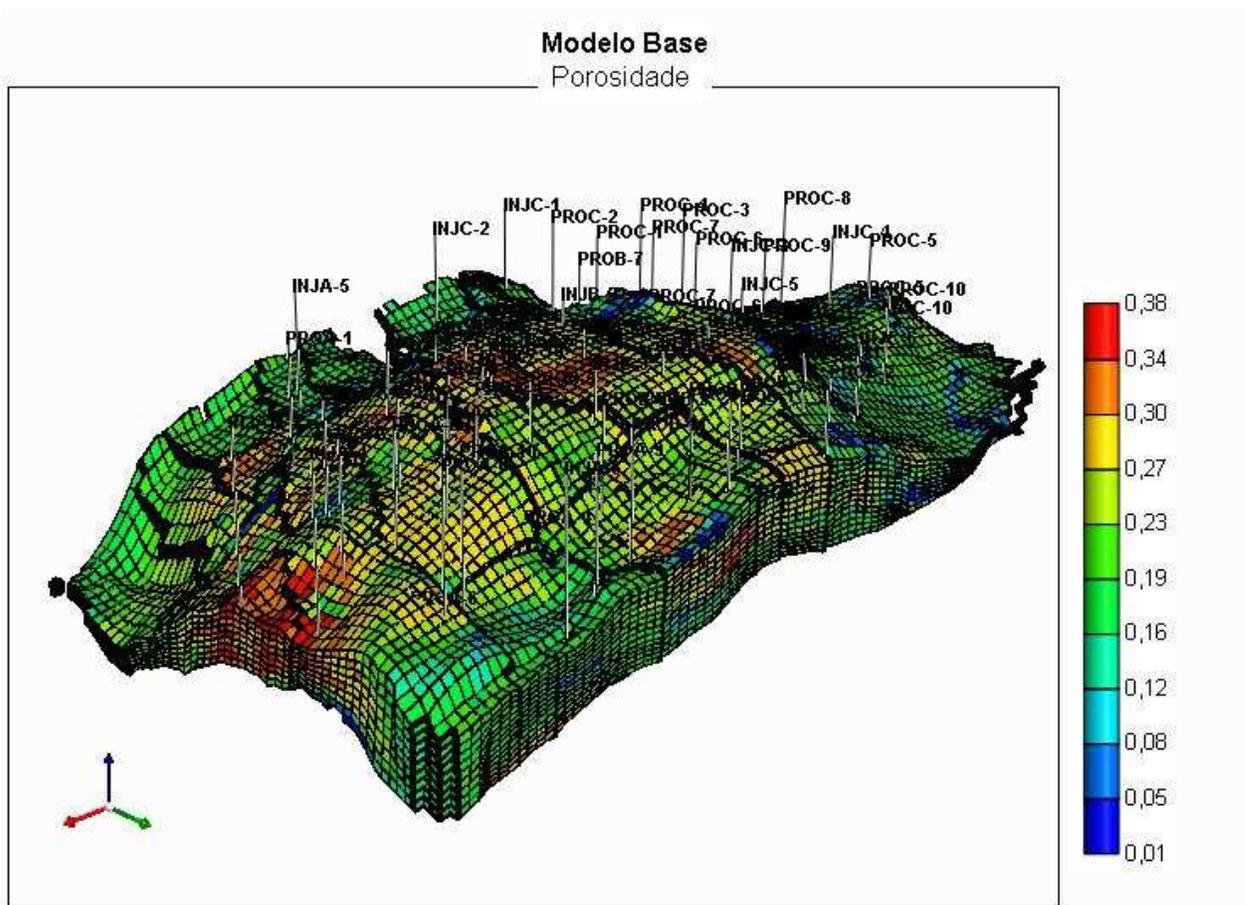


Figura 5.3 – Mapa 3 D da porosidade do modelo de simulação

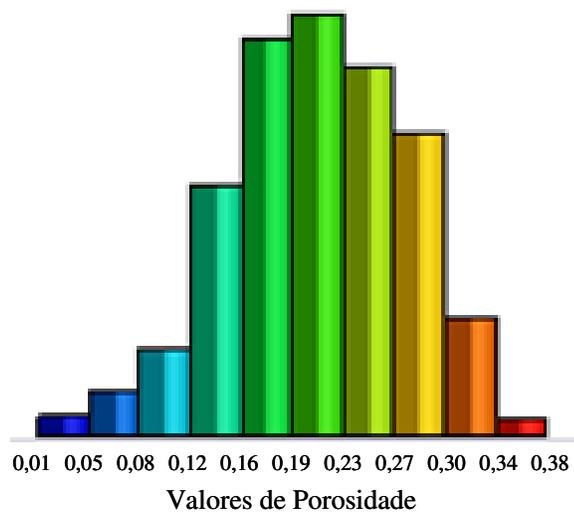


Figura 5.4 – Histograma com a distribuição dos valores de porosidade do modelo base.

A permeabilidade média do modelo é de cerca de 1100 mD, sendo que a zona superior possui rochas com permeabilidades médias menores que às rochas da zona inferior, além de apresentar mais intercalações, como pode ser visto nos mapas da Figura 5.5. As Figuras 5.6 e 5.7 mostram seções verticais do modelo de fluxo ilustrando algumas de suas propriedades, como permeabilidade e razão espessura porosa (*NTG*), evidenciando as diferenças entre as duas zonas.

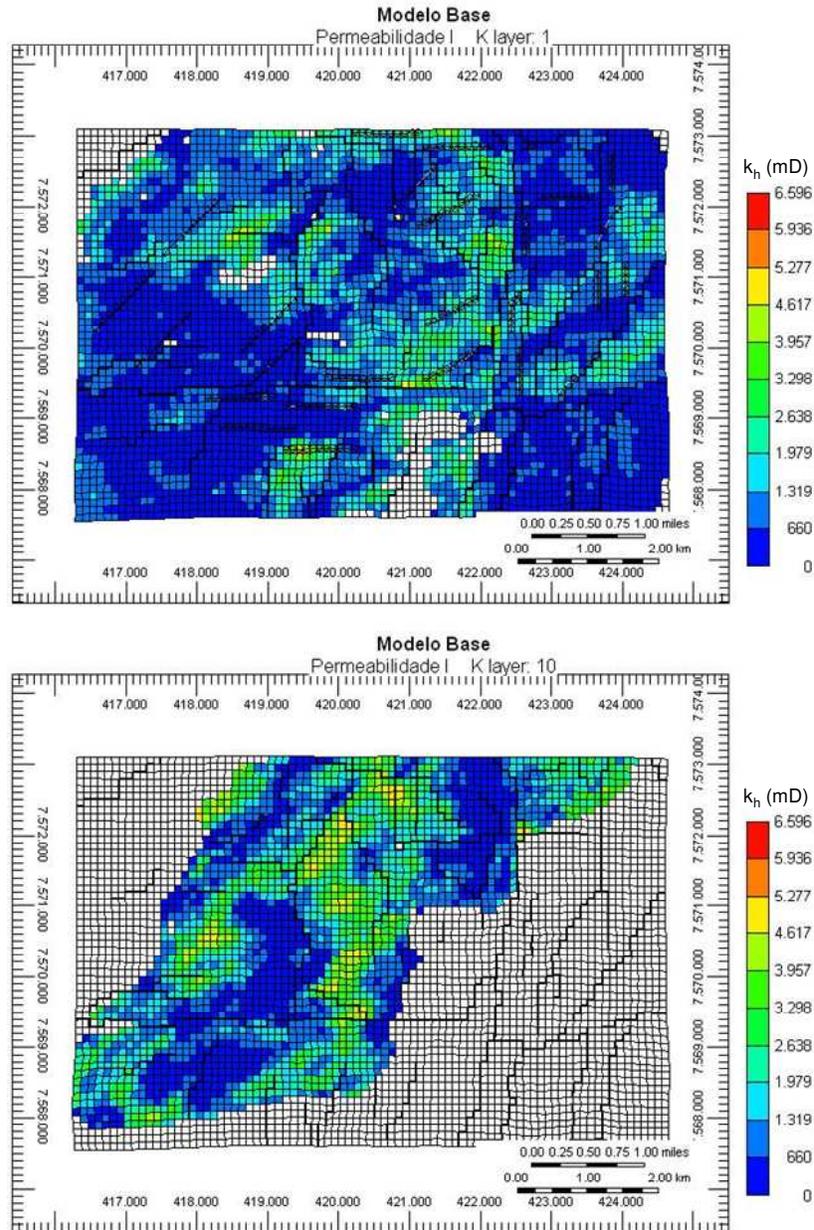


Figura 5.5 – Mapa de permeabilidade horizontal das camadas 1 (zona superior) e 10 (zona inferior).

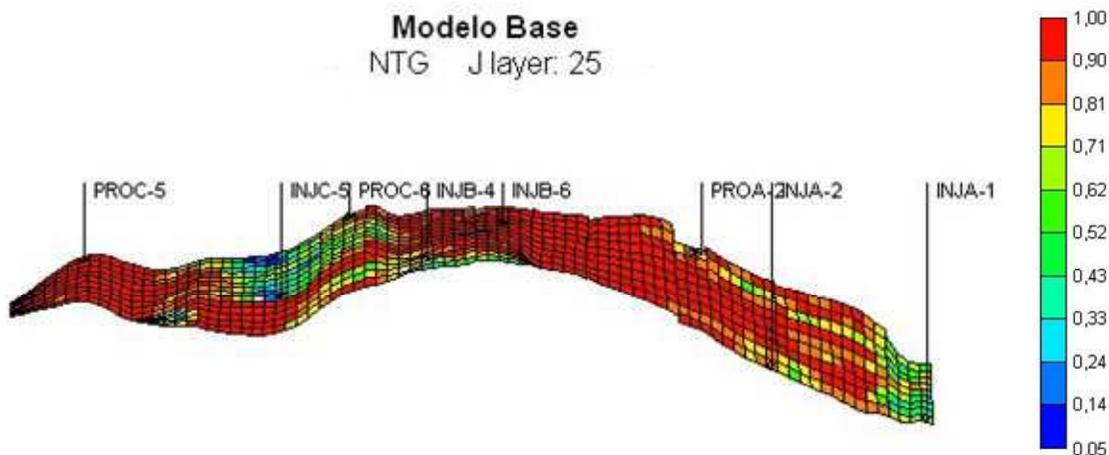


Figura 5.6 – Seção transversal J mostrando a razão *NTG*.

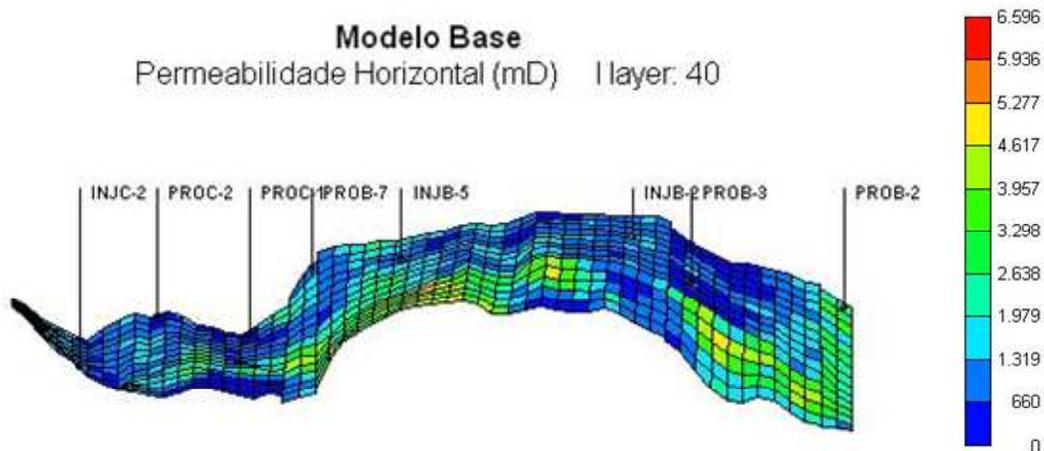


Figura 5.7 – Seção transversal I ilustrando a permeabilidade horizontal.

As maiores espessuras porosas com óleo (*net pay*) estão situadas na região do Bloco A, como pode ser visto na Figura 5.8. A PVT do modelo base possui um óleo pesado de 19 °API com uma pressão de saturação de 294,1 kgf/cm<sup>2</sup> e uma viscosidade de 7 a 13 cP. As pressões iniciais do modelo estão representadas na Figura 5.9. A pressão original do campo é de 331,64 kgf/cm<sup>2</sup> na profundidade de referência de 3150 m, não havendo gás livre no reservatório (Figura 5.10). Há dois contatos óleo-água diferentes no campo, 3229 m no Bloco A e 3167 m nos demais blocos, o que indica que a falha entre os Blocos A e B deve ser selante.



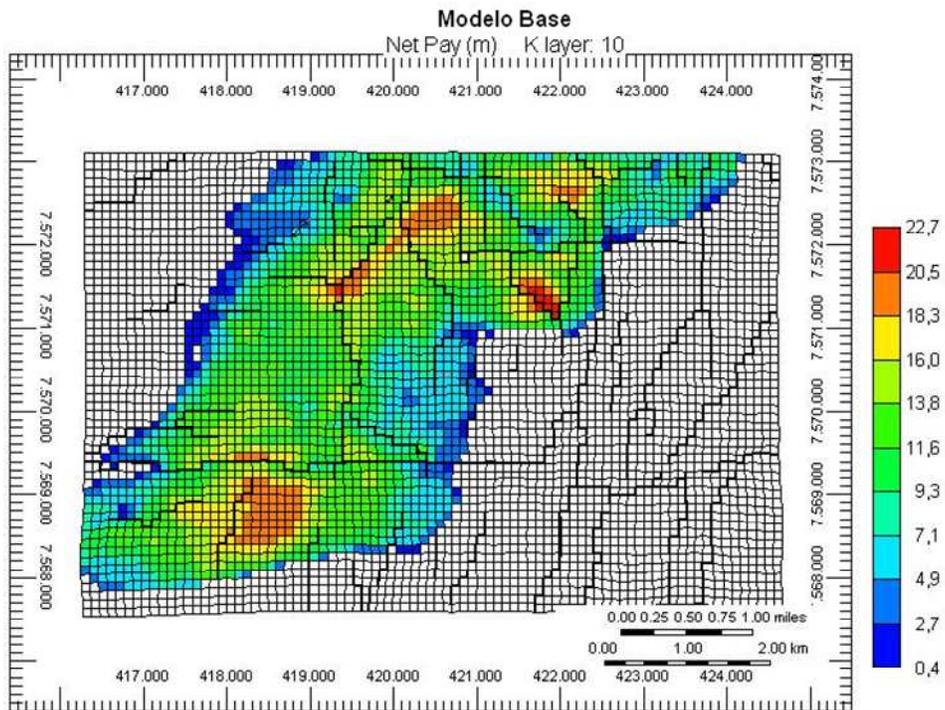
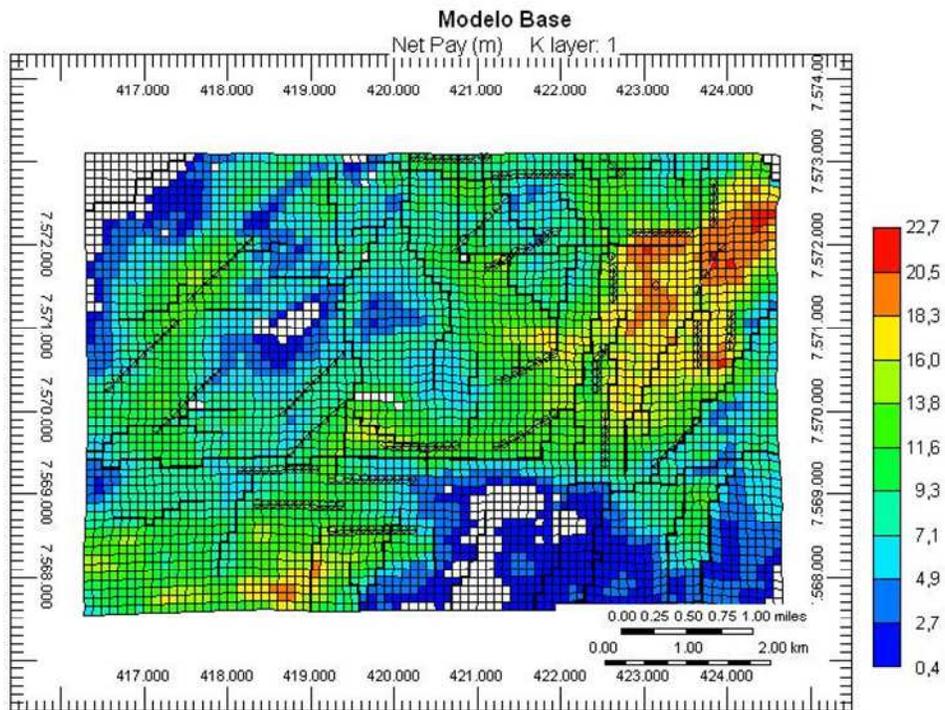


Figura 5.8 – Mapa da espessura porosa das zonas superior e inferior.

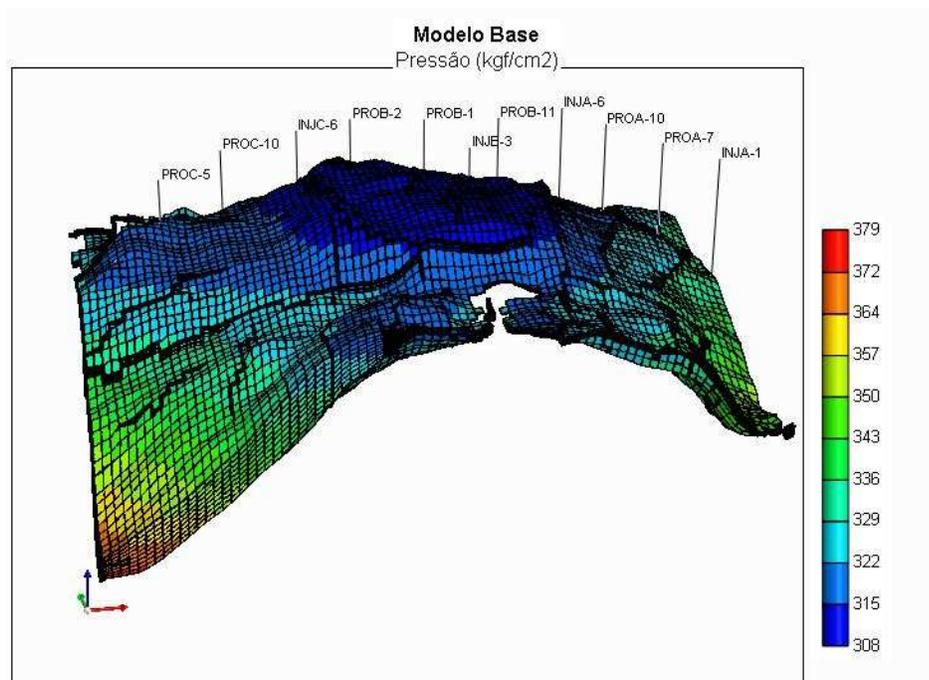


Figura 5.9 – Mapa 3D com a pressão original do reservatório.

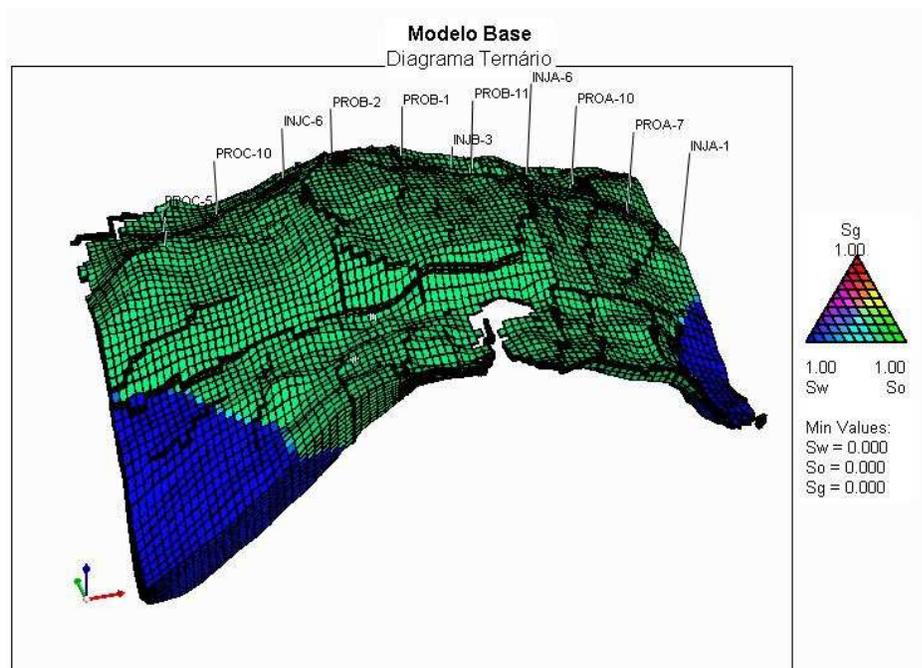


Figura 5.10 – Diagrama ternário mostrando as fases óleo e água.

O volume de óleo *in situ* (VOIS) do caso base do reservatório é cerca de 537 milhões de m<sup>3</sup>, distribuídos entre os blocos conforme a Tabela 5.1. Devido à complexidade do campo, seu plano de desenvolvimento prevê a produção em três módulos independentes, sendo o Bloco A o

primeiro a entrar em operação, seguido do B e do C, estando a quantidade de poços de cada um deles também mostrada na Tabela 5.1. Nos três blocos, a injeção de água é utilizada como mecanismo de recuperação secundária, mantendo a pressão do reservatório, com o objetivo de aumentar a recuperação de óleo.

Tabela 5.1 - Volume de óleo *in situ* e quantidade de poços por bloco.

<b>Bloco</b>	<b>VOIS (MM m<sup>3</sup>)</b>	<b>Produtores</b>	<b>Injetores</b>
Bloco A	162	10	6
Bloco B	227	11	6
Bloco C	148	11	6
<b>Campo</b>	<b>537</b>	<b>32</b>	<b>18</b>

## 5.2 Incertezas do Modelo

Os atributos incertos do reservatório são mapeados a partir deste modelo base, constituído pelos valores mais prováveis das incertezas. Os intervalos de incerteza dos atributos são definidos pelos seus limites e discretizados em 3 níveis com uma distribuição inicial de probabilidade uniforme, ou seja, a probabilidade de cada nível é de 33,33%. Dentre os atributos analisados estão aqueles relacionados ao modelo geológico e de fluxo que teriam relevância no ajuste de histórico de um reservatório de petróleo.

A Tabela 5.2 mostra os atributos identificados e que serão submetidos a uma análise de sensibilidade para a escolha dos 5 mais críticos para o ajuste. É importante ressaltar que neste trabalho não foi feito uma análise detalhada para a definição dos intervalos de incerteza dos atributos, eles foram escolhidos dentro de uma faixa usual com base no modelo de simulação de fluxo já construído. Porém, na prática, eles devem ser definidos por meio de um estudo de caracterização do reservatório anterior, feito por uma equipe multidisciplinar (geofísicos, geólogos e engenheiros). Esta simplificação foi feita porque o tratamento e parametrização dos atributos incertos não é o foco deste trabalho.

Os atributos porosidade e permeabilidade são avaliados por multiplicadores, isto é, com base em uma única distribuição criada da geoestatística são aplicados fatores que aumentam ou diminuem os valores médios das propriedades. Como o Bloco A é o primeiro a entrar em produção, possuindo mais dados medidos, ele tem intervalos de incerteza menores com relação

aos outros dois. A permeabilidade horizontal das duas zonas é tratada de forma diferenciada porque a zona inferior apresenta valores médios mais elevados que a zona superior. A transmissibilidade vertical é analisada pela razão entre as permeabilidades horizontal e vertical.

Tabela 5.2 - Atributos incertos do reservatório.

Atributo	Nível 0	Nível 1	Nível 2	Descrição
PhiA	*0,82	*1	*1,1	Multiplicador da porosidade do Bloco A
PhiB	*0,8	*1	*1,3	Multiplicador da porosidade do Bloco B
PhiC	*0,75	*0,9	*1,25	Multiplicador da porosidade do Bloco C
kA	*0,5	*1	*1,5	Multiplicador da permeabilidade do Bloco A na zona superior
kB	*0,7	*2,5	*4	Multiplicador da permeabilidade do Bloco B na zona superior
kC	*0,6	*1,5	*3	Multiplicador da permeabilidade do Bloco C na zona superior
ki	*0,5	*1	*1,5	Multiplicador da permeabilidade zona inferior
kv	0,05	0,18	0,33	Razão entre permeabilidade vertical e horizontal
FAB	0	0,1	1	Transmissibilidade da Falha A-B
FBC	0	0,1	1	Transmissibilidade da Falha B-C
Falhas	Modelo 0	Modelo 1	Modelo 2	Modelos de falhas
PVT	PVT0	PVT1	PVT2	Tabelas de PVT
krw	krw0	krw1	krw2	Curva de permeabilidade relativa à água

As transmissibilidades das falhas principais, falhas norte-sul entre os blocos (A-B e B-C), são tratadas cada uma como uma incerteza, podendo ser selantes (fechadas), parcialmente ou totalmente abertas, correspondendo aos níveis 0, 1 e 2, respectivamente. No atributo incerto Falhas, cada nível corresponde a um modelo de falhas internas aos Blocos A, B e C. O nível 0 é o modelo sem falhas internas, o provável (1) com poucas, e o nível 2 com muitas falhas internas, como mostrado na Figura 5.11.

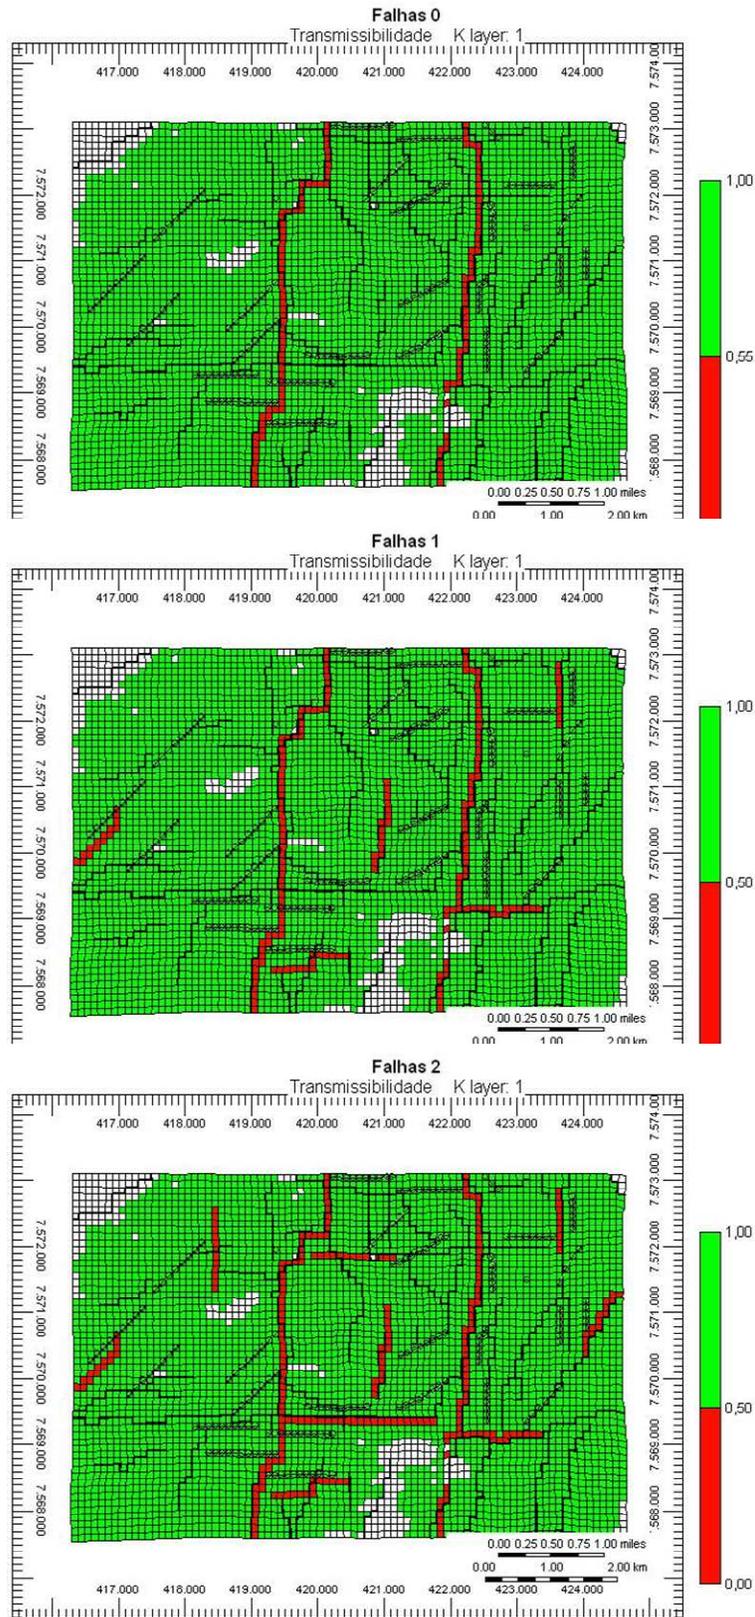


Figura 5.11 – Três modelos de falhas internas utilizados.

No caso da PVT, foram adotadas três tabelas diferentes para cada um dos níveis de incerteza considerados. A pressão de saturação de cada uma delas está mostrada na Tabela 5.3, bem como os valores de razão de solubilidade e viscosidade nesta pressão. O mesmo se aplica à permeabilidade relativa, em que cada nível corresponde a uma curva distinta de permeabilidade relativa à água, mostradas na Figura 5.12.

Tabela 5.3 – Dados de PVT utilizados.

PVT	Nível 0	Nível 1	Nível 2
$P_{sat}$ (kgf/cm <sup>2</sup> )	301,0	294,1	271,4
$R_S @ P_{sat}$ (sm <sup>3</sup> /sm <sup>3</sup> )	102,2	79,2	66,0
$\mu_o @ P_{sat}$ (cp)	3,2	7,7	13,7
° API do óleo	21	19	18

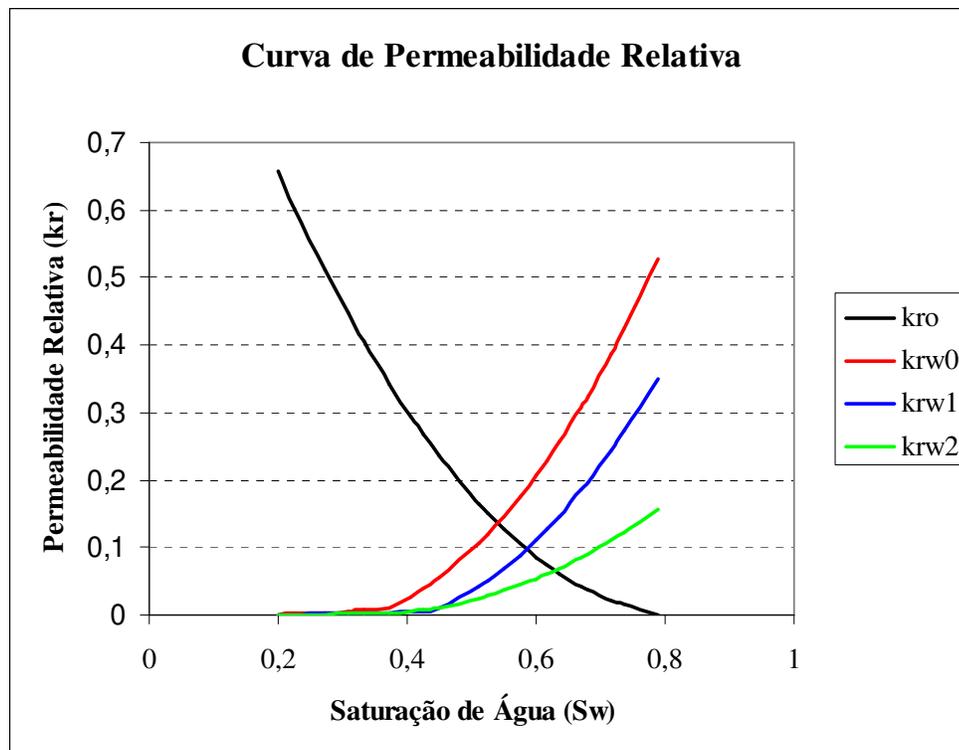


Figura 5.12 – Curvas de Permeabilidade relativa à água de cada nível.

### 5.3 Modelo de Histórico e Casos tratados

Para o desenvolvimento da metodologia é necessário conhecer o histórico de produção do campo, e como não se tem os dados reais medidos, foram geradas curvas sintéticas de histórico a partir de um cenário contido dentro das incertezas analisadas. O modelo de simulação utilizado para gerar o histórico de cerca de 10 anos está na Tabela 5.4. O fato de se criar o histórico a partir de um modelo é importante para validar a metodologia neste caso complexo, pois, desta forma, a redistribuição de probabilidades que deve ser obtida é mais ou menos conhecida.

Tabela 5.4 - Valores dos atributos incertos utilizados para gerar o histórico de produção.

Atributos	Caso histórico
PhiA	*0,82
PhiB	*1,15
PhiC	*0,9
kA	*1,4
kB	*2,2
kC	*0,8
ki	*0,9
kv	0,3
FAB	0
FBC	0,2
Falhas	Modelo 1
PVT	PVT2
krw	krw1

De posse do modelo base, do histórico a ser considerado e das incertezas foi feita a análise de sensibilidade para a escolha dos 5 atributos críticos, isto é, aqueles que mais afetam a FO escolhida (vazão de água e pressão dos poços), para a aplicação da metodologia analisada em dois casos:

- Caso A: considera o modelo base com todos os atributos no nível mais provável e, na aplicação, os cinco atributos críticos são variados nos três níveis e os demais atributos (oito) permanecem mapeados neste valor provável. Assim, existe uma combinação destes cinco atributos com resultados bem próximos ao histórico, esperando-se obter uma nova distribuição de probabilidades com maiores valores para estes níveis dos atributos.
- Caso B: como o modelo é bastante heterogêneo, deve ser utilizado o maior número de atributos incertos possível para gerar as novas distribuições de probabilidade, porém a

aplicação da árvore de derivação fica inviável. Devido a esta dificuldade, o segundo caso foi criado a partir do caso base anterior, tendo-se somente os cinco atributos críticos como incerteza e os demais fixados no valor utilizado para gerar o histórico de produção. Desta forma, todas as incertezas existentes são utilizadas para a redistribuição de probabilidades, havendo um modelo com resultados praticamente idênticos aos dados medidos, fato que será útil na calibração das fórmulas.

O caso B não é prático, ele foi criado somente para analisar a formulação dos métodos de maneira mais precisa, indicando que o principal problema estava na quantidade de atributos e seus intervalos de incerteza e não na evolução das fórmulas.

#### **5.4 Modelo Inicial (Base)**

A análise dos resultados da simulação do caso base permite avaliar o desajuste do modelo tratado. A Figura 5.13 mostra que o modelo simulado honra os dados impostos de vazão de óleo para o campo, porém a vazão de água encontra-se bastante desajustada, com a chegada de água (*breakthrough*) ocorrendo depois do observado e com uma produção de água bem menor que a real.

Os dados de pressão também apresentam grandes diferenças com relação aos valores medidos, estando o modelo base mais pressurizado, principalmente após alguns anos de produção, conforme pode ser visto na Figura 5.14.



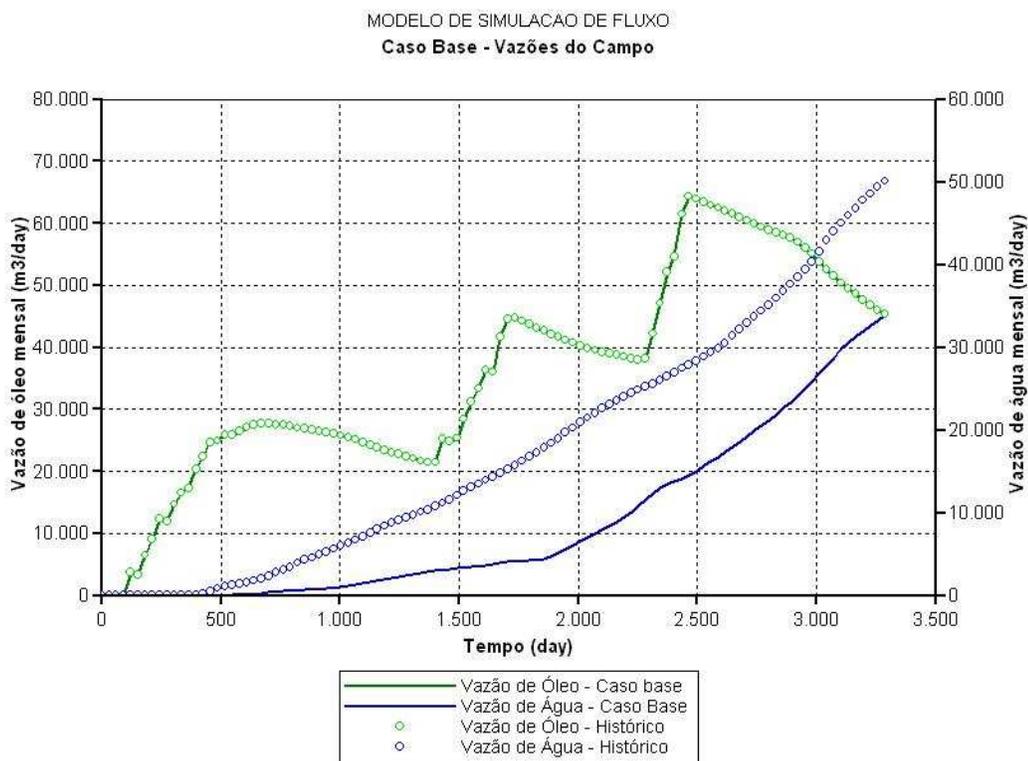


Figura 5.13 – Vazões de Óleo e Água do campo para o caso base e histórico.

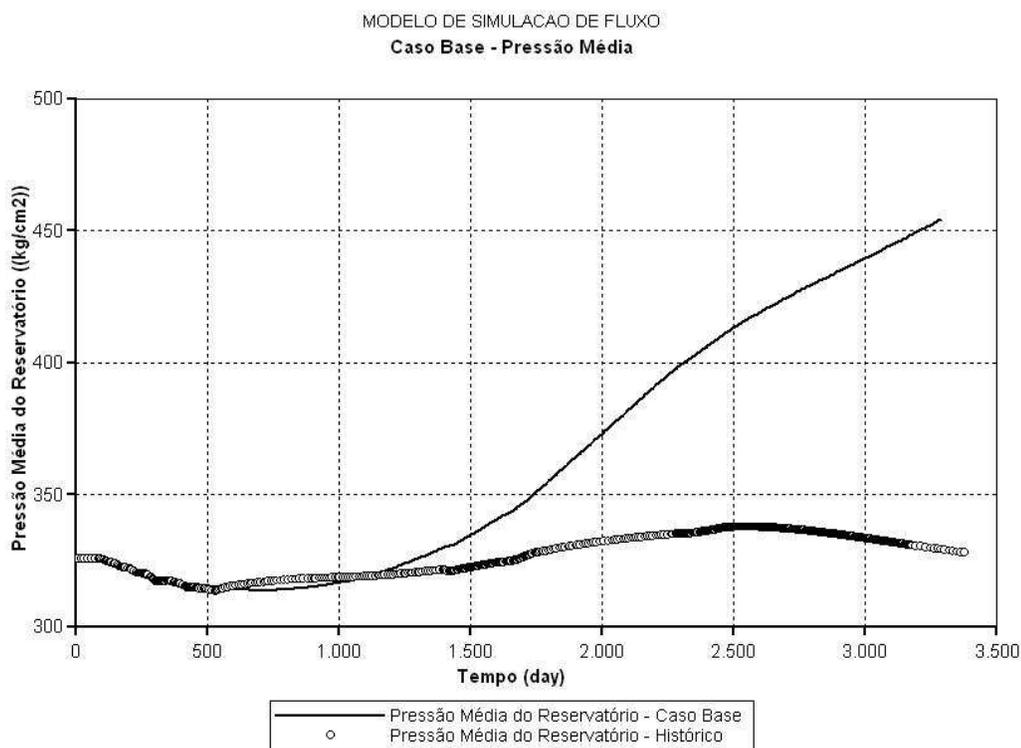


Figura 5.14 – Pressão Média do campo para o caso base e histórico.

Para os poços do Bloco A e do Bloco C o comportamento da vazão de água é bastante similar ao do campo, como pode ser visto nas Figuras 5.15 e 5.16 para os poços PROA-6 e PROC-4 respectivamente. Já para o Bloco B grande parte dos poços apresenta comportamento contrário, com a água atingindo os poços produtores nos dados simulados do caso base mais rapidamente que no histórico, como mostrado no exemplo do poço PROB-1 na Figura 5.17. Vale ressaltar que todos os poços conseguem produzir a vazão de óleo imposta pelo histórico de produção. Os poços produtores são nomeados com a sigla PRO, seguida do bloco a que pertencem e um número.

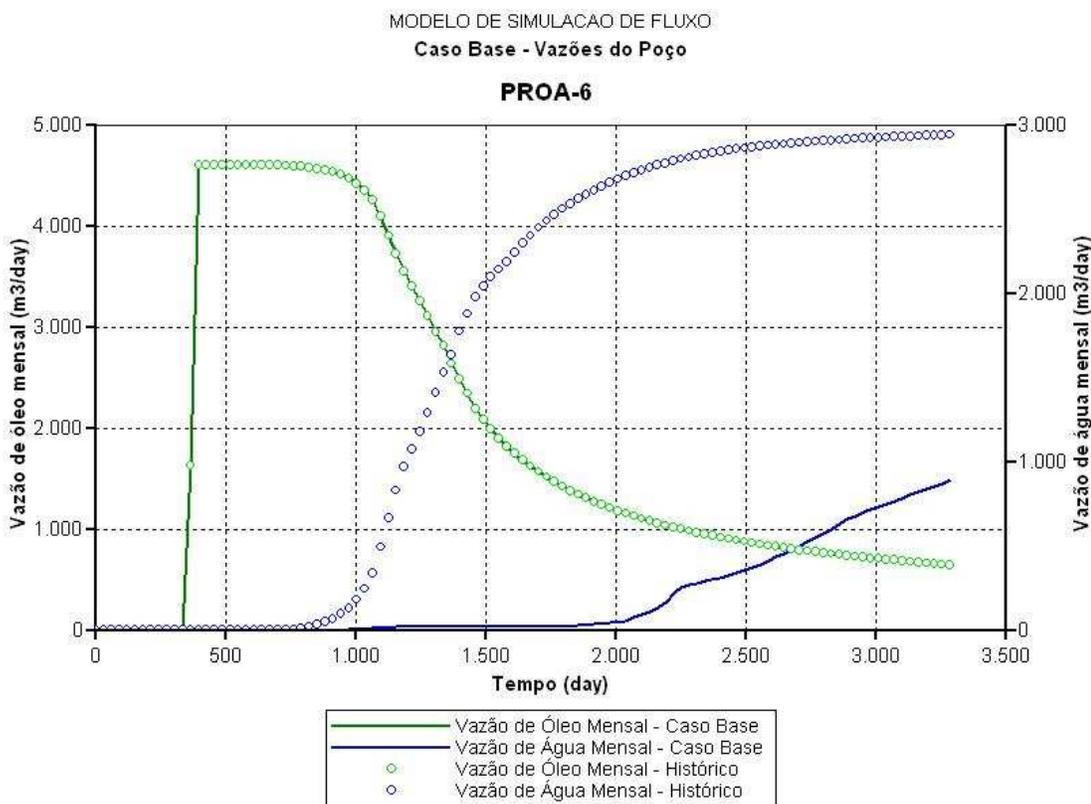


Figura 5.15 – Vazões de Óleo e Água do poço PROA-6 para o caso base e histórico.

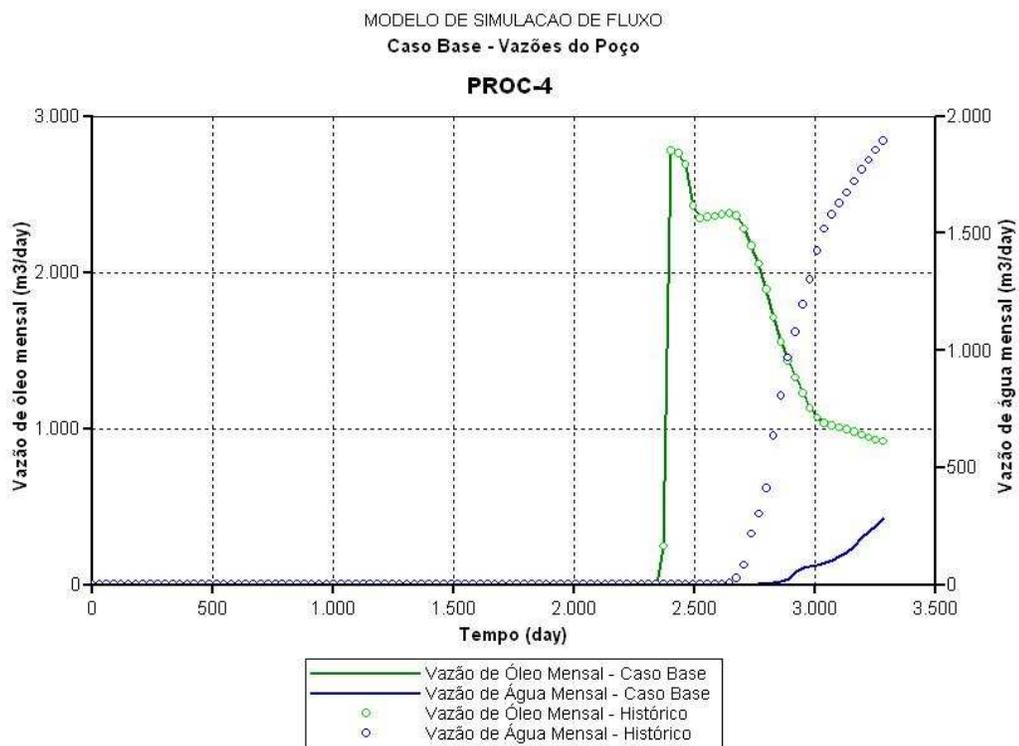


Figura 5.16 – Vazões de Óleo e Água do poço PROC-4 para o caso base e histórico.

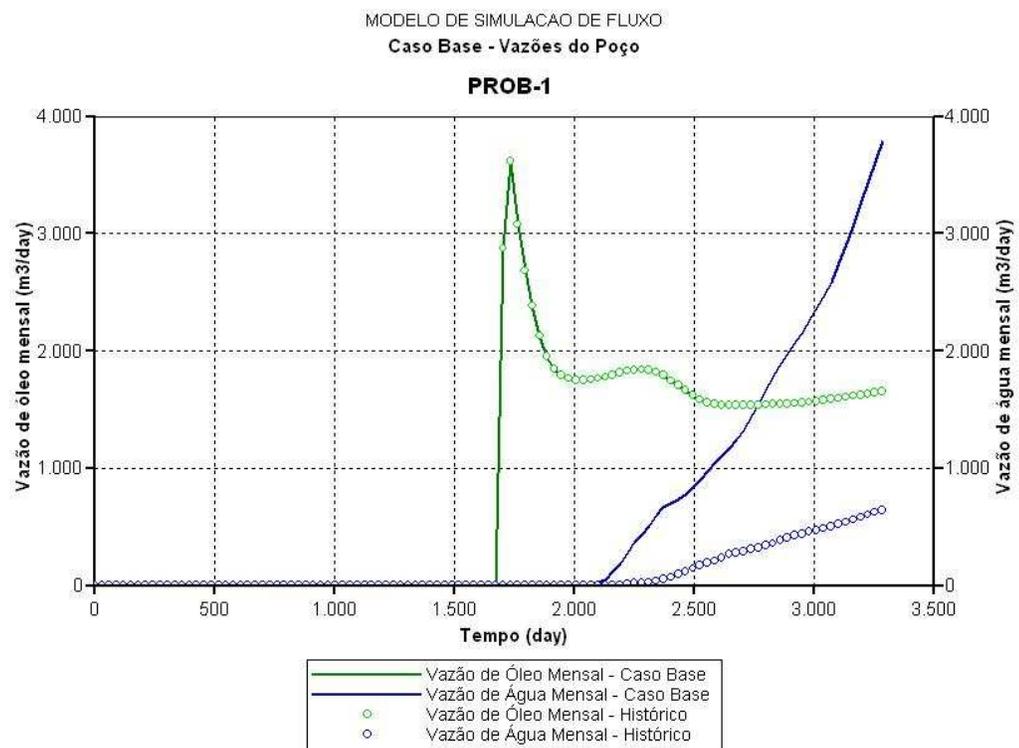


Figura 5.17 – Vazões de Óleo e Água do poço PROB-1 para o caso base e histórico.

De forma similar as pressões de fundo (PRF) dos poços também mostram um desajuste, estando o modelo base sempre mais pressurizado que o histórico. Um exemplo disso está nas Figuras 5.18, 5.19 e 5.20 para os mesmos poços mostrados anteriormente.

A RGO dos poços do modelo base também é um pouco diferente dos dados históricos, o que pode estar associado à incerteza existente na tabela de PVT do fluido do reservatório. Essas diferenças podem ser observadas em todos os poços, como exemplificado nas Figuras 5.21 e 5.22 para os poços PROA-1 e PROB-5, respectivamente.

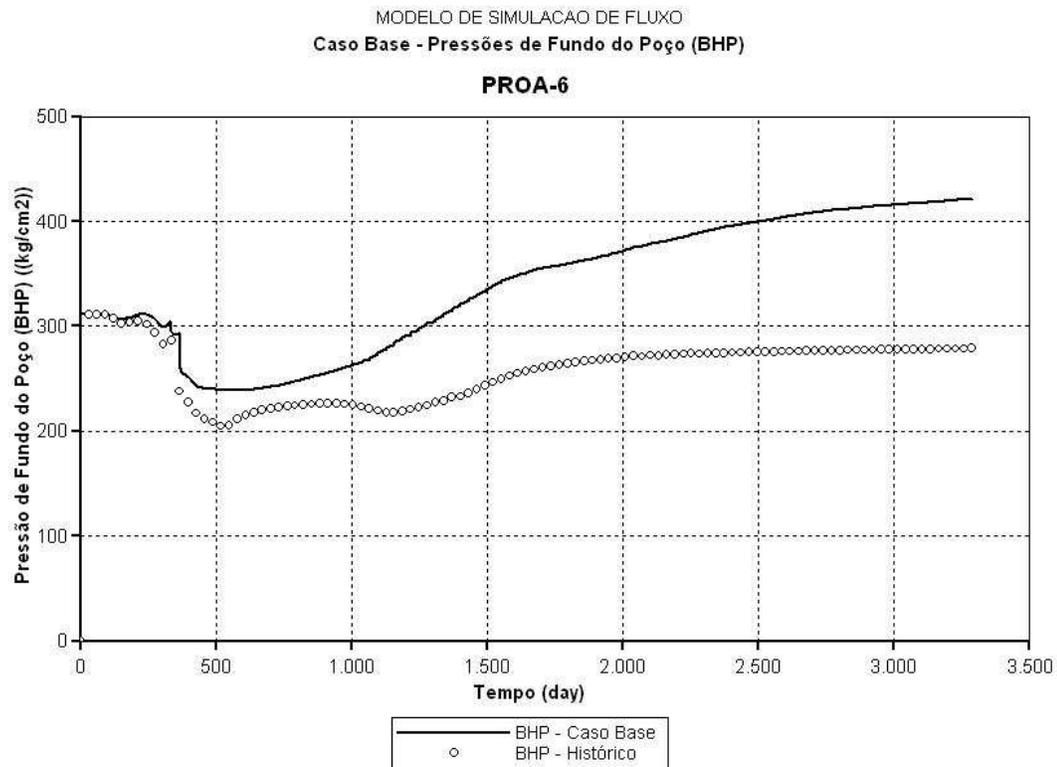


Figura 5.18 – Diferenças entre PRF do modelo base e do histórico para o poço PROA-6.

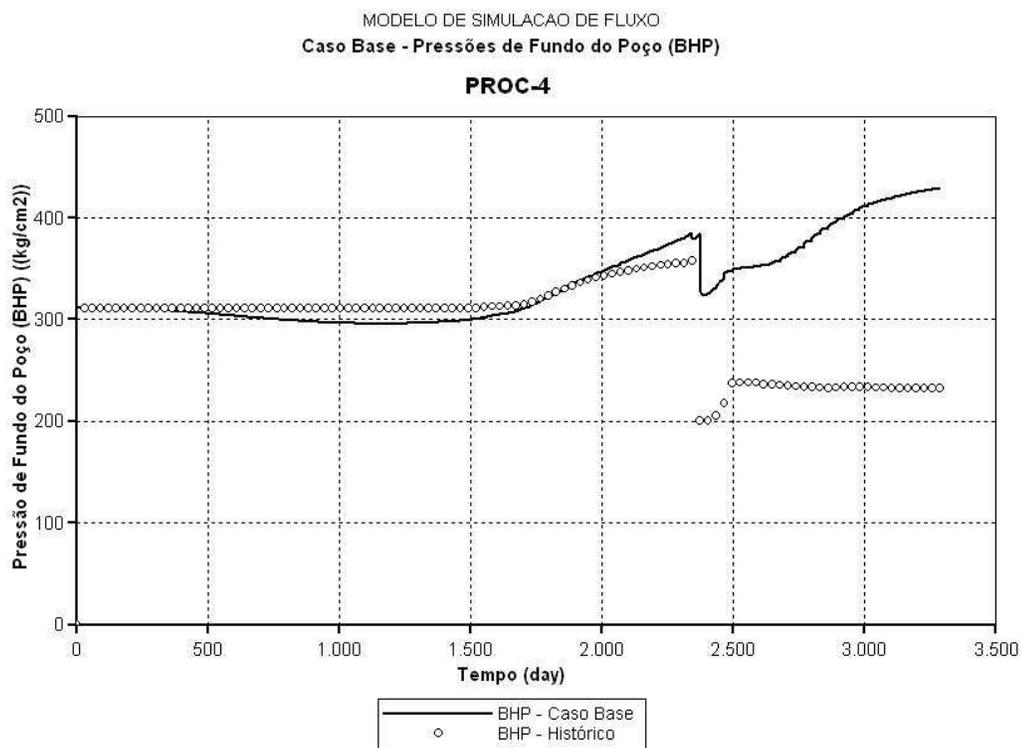


Figura 5.19 – Diferenças entre PRF do modelo base e do histórico para o poço PROC-4.

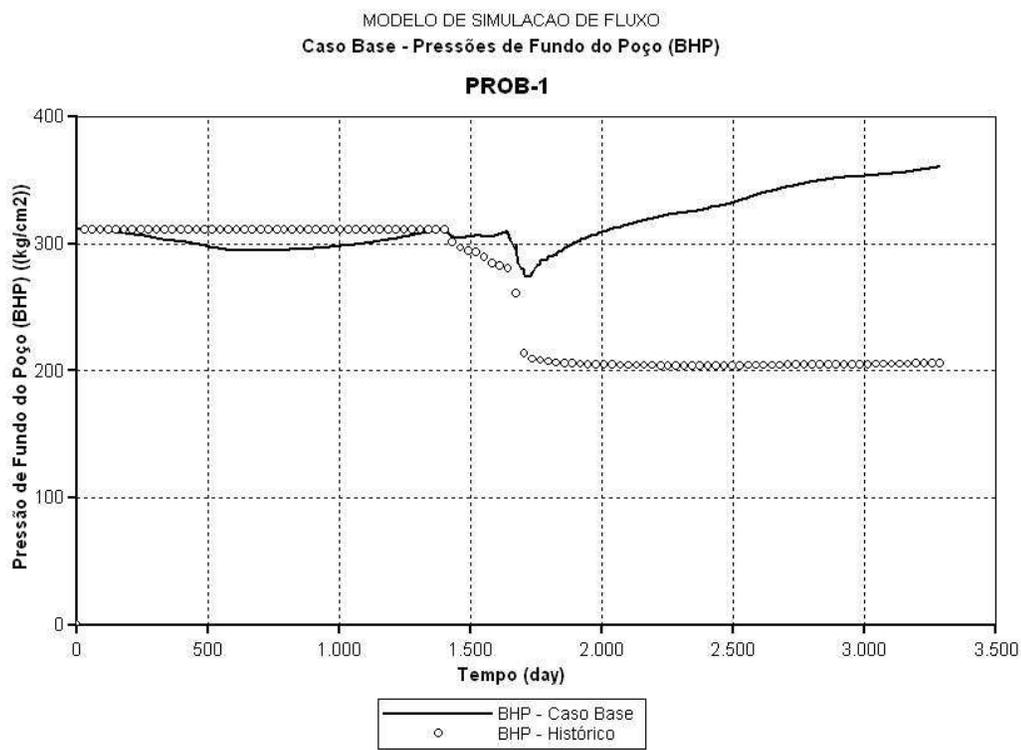


Figura 5.20 – Diferenças entre PRF do modelo base e do histórico para o poço PROB-1.

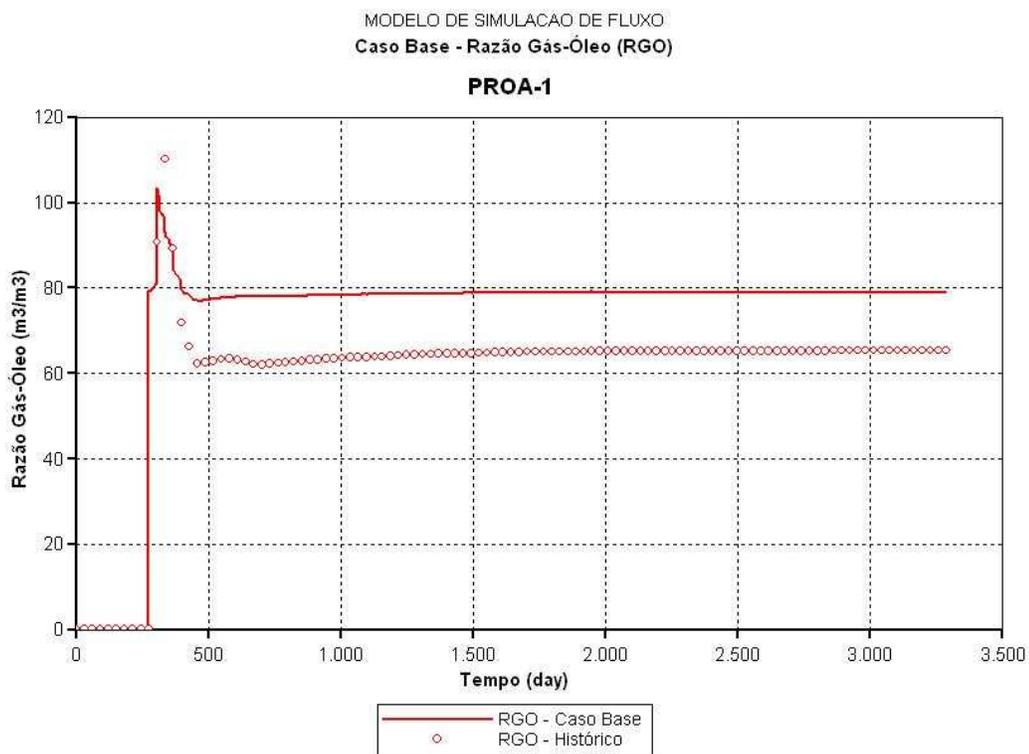


Figura 5.21 – RGO do caso base comparada com o histórico do poço PROA-1.

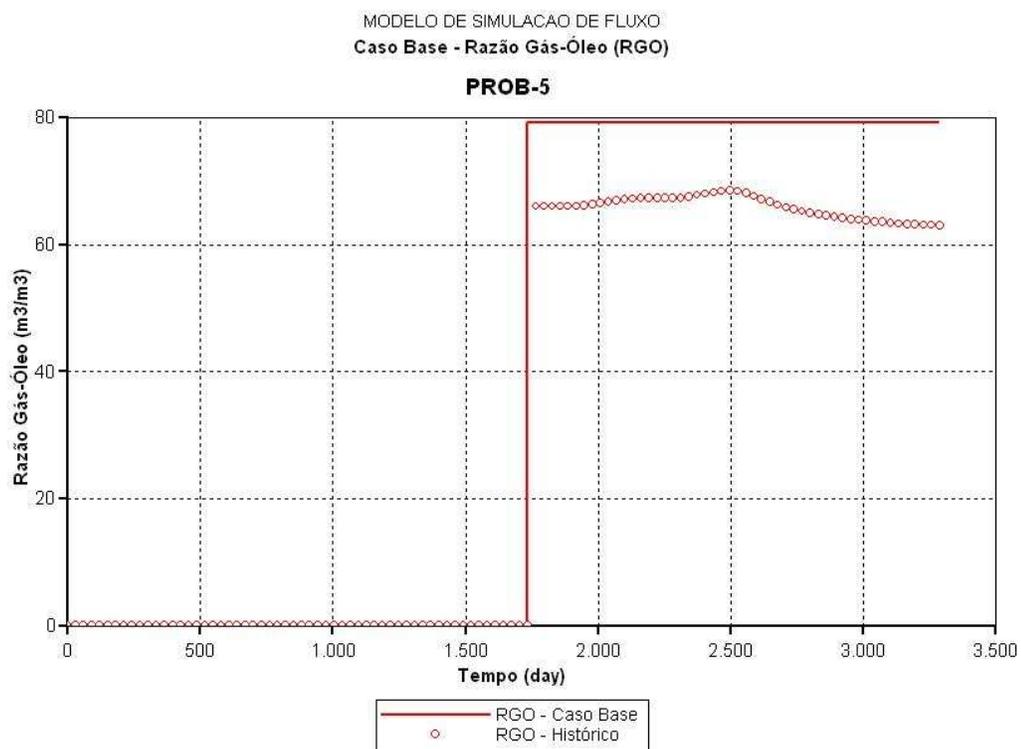


Figura 5.22 – RGO do caso base comparada com o histórico do poço PROB-5.



## 6. RESULTADOS E DISCUSSÃO

Neste capítulo, são apresentados os resultados referentes à aplicação da metodologia proposta nos dois casos estudados. No primeiro deles, são aplicados os quatro métodos citados e é feita uma comparação entre as respostas obtidas. Já no segundo caso, somente os métodos 3 e 4, propostos por este trabalho tem seus resultados avaliados.

### 6.1 Análise de Sensibilidade

A análise de sensibilidade é feita para verificar os atributos incertos críticos dentre os 13 citados no Item 5.2. Partindo-se do modelo base (atributos no nível 1) com o histórico de produção inserido (vazão de óleo), foram simulados os casos alterando-se para o valor do nível 0 e 2 de cada um dos atributos individualmente. Sendo assim, foram simulados 27 modelos, contando o cenário base.

Em seguida, as Equações 3.2 e 3.3 foram utilizadas para calcular os afastamentos com relação ao caso base, ou seja, colocando-se no lugar do histórico os resultados do caso base. A FO utilizada para os cálculos é uma combinação de  $Q_w$  e  $PRF$  dos poços através das Equações 4.1 e 4.2, visto que a  $Q_o$  imposta é honrada pelos poços. Foi feita uma normalização dos afastamentos quadráticos em relação ao máximo obtido nos diferentes modelos simulados, obtendo-se o índice de sensibilidade (IS), descrito no Item 2.2.1. Desta forma, o IS fica restrito a valores entre -1 e 1, sendo que os extremos indicam que o atributo modificado do cenário base é o que mais influencia a função medida. Os resultados obtidos para o campo e para os Blocos A, B e C estão nos gráficos abaixo (Figuras 6.1, 6.2, 6.3 e 6.4).



As cores utilizadas nos gráficos mostram se o atributo foi alterado para o seu limite inferior ou superior. As curvas vermelhas referem-se à alteração do atributo considerado para o seu nível inferior (0), já as curvas azuis, para o nível superior (2).

As figuras abaixo mostram que para cada bloco os parâmetros críticos são diferentes. Porém, existem alguns atributos que influenciam bastante as funções de todos os blocos e do campo, como a transmissibilidade da falha A-B, a curva de permeabilidade relativa, a PVT e o modelo de falhas. Sendo assim, estes foram os parâmetros críticos escolhidos para a aplicação da metodologia, juntamente com a porosidade do Bloco A, já que é o bloco com maior período de histórico de produção.

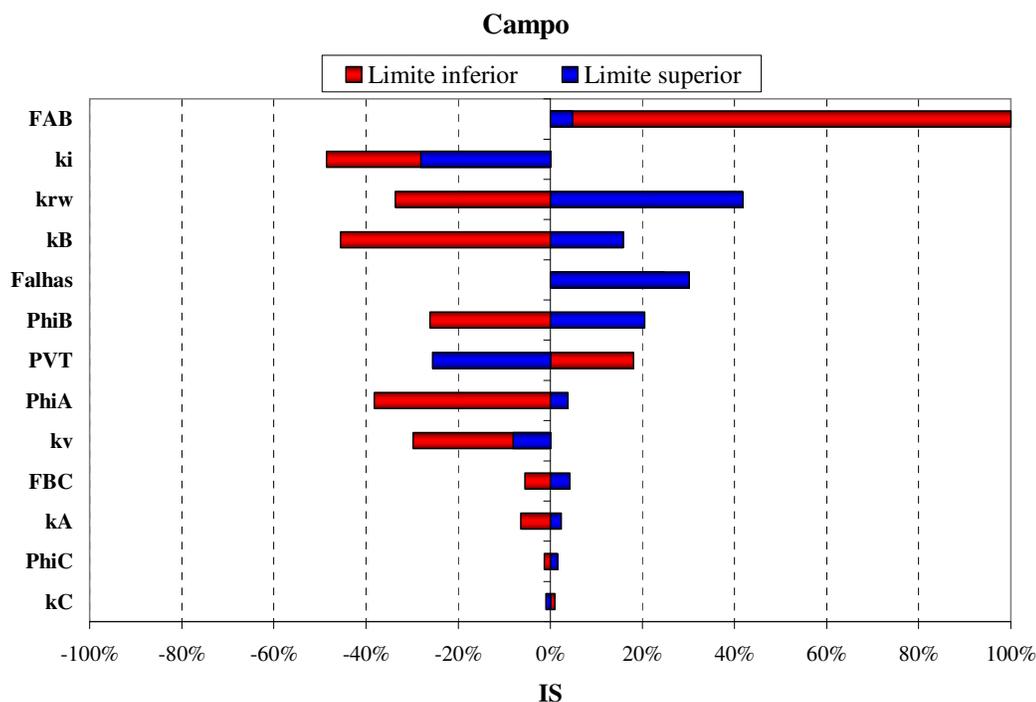


Figura 6.1 – Análise de sensibilidade para o Campo.

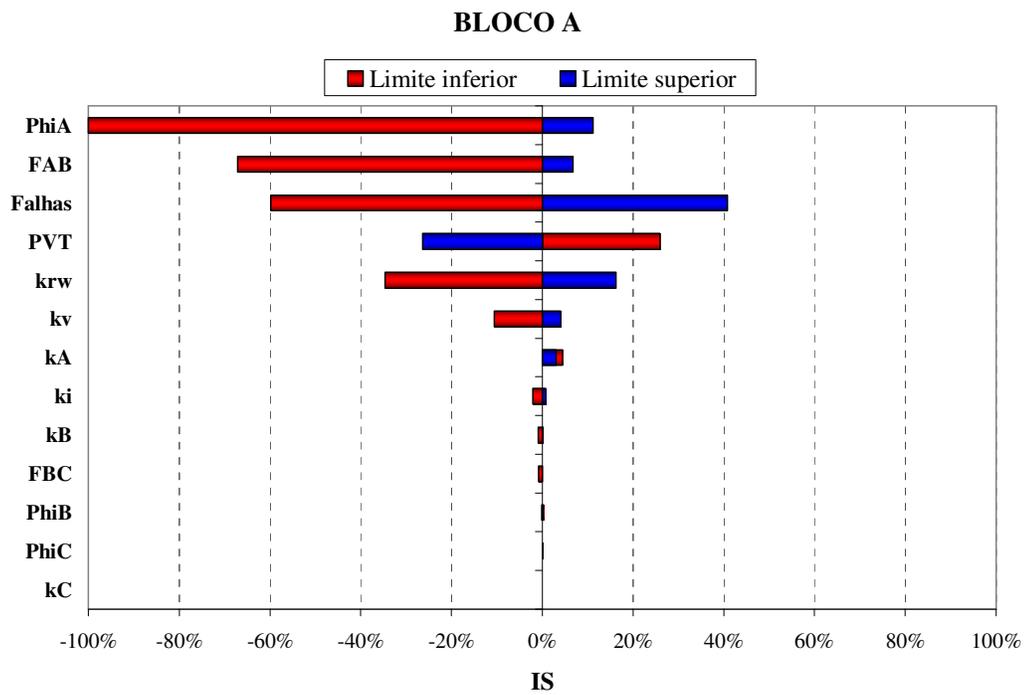


Figura 6.2 – Análise de sensibilidade para o Bloco A.

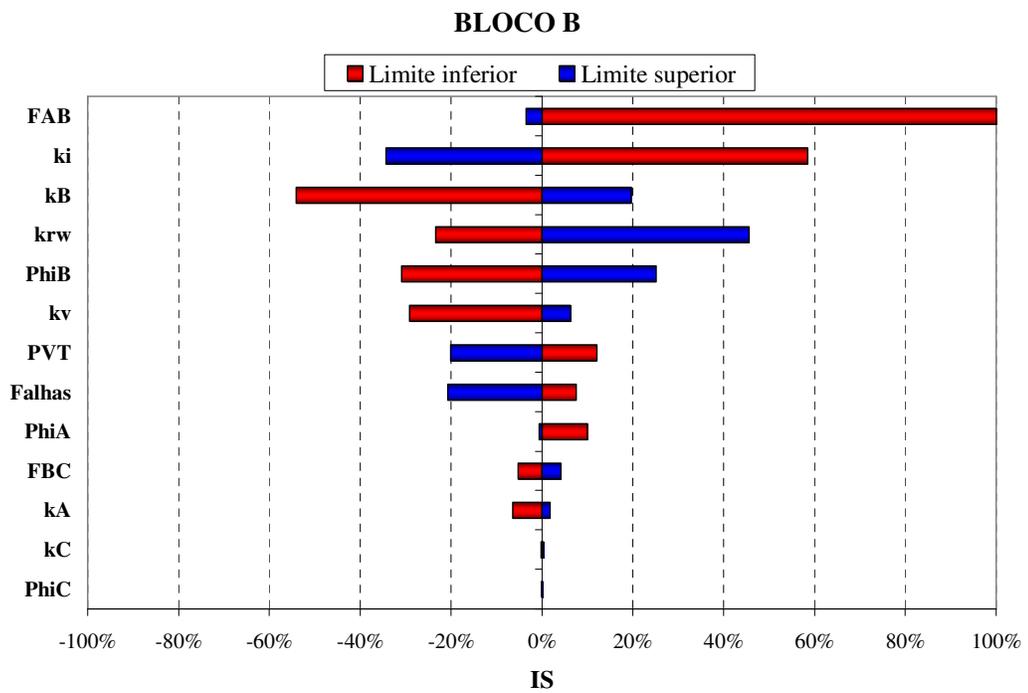


Figura 6.3 – Análise de sensibilidade para o Bloco B.

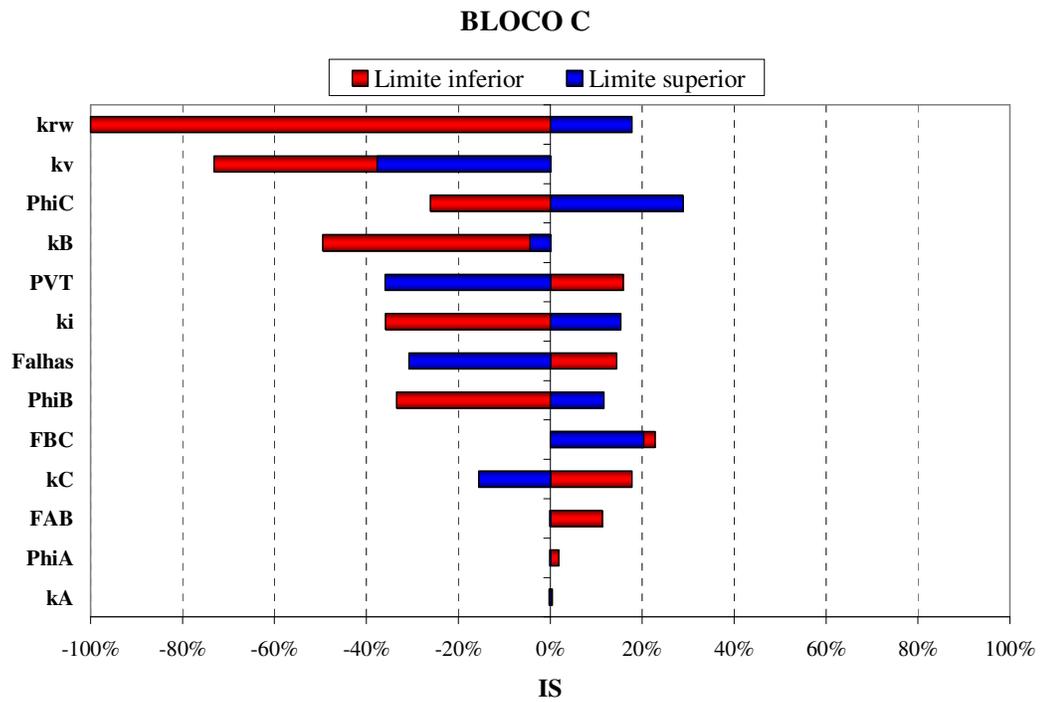


Figura 6.4 – Análise de sensibilidade para o Bloco C.

## 6.2 Caso A

### 6.2.1 Método 1

A combinação dos cinco atributos críticos selecionados discretizados em três níveis gera 243 modelos ( $n_{\text{níveis}}^{\text{atributos}} = 3^5$ ). Os resultados obtidos de vazão de óleo, água e pressão são comparados ao histórico, aplicando-se as Equações 3.2, 3.3, 4.1 e 4.2. Em seguida, é aplicada a Equação 3.4 para o recálculo das probabilidades, cujo resultado está mostrado na Figura 6.5 e na Tabela 6.1, onde está destacado em verde o nível mais próximo do utilizado para gerar o histórico.

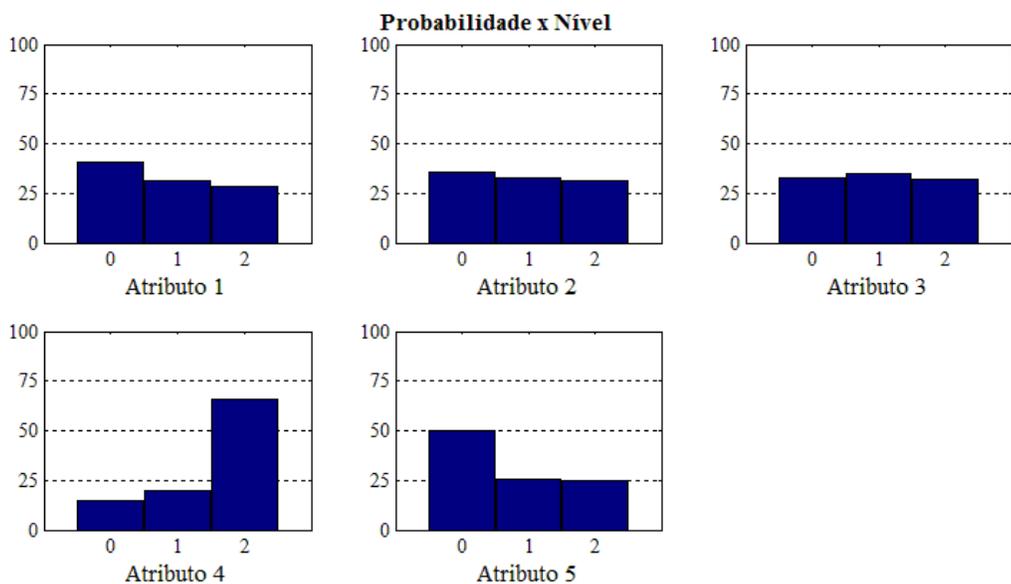


Figura 6.5 – Redistribuição de probabilidades pelo Método 1 – Caso A.

Tabela 6.1 - Resultados da aplicação do Método 1 – Caso A.

	Atributo	Probabilidade		
		0	1	2
1	PhiA	41%	31%	28%
2	FAB	36%	33%	31%
3	Falhas	33%	35%	32%
4	PVT	14%	20%	66%
5	krw	50%	25%	25%

Observa-se da Figura 6.5 que o Atributo 5 (krw) teve aumentada a probabilidade do nível 0, que não é o correto segundo o histórico conhecido. Além disso, os três primeiros atributos tiveram sua probabilidade muito pouco alterada, permanecendo quase uniforme. Porém, pelos gráficos contendo todas as curvas de produção de água e de pressão do campo para cada um dos três níveis verifica-se que o nível 0 do atributo FAB é o que apresenta resultados mais próximos do histórico, apesar do grande espalhamento das curvas (Figura 6.6).

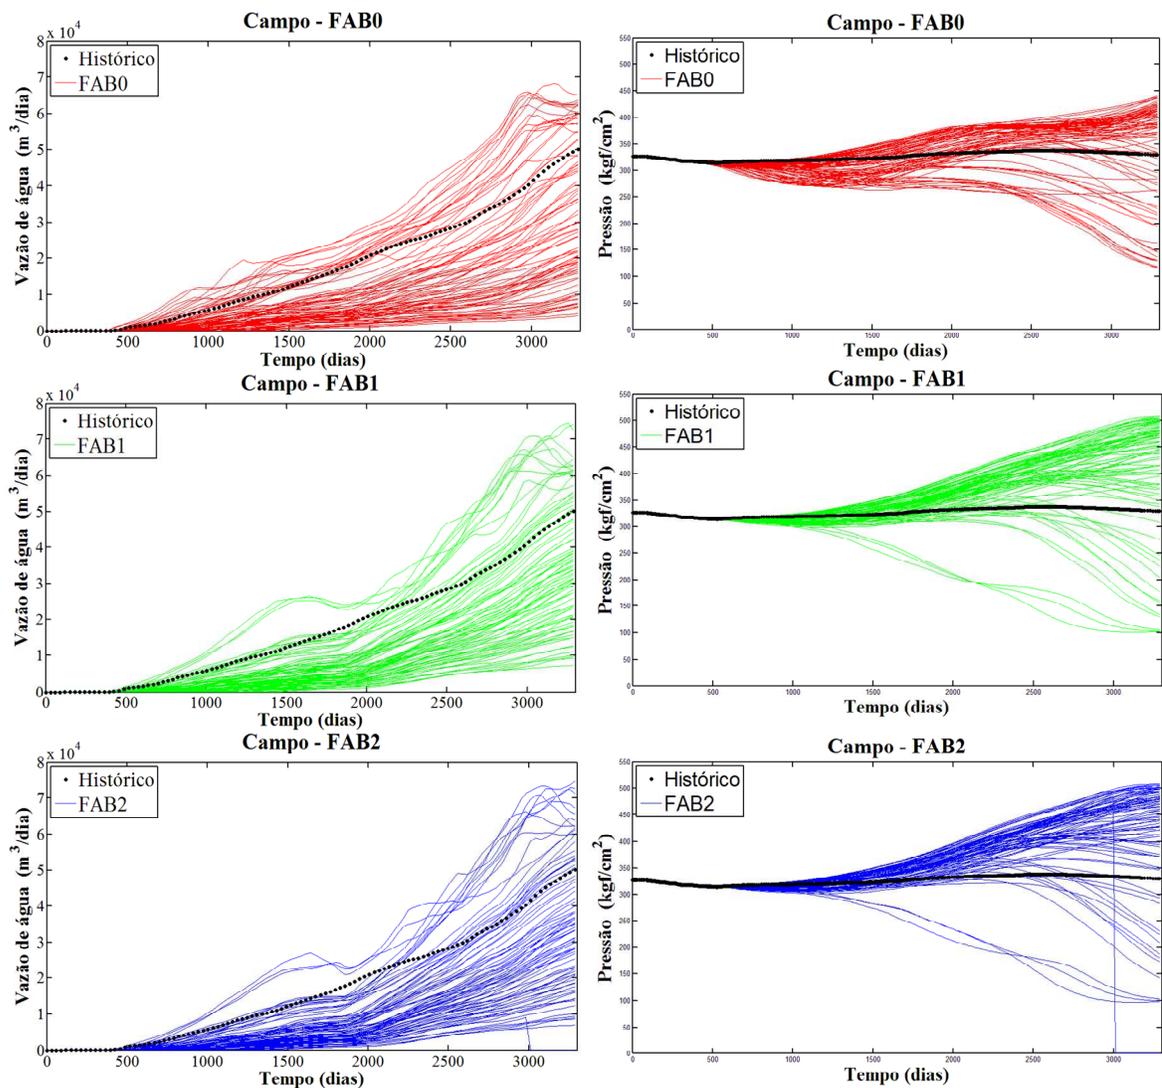


Figura 6.6 - Curvas de produção de água (esquerda) e pressão do campo para os diferentes níveis do atributo FAB (0- vermelho, 1- verde, 2- azul).

Analisando-se a Figura 6.7, que mostra para cada nível, o  $K_n$  calculado pela Equação 3.5, verifica-se que de acordo com os afastamentos calculados, a probabilidade dos níveis PhiA 0, FAB 0 e Falhas 1 deveria ter sido aumentada em relação aos demais níveis. Para os atributos PVT e  $kr_w$ , o uso apenas do afastamento leva ao aumento da probabilidade do nível errado (PVT 1 e  $kr_w$  2).

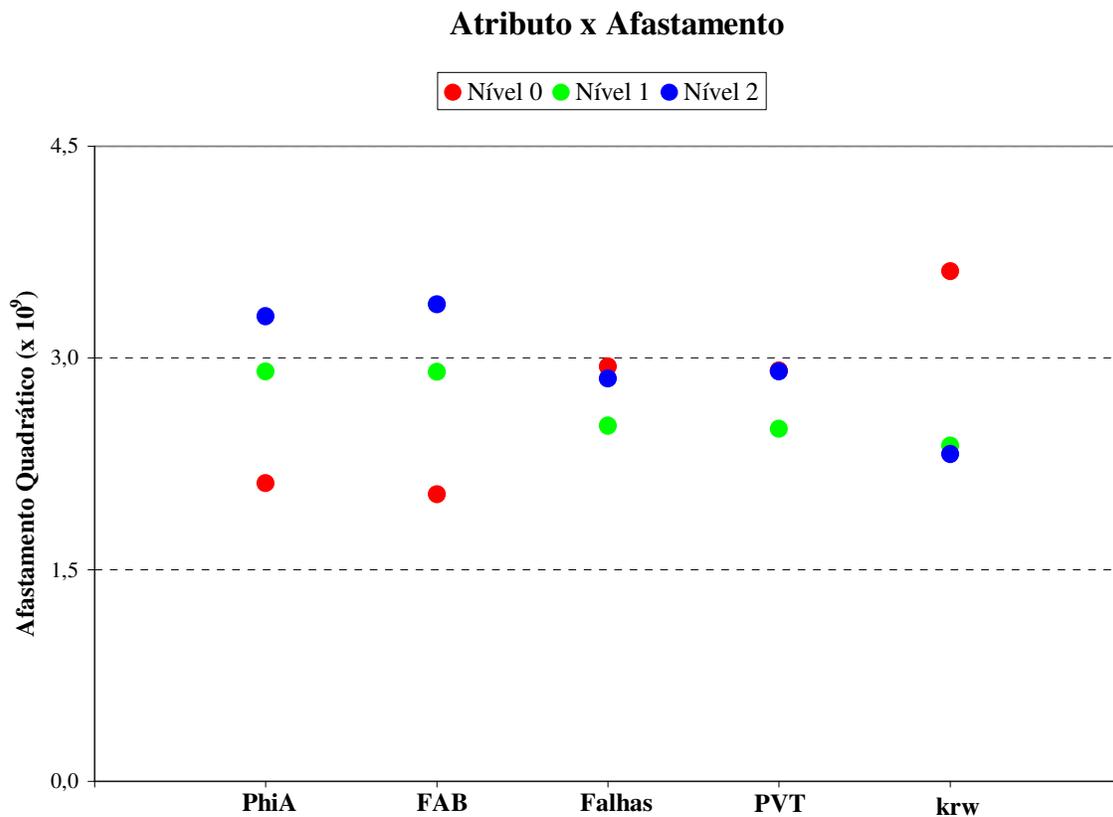


Figura 6.7 - Gráfico da soma dos afastamentos quadráticos ( $K_n$ ) para cada nível dos atributos.

Além disso, pode-se também mostrar os afastamentos quadráticos dos 243 cenários, separados pelos níveis do atributo considerado, sendo que o nível que apresenta os menores valores (mais próximos de zero) é o que deve ter a probabilidade aumentada. Tais afastamentos foram obtidos através das Equações 3.3 e 4.1, combinando-se vazão de óleo, vazão de água e pressão de fundo de todos os poços. A Figura 6.8 ilustra os afastamentos dos 81 modelos de cada nível para os cinco atributos críticos, mostrando que os níveis de menor afastamento são, respectivamente, 0, 0, 1, 1 e 2 para cada atributo, indicando um aumento de probabilidade errada para os dois últimos atributos.

No entanto, como as probabilidades dos três primeiros atributos praticamente não se alteram, o problema no cálculo da redistribuição de probabilidades pelo Método 1 está na simetria, a qual utiliza o sinal da FO, que, por sua vez, depende do afastamento simples. Como nesse caso complexo, foram combinadas distintas séries de dados, como produção de óleo, água e pressão, que muitas vezes possuem sentidos de crescimento contrários e ordens de grandezas

diferentes, o resultado obtido para o sinal (Equação 4.2) não representa bem a simetria da combinação das funções. Para o caso simples, em que se analisa somente um tipo de variável, a combinação feita pela Equação 4.2 é válida, como por exemplo, ao se utilizar somente  $Q_w$  de um poço.

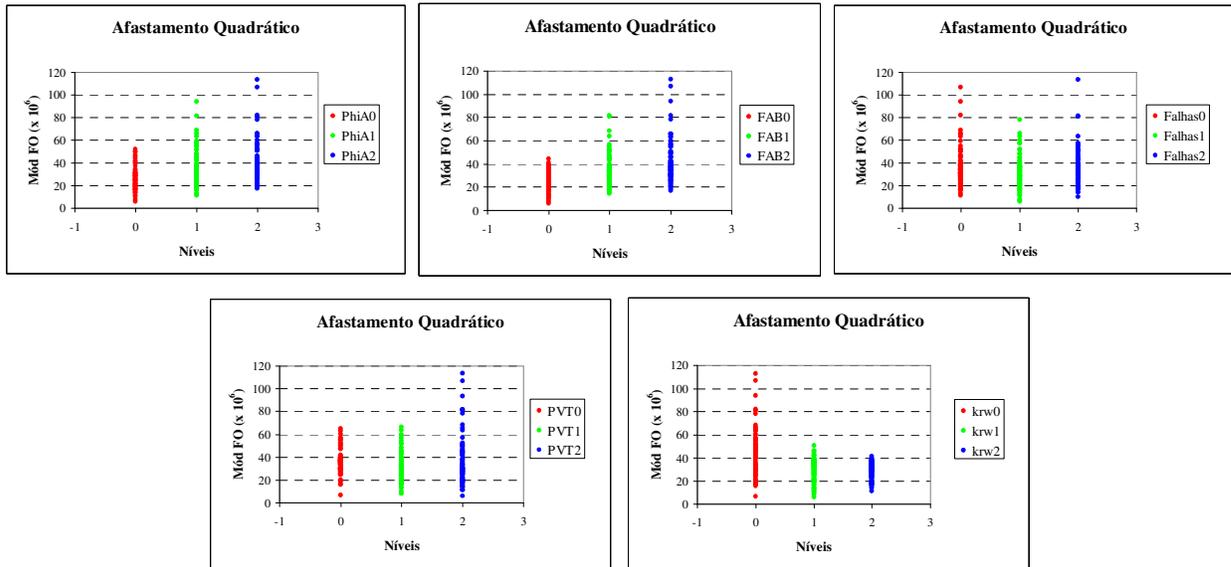


Figura 6.8 - Afastamento quadrático dos modelos dos cinco atributos por nível.

Sendo assim, a forma como foi realizado o cálculo da simetria não está adequada, gerando resultados não esperados no cálculo da probabilidade. Um exemplo que mostra isso é obter novas probabilidades para o atributo PhiA, utilizando como FO somente as produções e pressões dos poços do Bloco C, as quais não são alteradas pela variação desse atributo segundo a análise de sensibilidade (dois primeiros gráficos da Figura 6.9). O resultado obtido deveria ser uma distribuição uniforme para PhiA (gráfico da direita na Figura 6.9), visto que não importa para os poços do Bloco C o seu valor. Porém, ao utilizar o Método 1, isso não é observado, o que prova que há inconsistências para a combinação de muitas funções para a redistribuição da probabilidade, principalmente no cálculo da simetria.

Uma possível solução para esse problema é não agrupar as diferentes séries de dados, como propõe o Método 3, cujos resultados estão apresentados ainda neste capítulo. Isso ocorre principalmente pelas diferentes características dos afastamentos de funções diferentes como pressão e água, por exemplo, que em geral, possuem sentidos opostos de crescimento, conforme já mostrado nos exemplos teóricos do Capítulo 4.

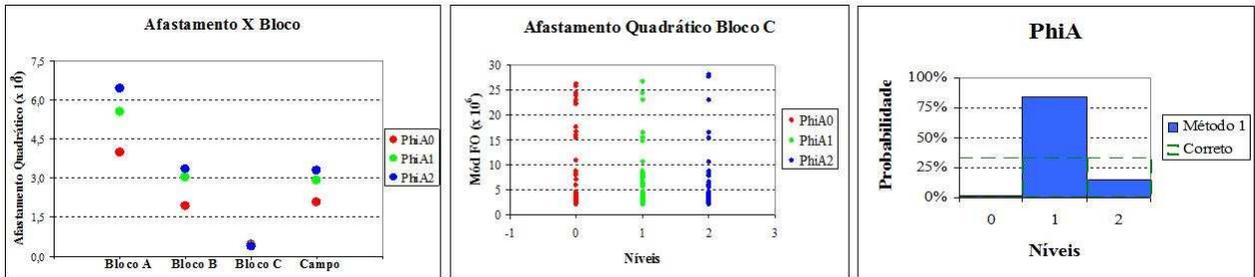


Figura 6.9 - Independência da FO do Bloco C com relação ao atributo PhiA e redistribuição da probabilidade de PhiA pelo Método 1 com esta FO.

A curva de incerteza, descrita no Item 2.2.3, traçada para o Método 1, mostra que não há redução das incertezas, apenas uma maior centralização dos afastamentos em relação ao afastamento zero. As curvas foram traçadas usando como FO a combinação dos afastamentos das vazões de água dos poços e a combinação dos afastamentos das pressões de fundo dos poços de acordo com as Equações 4.1 e 4.2 e estão ilustradas na Figura 6.10. Como na combinação de diferentes funções ( $Q_w$  e  $PRF$ ), há o problema do cálculo do sinal, as curvas foram traçadas para cada uma separadamente, combinando somente os poços. O método somente melhora a centralização das curvas em torno do histórico de produção para a vazão de água, não apresentando bons resultados para a redução da dispersão. Para os dados de pressão, nos percentis acima de 30% há uma redução no valor da FO, porém abaixo dele os afastamentos aumentam com relação ao inicial.

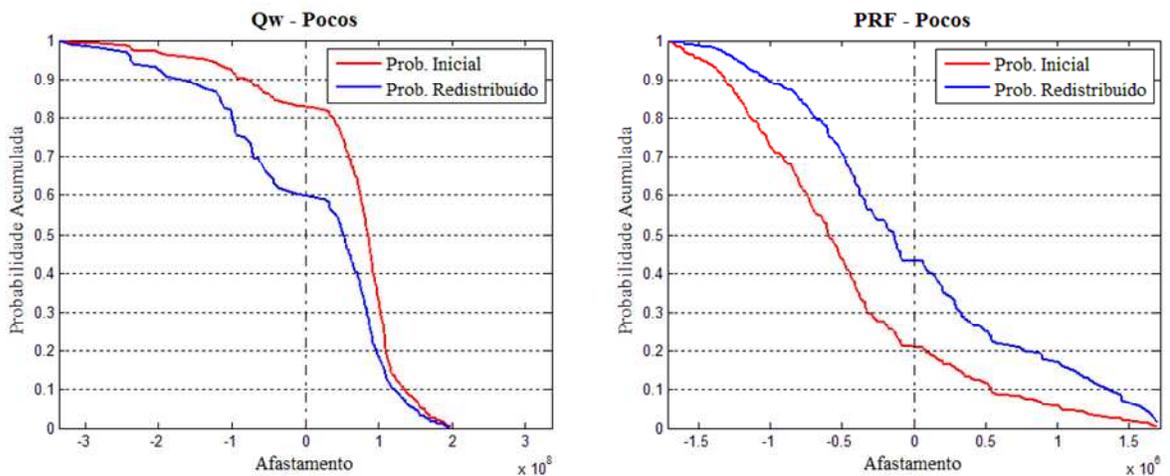


Figura 6.10 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 1 – Caso A.



A Figura 6.11 ilustra a produção de água do campo de todos os modelos entre os percentis P10 e P90 das curvas de incerteza inicial e final (vermelha e azul, respectivamente) traçadas com a FO da combinação de afastamentos das vazões de água dos poços. Verifica-se que não há redução das incertezas do reservatório, visto que grande parte das curvas azuis está sobreposta às vermelhas e o número de modelos extraídos da curva inicial, 194, é menor que os da curva final, 201. Isso acontece por causa da combinação de diversas funções para a redistribuição de probabilidades dos atributos, as quais podem possuir sentidos contrários de crescimento, anulando-se; e pela simetria utilizada que, conforme explicado acima, não representa bem a simetria da combinação de funções.

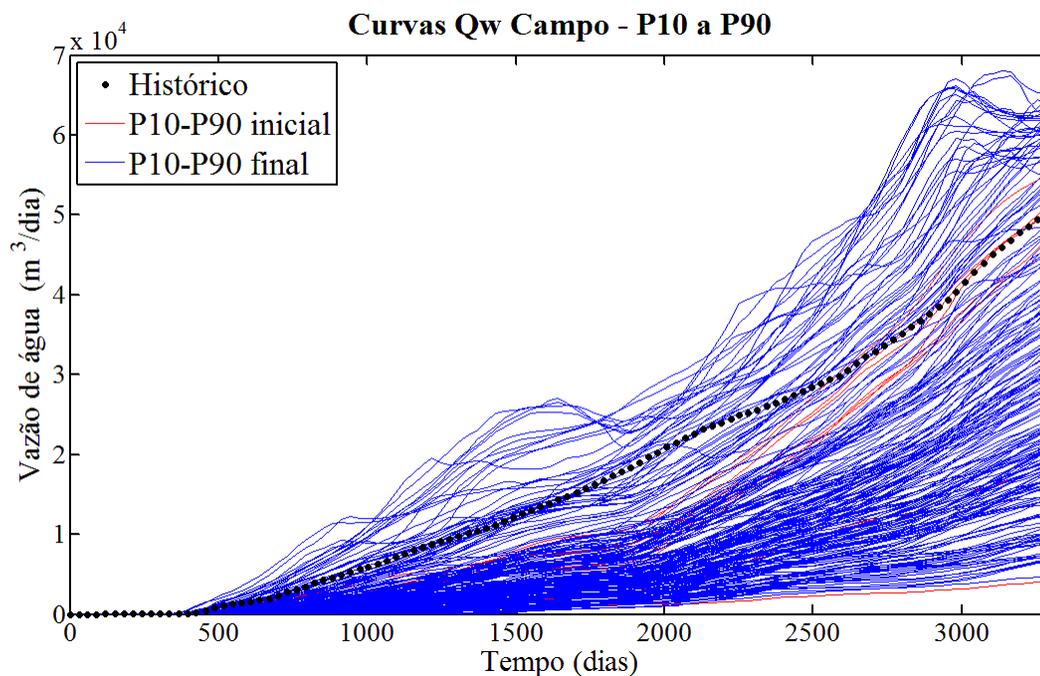


Figura 6.11 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 1 – Caso A.

O mesmo raciocínio pode ser usado para construir os gráficos de pressão, selecionando todos os modelos entre os percentis P10 e P90 das curvas de incerteza inicial e final traçadas com a FO da combinação de afastamentos das pressões de fundo dos poços. A Figura 6.12 ilustra a pressão do campo, mostrando que as incertezas não diminuem, pois a maioria das curvas azuis está sobreposta às vermelhas. De forma similar, ao se traçar tais curvas para os poços, também não é observada redução das incertezas como mostrado na Figura 6.13, para a vazão de água do

poço PROA-4 e pressão do PROC-4. Destaca-se que os modelos usados para traçar estes dois últimos gráficos foram respectivamente os mesmos das Figuras 6.11 e 6.12. A explicação para a não diminuição das incertezas é a mesma descrita acima para as curvas de vazão de água.

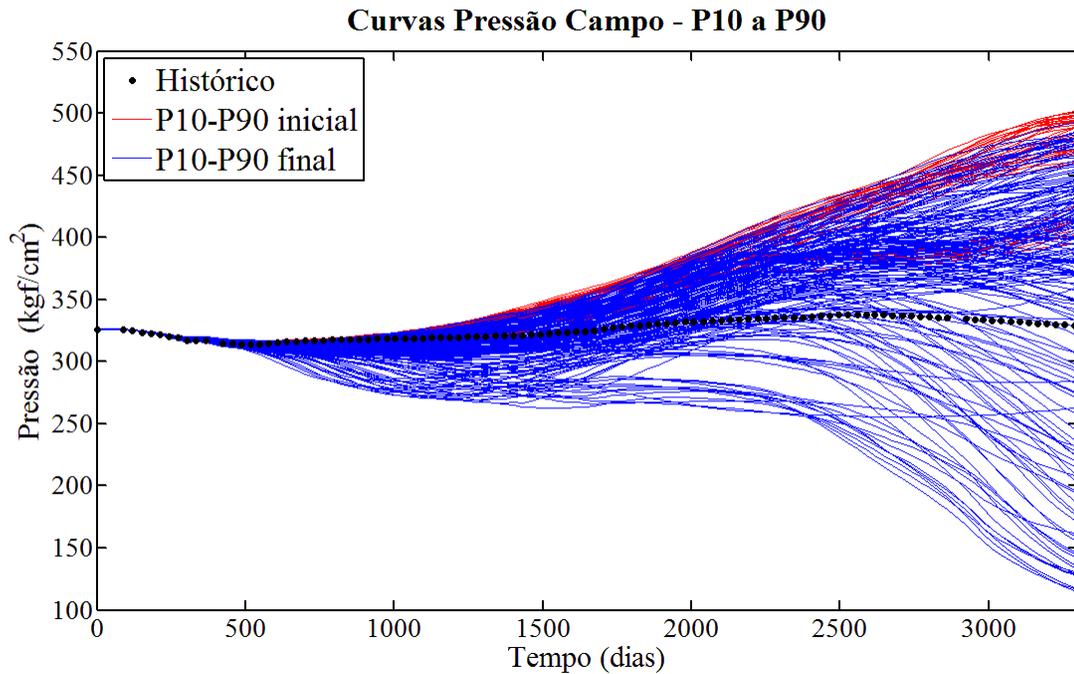


Figura 6.12 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 1 – Caso A.

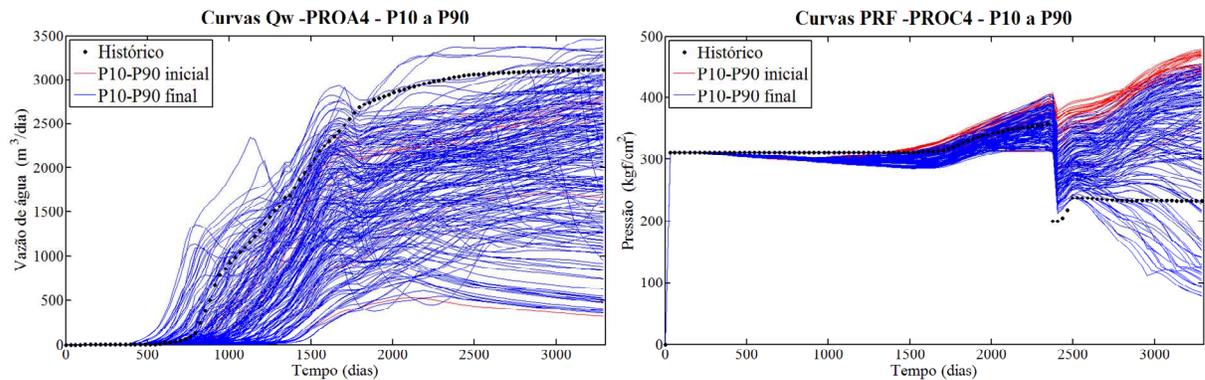


Figura 6.13 – Curvas de  $Q_w$  do PROA-4 e  $PRF$  do PROC-4 para os modelos entre P10 e P90, resultantes do Método 1 – Caso A.

## 6.2.2 Método 2

O objetivo da redistribuição é aumentar a probabilidade do nível do atributo cujos cenários simulados apresentam o menor afastamento quadrático com relação ao histórico, reduzindo assim as incertezas do reservatório. Da forma como foi feito no Método 1, são somados os afastamentos quadráticos de cada nível e no cálculo da probabilidade do nível, este valor é invertido (Equação 3.4), de forma a aumentar a probabilidade do menor deles. Porém, melhores resultados são obtidos na proposta de Maschio et al. (2010), que inverte o afastamento quadrático antes de realizar o somatório para o nível (Equações 3.8 e 3.9), compondo o Método 2. O resultado obtido, utilizando o mesmo  $F$  do trabalho original ( $F = 2,5$ ), está mostrado na Tabela 6.2 e na Figura 6.14.

Tabela 6.2 – Resultados da aplicação do Método 2 – Caso A.

	Atributo	Probabilidade		
		0	1	2
1	PhiA	66%	21%	13%
2	FAB	68%	19%	13%
3	Falhas	22%	54%	24%
4	PVT	23%	34%	43%
5	krw	24%	49%	27%

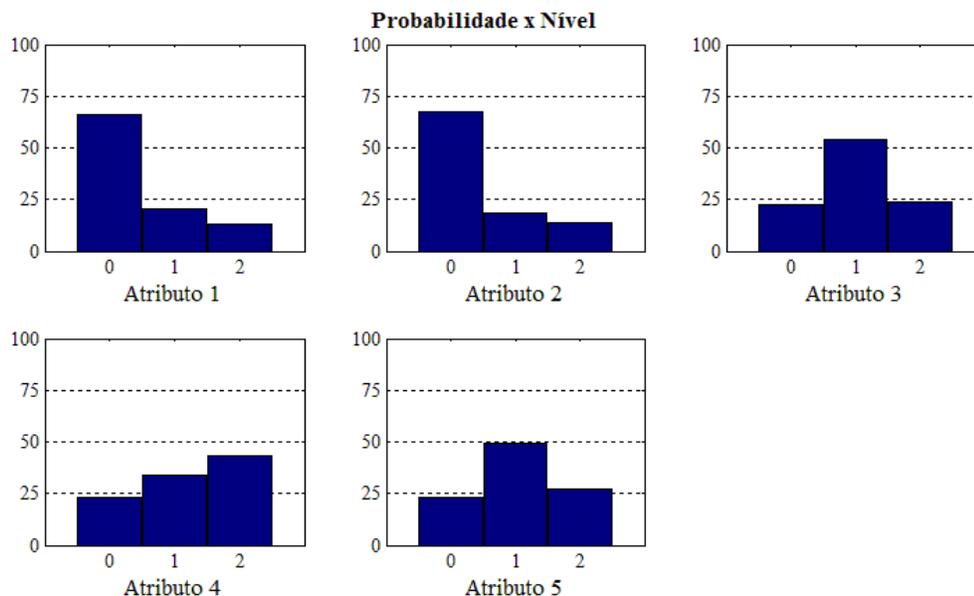


Figura 6.14 - Redistribuição de probabilidades pelo Método 2 – Caso A.

Os resultados do Método 2 de todos os atributos estão mais coerentes com a resposta correta (destacada em verde na Tabela 6.2), pois além da melhoria citada acima, ele não utiliza o sinal da FO e nem a simetria em suas fórmulas, visto que ela apresentou inconsistências ao se combinar diferentes séries de dados no Método 1. A Figura 6.15 mostra, para cada nível, o  $K_{in}$  calculado pela Equação 3.8, confirmando que são atribuídas maiores probabilidades aos níveis com maior  $K_{in}$ , isto é, com menores afastamentos.

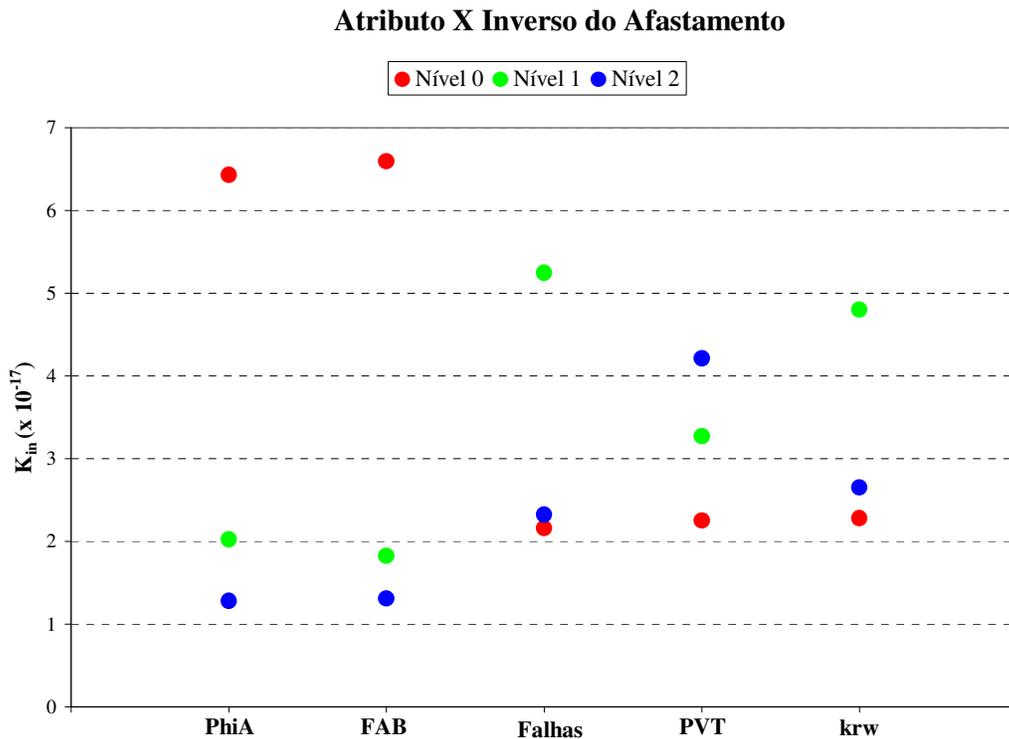


Figura 6.15 - Gráfico da soma dos afastamentos quadráticos invertidos ( $K_{in}$ ) para cada nível dos atributos.

Outra observação importante a ser feita é que neste caso não ocorre o problema mostrado no item anterior na Figura 6.9. Quando um atributo não influencia uma determinada função, a redistribuição das probabilidades fica uniforme ao se utilizar essa FO no cálculo. O mesmo exemplo citado no Item 6.2.1 é aplicado ao Método 2, obtendo-se uma distribuição uniforme para PhiA, o que mostra coerência nessa nova fórmula utilizada (Figura 6.16).

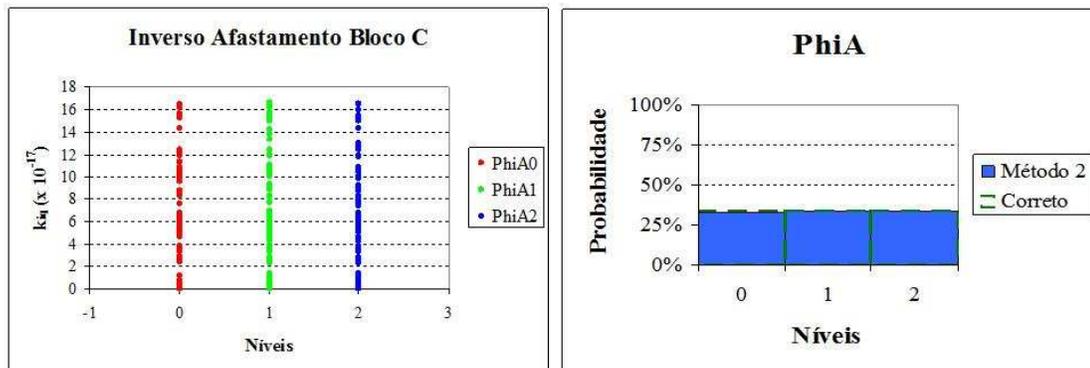


Figura 6.16 – Independência da FO do Bloco C com relação ao atributo PhiA e redistribuição da probabilidade de PhiA pelo Método 2 com esta FO.

Os resultados também podem ser analisados a partir das curvas de incerteza (Item 2.2.3), ilustradas na Figura 6.17, que mostram a dispersão dos modelos simulados com relação aos dados de histórico. De forma similar a anterior, as curvas foram traçadas para cada função separadamente, combinando somente os poços, porque há o problema do cálculo do sinal ao se juntar diferentes funções ( $Q_w$  e  $PRF$ ). Para a produção de água dos poços, a curva de incerteza do Método 2 apresenta afastamentos com relação ao histórico menores quando comparada com a curva inicial, principalmente para percentis menores que 80%, ou seja, há uma aproximação da curva final em direção ao eixo y (histórico), indicando uma redução das incertezas, porém a centralização ao redor do histórico é menor que no Método 1. Já para a pressão dos poços, nos percentis acima de 30% há uma redução no valor da FO, porém abaixo do percentil 30 a curva final apresenta afastamentos maiores que a inicial.

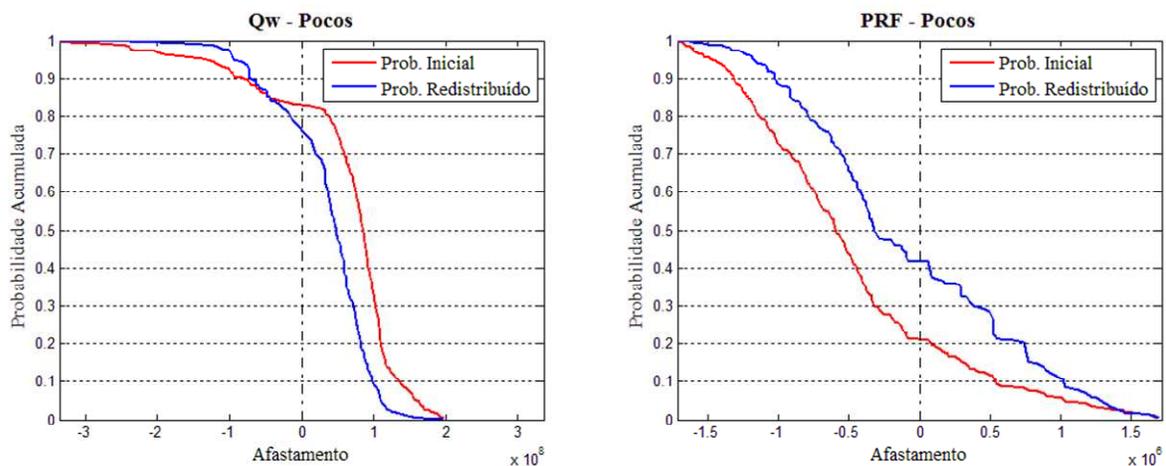


Figura 6.17 – Curvas de incerteza da vazão de água e pressão dos poços – Método 2 – Caso A.

Das curvas de incerteza inicial e final (Método 2) é possível selecionar modelos representativos da faixa de incerteza P1, P10, P90 e P99 conforme descrito no Capítulo 2, obtendo-se os gráficos mostrados na Figura 6.18. Estes ilustram a redução do espalhamento (diferença entre a FO do percentil P10 e do P90) com a aplicação do método e também a centralização em torno do histórico. No caso similar a um modelo real considerado, onde estão sendo consideradas duas variáveis ( $Q_w$  e  $PRF$ ) para a redistribuição das probabilidades dos atributos, os resultados mostram que o processo está centralizando a FO em torno do histórico (afastamento nulo), porém não está reduzindo de forma significativa as incertezas, visto que a dispersão continua grande.

Comparando-se o espalhamento inicial com o final há uma redução de somente 23,2% quando a FO considerada é a vazão de água. No caso da pressão, ocorre uma boa centralização em torno do histórico, porém a dispersão não reduz como esperado, ela aumenta um pouco (9,8%), como pode ser visto na Figura 6.18 à direita. Uma possível explicação para isso está na forma como foi feita a combinação das funções para o recálculo das probabilidades dos atributos, que gerou resultados razoáveis para a vazão de água, mas ruins para a pressão, indicando que os afastamentos da vazão de água são maiores numericamente que os de pressão, se sobressaindo na obtenção das novas probabilidades.

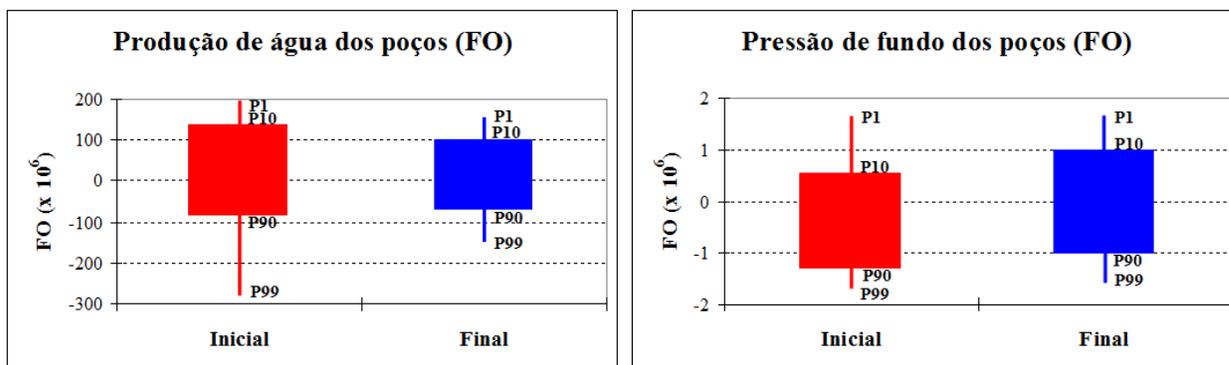


Figura 6.18 – Comparativo da FO de produção de água e de pressão dos poços antes e depois da aplicação do Método 2 (Caso A).

A Figura 6.19 ilustra a produção de água do campo de todos os modelos situados entre os percentis P10 e P90 das curvas de incerteza inicial e final para combinação dos afastamentos das vazões de água dos poços (vermelha e azul, respectivamente). Observa-se que houve uma pequena diminuição na faixa de incertezas do reservatório, eliminando-se alguns casos situados

muito distantes do histórico, conforme já mostrado no gráfico da Figura 6.18. O número de modelos situados entre P10 e P90 diminuiu de 194 da curva inicial para 130 extraídos da curva final. Isso mostra que as fórmulas se aplicam de forma coerente num caso complexo, com muitas funções diferentes, porém há apenas uma pequena melhoria no ajuste do histórico.

No entanto, para a pressão do campo ilustrada na Figura 6.20, com gráficos dos modelos da faixa P10-P90 extraídos da curva de incerteza das pressões (final: 170 modelos), praticamente não há redução alguma de incertezas, similar ao já exemplificado na Figura 6.18. A Figura 6.21, com o gráfico dos poços, vazão de água do PROA-4 e pressão do PROC-4, mostra redução bem pequena da incerteza para ambos os casos.

Mesmo com essa pequena diminuição na faixa dos modelos entre P10 e P90, pode-se fazer uma previsão de produção probabilística um pouco mais confiável. Porém, objetiva-se conseguir uma redução maior desta faixa, eliminando dela um maior número de modelos com afastamentos elevados.

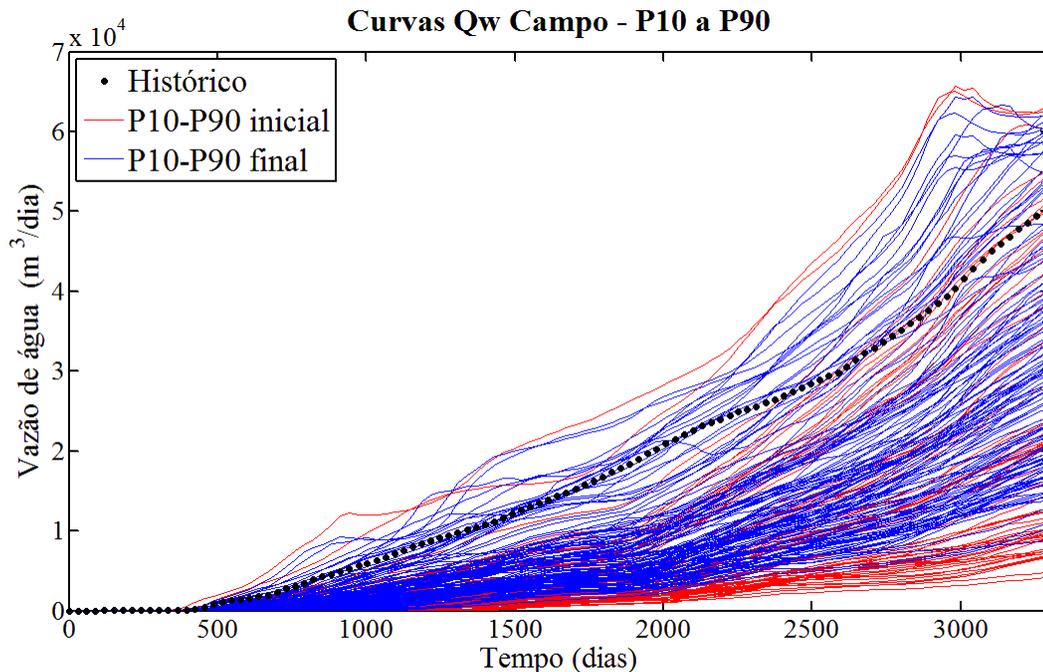


Figura 6.19 - Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 2 – Caso A

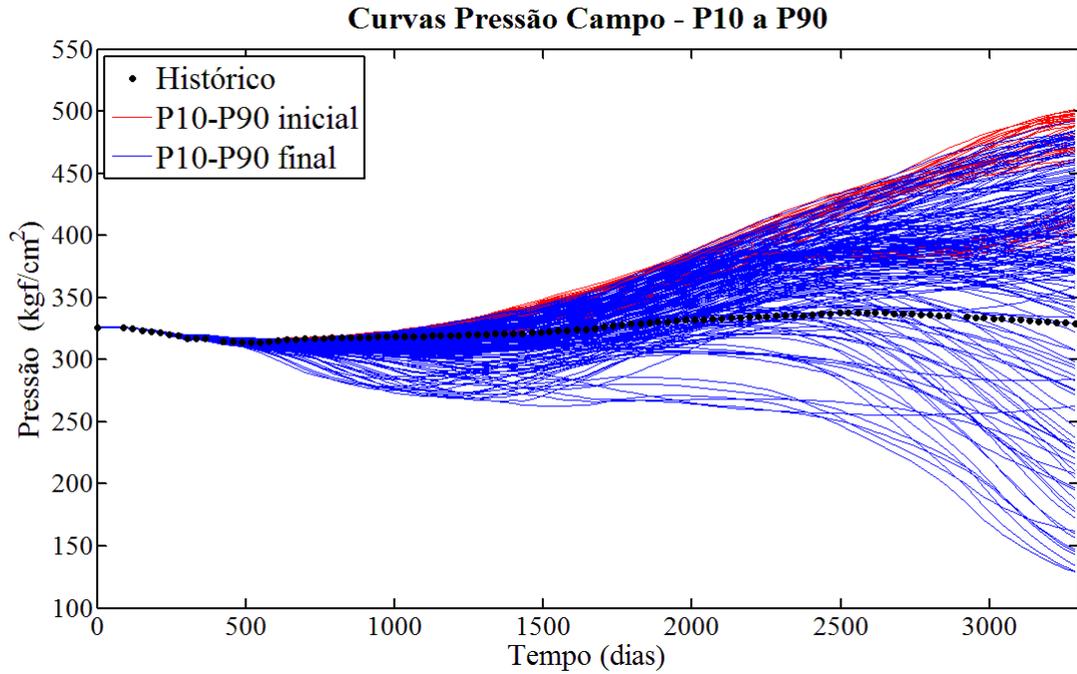


Figura 6.20 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 2 – Caso A.

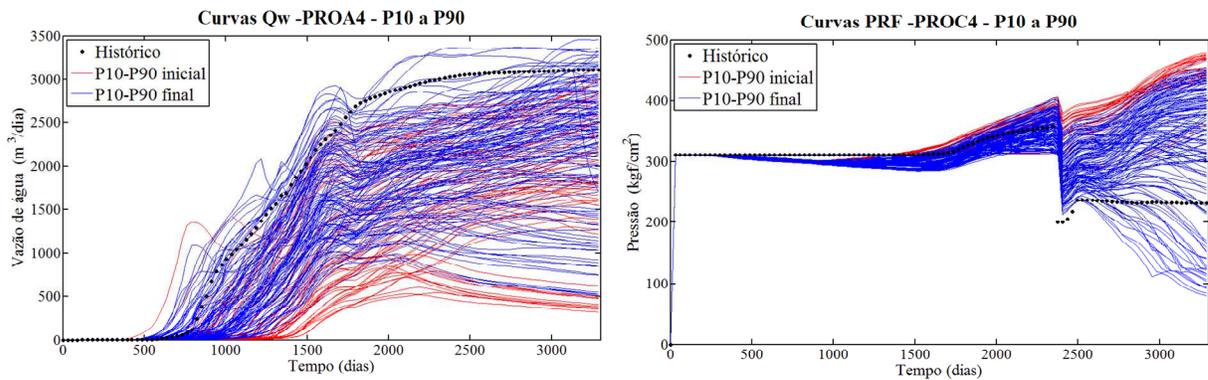


Figura 6.21 – Curvas de  $Q_w$  do PROA-4 e PRF do PROC-4 para os modelos entre P10 e P90, resultantes do Método 2 – Caso A..

Além disso, foi feita também uma sensibilidade ao fator  $F$ , presente na Equação 3.7 e que serve para amplificar o  $k_{iq}$  dos casos mais bem ajustados. Os resultados da redistribuição de probabilidades para  $F= 1, 2, 2,5, 3, 5$  e 10 estão na Tabela 6.3.



Tabela 6.3 – Redistribuição de probabilidade para diferentes valores do fator  $F$ .

F=1	Probabilidade			F=2	Probabilidade			F=2,5	Probabilidade		
	0	1	2		0	1	2		0	1	2
PhiA	44%	30%	26%	PhiA	58%	24%	18%	PhiA	66%	21%	13%
FAB	44%	30%	26%	FAB	59%	23%	18%	FAB	68%	19%	13%
Falhas	31%	38%	31%	Falhas	26%	47%	27%	Falhas	22%	54%	24%
PVT	29%	35%	36%	PVT	25%	35%	40%	PVT	23%	34%	43%
krw	27%	38%	35%	krw	24%	45%	31%	krw	24%	49%	27%
F=3	Probabilidade			F=5	Probabilidade			F=10	Probabilidade		
	0	1	2		0	1	2		0	1	2
PhiA	74%	17%	9%	PhiA	94%	5%	1%	PhiA	100%	0%	0%
FAB	76%	14%	10%	FAB	96%	3%	1%	FAB	100%	0%	0%
Falhas	18%	62%	20%	Falhas	6%	87%	7%	Falhas	0%	99%	1%
PVT	23%	31%	46%	PVT	25%	18%	57%	PVT	19%	3%	78%
krw	24%	54%	22%	krw	25%	69%	6%	krw	19%	81%	0%

Os valores menores de  $F$  redistribuem de forma coerente com a resposta real, porém priorizam pouco os níveis com menores afastamentos. Valores de  $F$  superiores a 5 também foram analisados, mostrando uma redução um pouco maior na dispersão dos modelos, porém ao elevar demais o valor deste fator, acaba-se dando um peso muito alto para modelos com afastamento pequeno. O uso de um valor muito elevado de  $F$  torna o resultado determinístico, ou seja, praticamente todos os cenários (242) têm probabilidade nula, exceto um deles que terá probabilidade 100% e, que não necessariamente é o correto. Entretanto, o objetivo do trabalho é uma redução de incertezas, onde se objetiva um conjunto de modelos que oferecem bom ajuste e não um único. Sendo assim, a utilização de  $F$  entre 2 e 3 gera bons resultados para esta aplicação, o que indica coerência com os resultados mostrado acima.

A aplicação do Método 2 neste caso complexo apresenta resultados coerentes quando comparado com o Método 1, pois se consegue alguma redução da dispersão dos modelos, além de uma centralização em torno do histórico de produção. Porém, ele não consegue reduzir de forma significativa as incertezas, o que sugere a utilização do Método 3.

### 6.2.3 Método 3

O Método 3 surgiu dos dois problemas encontrados nos métodos anteriores e citados no Item 4.2. O primeiro é a combinação de diversas variáveis, como  $Q_w$  e  $PRF$  dos poços que podem possuir sentidos de crescimento diferentes, isto é, sinais diferentes, causando problemas no cálculo da simetria. O segundo é a combinação de variáveis com ordens de grandezas diferentes como as vazões de água de diferentes poços, pois, neste caso, os que possuem maior valor acabam influenciando mais na redistribuição das probabilidades.

Ambos os problemas foram resolvidos com o cálculo das novas probabilidades sendo feito para as variáveis de ajuste de cada poço individualmente, combinando, em seguida, as probabilidades obtidas como explicado nos exemplos teóricos do Item 4.2. Além disso, ele combina a simetria do Método 1 com a inversão dos afastamentos do Método 2 na fórmula do cálculo da nova probabilidade do atributo.

Desta forma, para o caso tratado, foram calculadas redistribuições de probabilidades dos atributos para as vazões de produção de água e pressões de fundo de cada poço individualmente através das Equações 3.6, 3.8 e 4.3, sendo  $F=-2,5$  e  $1/|S_n|_{máximo} = 5$  (valores das referências citadas no Item 3.2). A Figura 6.22 mostra os resultados para o uso da vazão de água do poço PROA-1 na redistribuição de probabilidades do atributo PhiA, ou seja, a FO é a diferença entre o histórico e simulado para essa vazão. Na parte superior estão os gráficos dos afastamentos quadráticos (Equação 3.3) e da função-objetivo analisada (Equação 3.1) para todos os modelos simulados. Na parte inferior está o gráfico do afastamento invertido (Equação 3.7) e da redistribuição de probabilidades obtida (Equação 4.3).

Dos gráficos da Figura 6.22, observa-se que o nível 0 apresenta valores de afastamentos invertidos mais elevados que os outros dois níveis (gráfico inferior à esquerda). Além disso, ele possui uma melhor simetria com relação ao eixo zero (afastamento nulo), tendo, portanto, sua probabilidade aumentada com relação aos demais níveis. As Figuras 6.23 e 6.24 ilustram os mesmos gráficos da Figura 6.22 para a pressão de fundo do poço PROB-3 e vazão de água do poço PROC-3, respectivamente.

A Figura 6.23 mostra que apesar dos três níveis apresentarem valores similares do afastamento invertido (gráfico inferior), a probabilidade do nível 0 é aumentada por conta da

maior simetria dos modelos em torno do histórico para este nível. Se para o cálculo das probabilidades fosse utilizado a formulação do Método 2, que não considera a simetria, o resultado obtido seria uma distribuição praticamente uniforme.

Na Figura 6.24, observa-se o resultado da redistribuição de probabilidade do atributo PhiA, utilizando-se a vazão de produção de água do poço PROC-3. Os gráficos do afastamento e do afastamento invertido indicam que os três níveis devem apresentar probabilidades bastante próximas, indicando que essa função praticamente não é influenciada pelo atributo PhiA. O nível 0 é um pouco favorecido por conta da melhor simetria em torno do histórico.

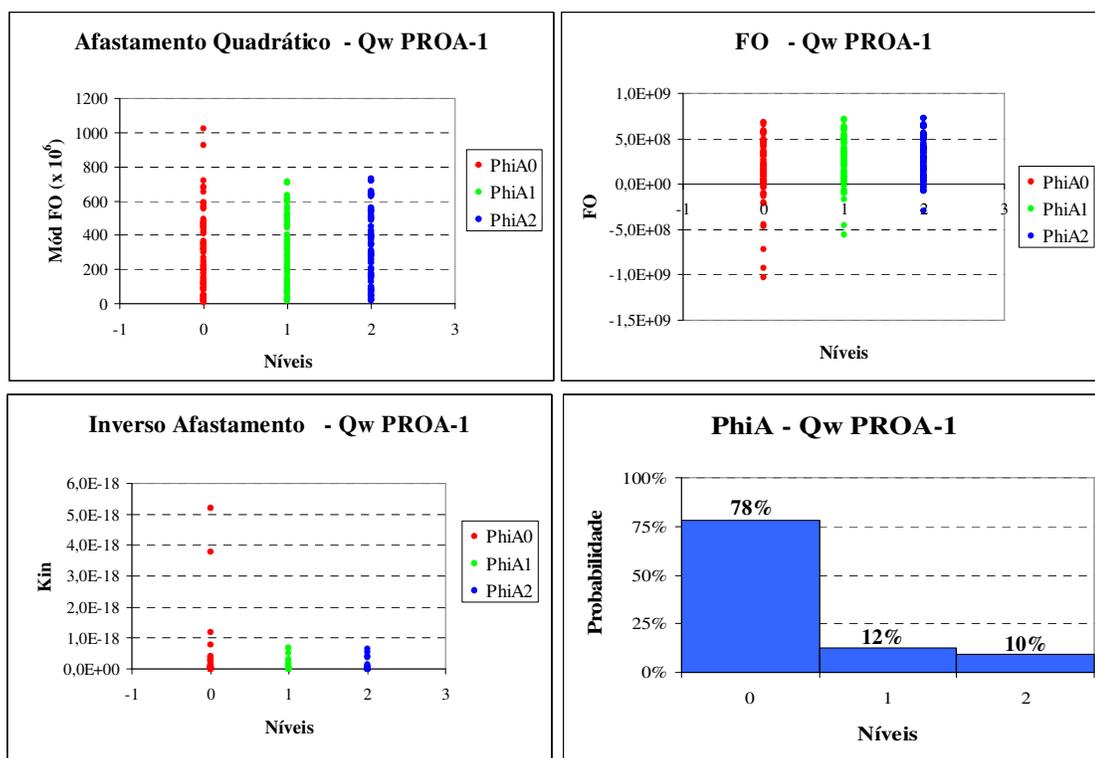


Figura 6.22 – Redistribuição de probabilidades de PhiA, utilizando a  $Q_w$  do PROA-1 – Caso A.

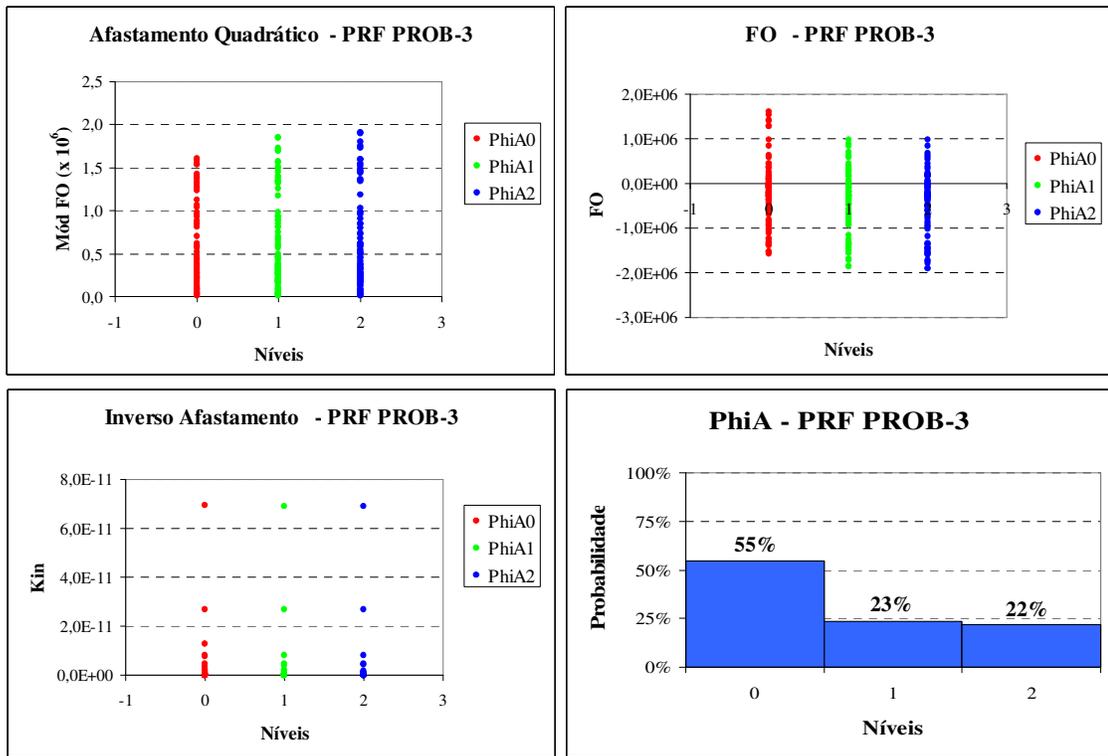


Figura 6.23 – Redistribuição de probabilidades de PhiA, utilizando a PRF do PROB-3 – Caso A.

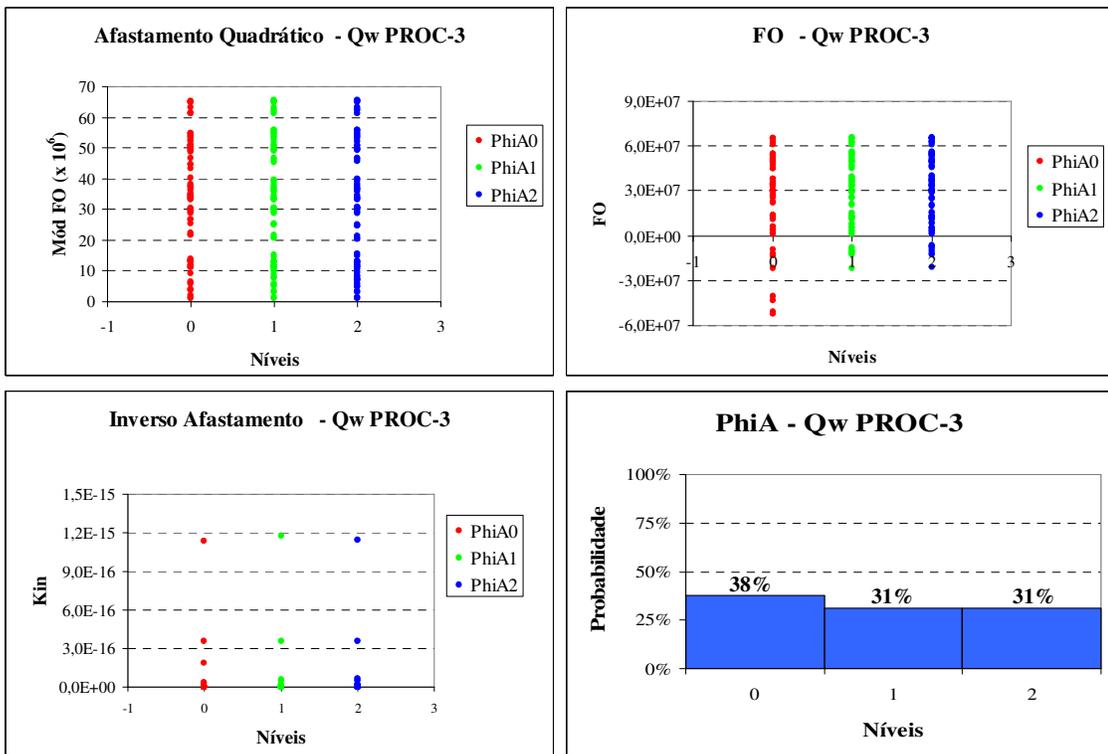


Figura 6.24 – Redistribuição de probabilidades de PhiA, a partir da Q<sub>w</sub> do PROC-3 – Caso A.

A redistribuição final das probabilidades dos atributos é feita combinando-se os valores obtidos para cada função independente de duas formas diferentes, constituindo-se nos Métodos 3.1 e 3.2. Em cada um deles, as probabilidades obtidas para as 64 funções ( $Q_w$  e  $PRF$  dos 32 poços produtores) são combinadas de forma diferente.

### 6.2.3.1 Método 3.1

Os resultados da redistribuição de probabilidades dos cinco atributos para o Método 3.1, que utiliza a média aritmética para combinar os resultados das diversas funções, estão na Tabela 6.4 e na Figura 6.25. Neste caso, utiliza-se  $F$  igual a 2,5 na Equação 3.7 (como no Método2) e  $1/|S_n|_{máximo}$  de 5 como no Método 1.

Comparando-se a Tabela 6.4 com a Tabela 6.2 observa-se que apenas a redistribuição de probabilidades do atributo PVT apresenta melhores resultados. Pelo Método 3.1, os atributos PhiA, FAB e Falhas mostram redistribuições consistentes com o resultado desejado, similar ao obtido no Método 2. Porém, o  $krw$  resulta numa distribuição praticamente uniforme, indicando que a incerteza deste atributo não é reduzida com o histórico para este método.

Tabela 6.4 – Resultados da aplicação do Método 3.1 – Caso A.

	Atributo	Probabilidade		
		0	1	2
1	PhiA	55%	23%	22%
2	FAB	59%	22%	19%
3	Falhas	23%	47%	30%
4	PVT	7%	27%	66%
5	krw	33%	36%	31%

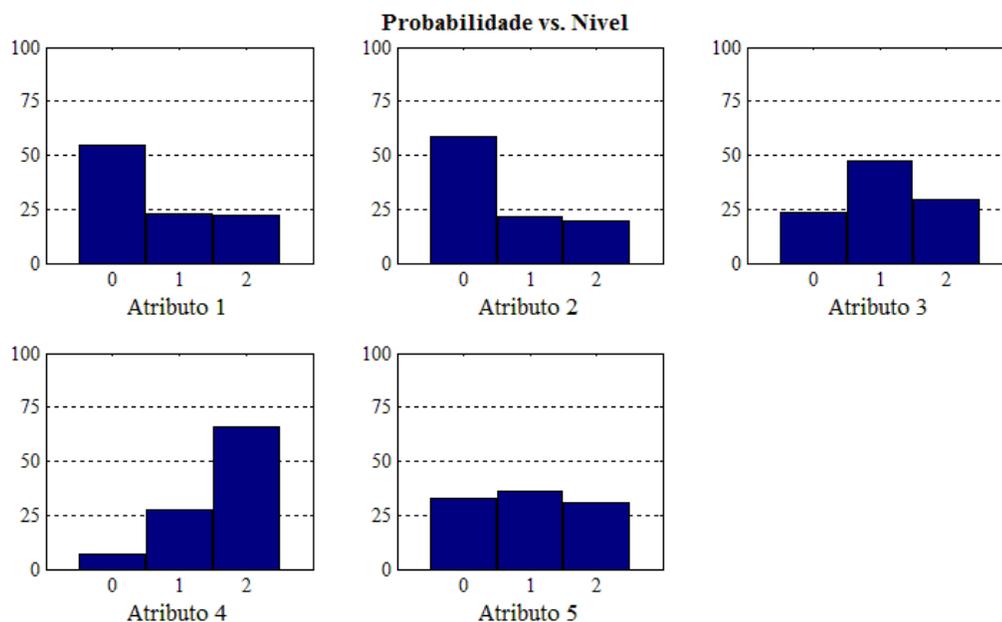


Figura 6.25 – Redistribuição de probabilidades pelo Método 3.1 – Caso A.

A análise das curvas de incerteza da Figura 6.26 mostra que para a produção de água, ocorre redução dos afastamentos com relação ao histórico para percentis menores que 70%, resultado um pouco pior que o do Método 2. Porém, neste caso há uma melhor centralização em torno do histórico que no Método 2. Já para a pressão dos poços, o resultado mostrado é similar ao do Método 2, visto que a há uma diminuição do valor da FO nos percentis acima de 50% e um aumento, nos percentis abaixo. Vale destacar que tais curvas foram traçadas de forma similar a descrita nos itens 6.2.1 e 6.2.2 para os Métodos 1 e 2, respectivamente.

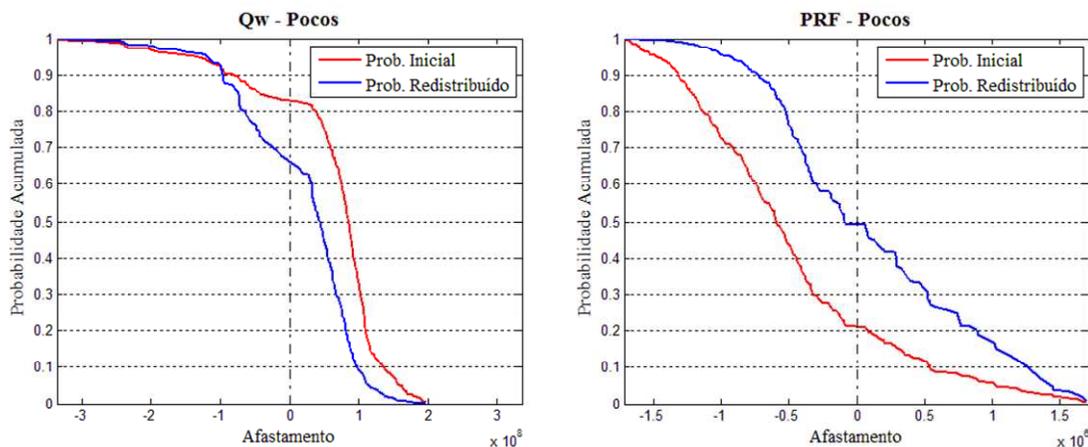


Figura 6.26 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 3.1 – Caso A.

A produção de água do campo de todos os modelos entre os percentis P10 e P90 das curvas de incerteza inicial e final com FO dada pela combinação dos afastamentos das vazões de água dos poços está ilustrada na Figura 6.27. Houve uma pequena diminuição das incertezas do reservatório, bastante similar a do Método 2, inclusive no número de modelos extraídos da curva final, 135. Uma diferença entre elas é que o Método 3.1 seleciona mais curvas acima do histórico que o anterior, ou seja, tenta centralizar mais o histórico nos modelos escolhidos. De forma análoga, para os gráficos de pressão da Figura 6.28, também é observada uma redução das incertezas pequena e com número de modelos finais bastante parecido, 136.

A obtenção de alguns resultados não satisfatórios está associada ao uso da média aritmética para combinar as redistribuições obtidas para as diferentes funções dos poços. Isso ocorre porque a redistribuição final acaba sendo penalizada por funções que não dependem de determinado atributo, e que geram como resultado uma distribuição uniforme para os três níveis. Desta forma, ao ser combinado na média, este resultado faz a probabilidade final do nível melhor cair e do pior subir, prejudicando a distribuição de probabilidades final do atributo.

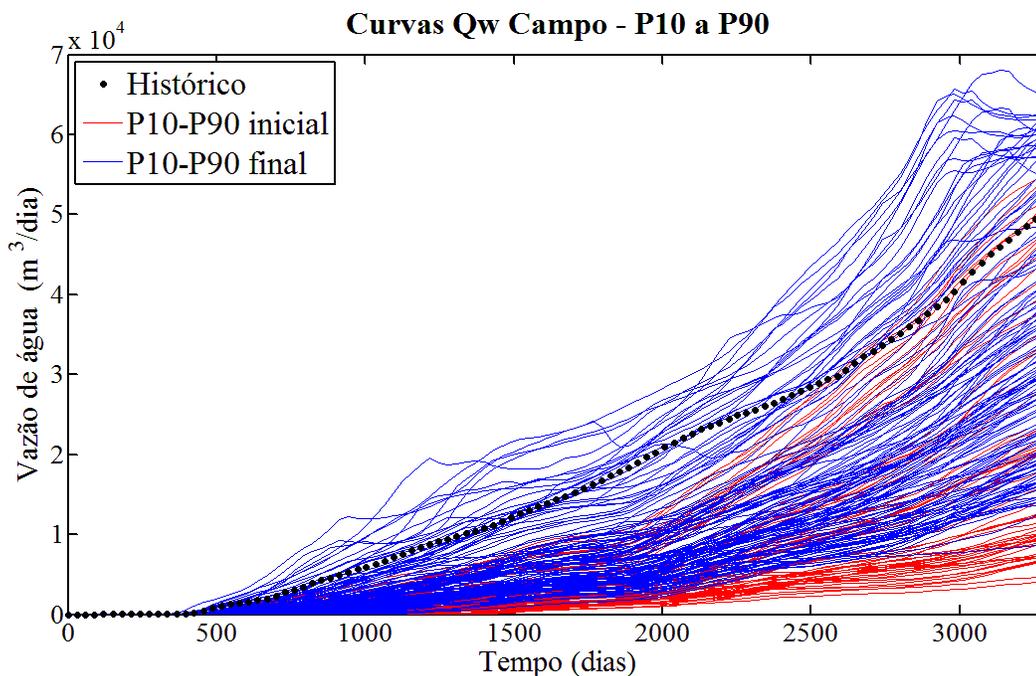


Figura 6.27 – Curvas de produção de água do campo para os modelos entre P10 e P90 resultantes do Método 3.1 – Caso A.

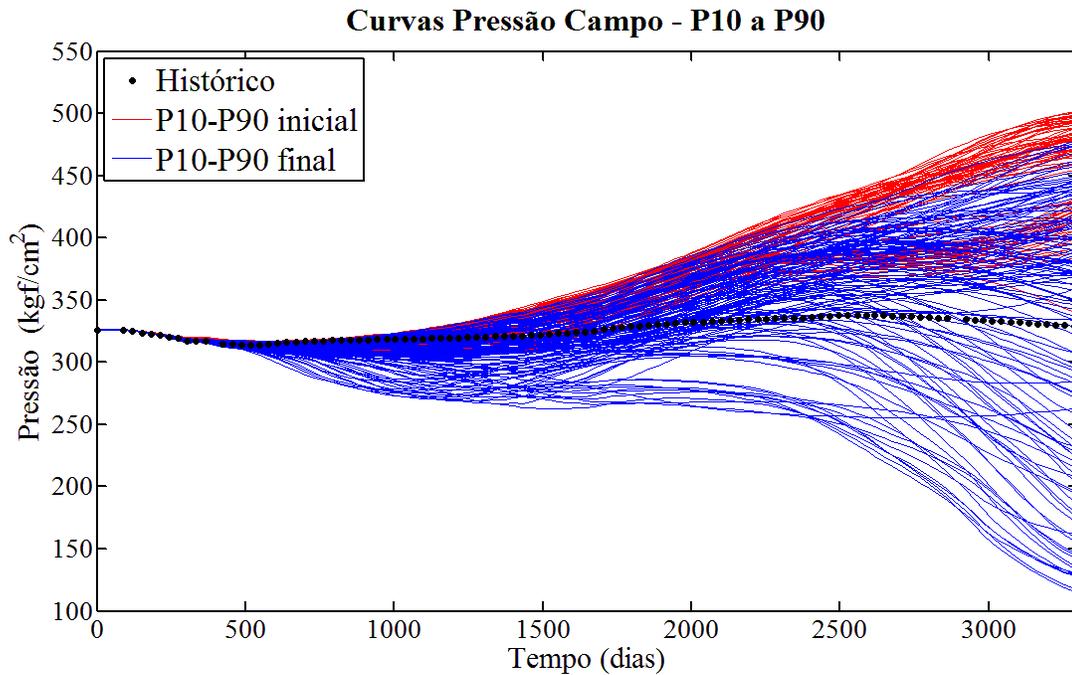


Figura 6.28 – Curvas de pressão do campo para os modelos entre P10 e P90 resultantes do Método 3.1 – Caso A.

### 6.2.3.2 Método 3.2

Para melhor redistribuir as probabilidades dos atributos é utilizada uma média aritmética ponderada pelo índice de sensibilidade ( $IS$ ) da função considerada com relação ao atributo incerto. Desta forma, se determinado atributo não influencia uma função ( $Q_w$  ou  $PRF$ ), o peso da redistribuição de probabilidade dele para esta função possui valor bem pequeno, e praticamente não influencia a média final, onde são combinadas as redistribuições de todas as funções.

A Tabela 6.5 e a Figura 6.29 mostram os resultados da redistribuição de probabilidades para os cinco atributos críticos, utilizando o Método 3.2. No caso em questão, é utilizado  $F$  de 2,5 (Método 2) na Equação 3.7 e  $1/|S_n|_{máximo}$  igual a 5 (Método1).



Tabela 6.5 – Resultados da aplicação do Método 3.2 – Caso A.

	Atributo	Probabilidade		
		0	1	2
1	PhiA	81%	11%	7%
2	FAB	71%	15%	14%
3	Falhas	22%	48%	30%
4	PVT	3%	27%	70%
5	krw	40%	36%	24%

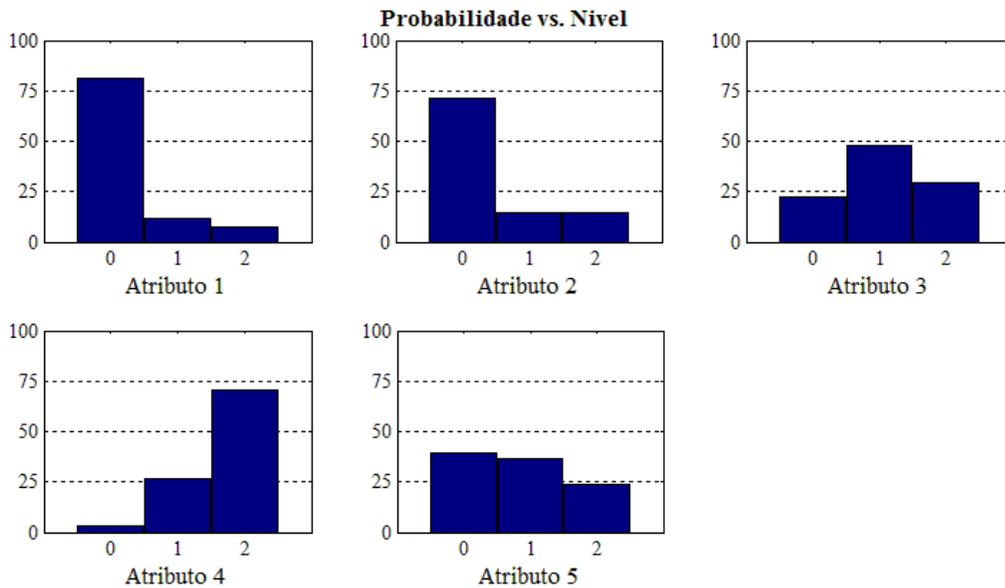


Figura 6.29 – Redistribuição de probabilidades pelo Método 3.2 – Caso A.

As novas probabilidades obtidas para os atributos PhiA, FAB, Falhas e PVT são bem mais coerentes com as respostas esperadas, dado que a combinação de parâmetros utilizada para gerar o histórico é conhecida. Tais resultados são melhores, porque quando um atributo não influencia determinada função, o peso dela na média ponderada fica pequeno no cálculo da redistribuição de probabilidades final do atributo. Um exemplo disso é a redistribuição de probabilidades do atributo PhiA que praticamente não influencia poços do Bloco C, sendo assim, o peso destes poços na média final é muito inferior ao utilizado para os poços do Bloco A.

O atributo krw apresenta probabilidades muito próximas para os níveis 0 e 1, diminuindo a probabilidade do nível 2. Sabe-se que o nível 1 foi utilizado para gerar o histórico, e o fato do nível 0 ter uma probabilidade um pouco maior pode ser explicado pela não utilização de todas as incertezas na metodologia, visto que 8 atributos incertos ficam no nível mais provável que não

necessariamente é o correto. Provavelmente, alguns atributos não utilizados influenciam os resultados do krw, e ao incorporá-los na análise, ter-se-ia uma resposta melhor para a redistribuição de probabilidades da permeabilidade relativa à água.

As curvas de incerteza para a produção de água e pressão dos poços estão na Figura 6.30. Elas foram obtidas conforme a descrição do Item 2.2.3, de forma similar ao feito para os demais métodos. Para a produção de água dos poços, o resultado em relação ao método anterior (3.1) é melhor, com a curva se aproximando mais do eixo zero, principalmente no ponto que se refere ao percentil 50%. Ao comparar com o Método 2, os resultados para percentis acima de 70% é pior, porém para o restante da curva os afastamentos são reduzidos, além de haver uma melhor centralização em torno do histórico com a curva cruzando o eixo zero bem próxima ao 50%.

Já para a pressão dos poços, a curva reduz um pouco a dispersão, porém piora a centralização em torno do histórico quando comparada aos dois métodos anteriores (2 e 3.1). Além disso, ela aumenta os afastamentos para percentis menores que 60%. Das curvas de incerteza final e inicial dos Métodos, 3.1 e 3.2 (Figuras 6.26 e 6.30), podem-se extrair os afastamentos dos modelos representativos da faixa de incerteza P1, P10, P90 e P99, conforme feito no Item 6.2.2 para traçar os gráficos de “bastão” que mostram o espalhamento e a centralização resultantes dos métodos.

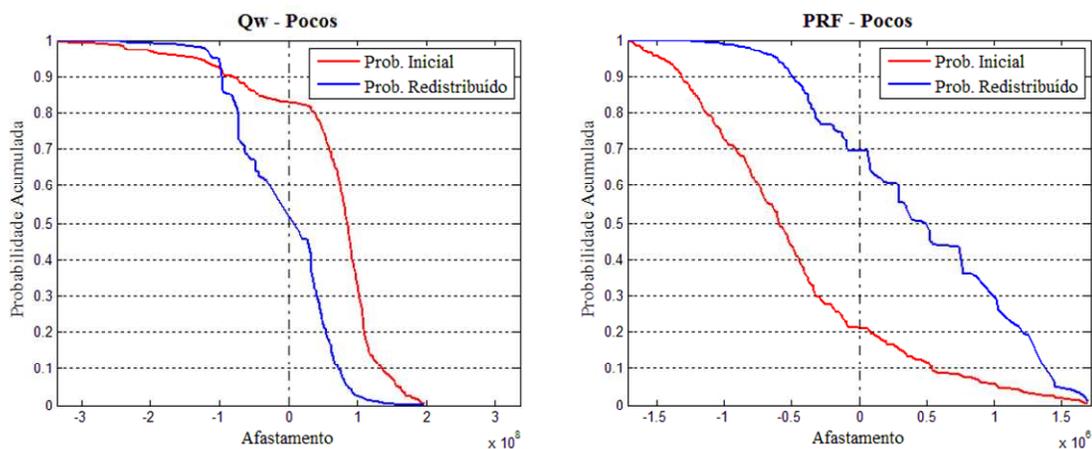


Figura 6.30 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 3.2 – Caso A.

Ao considerar a FO como a produção de água dos poços, observa-se na Figura 6.31 a melhora ao se passar de um método para o outro, diminuindo a dispersão e centralizando em

torno do zero (histórico). Apesar do número de modelos situados entre P10 e P90, ter diminuído bastante com relação aos demais métodos (inicial: 194, final: 72), a redução da dispersão foi bastante similar a do Método 2, cerca de 23%,. Isto provavelmente está associado à grande heterogeneidade do modelo, aos intervalos de incerteza selecionados para os atributos e à utilização de apenas cinco atributos incertos para a aplicação da metodologia, ficando os demais no nível provável.

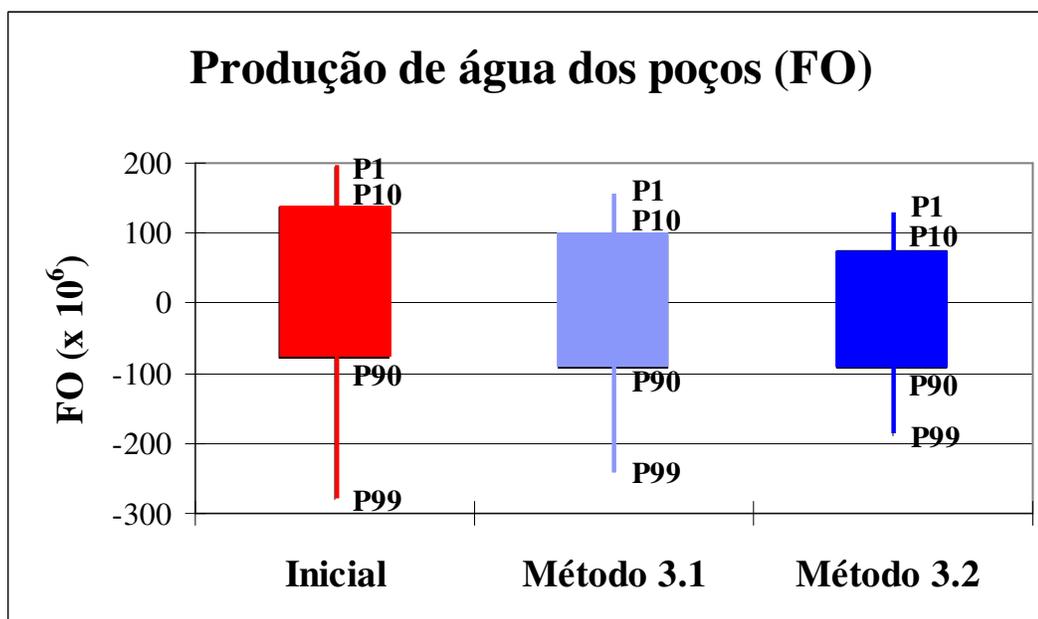


Figura 6.31 – Comparativo da FO de  $Q_w$  inicial e após aplicação do Método 3 – Caso A.

Já no caso da pressão (Figura 6.32), o método intermediário (3.1) aumenta o espalhamento apesar de centralizar um pouco melhor no histórico de pressão. O Método 3.2, possui a mesma dispersão da distribuição inicial, porém, um pouco melhor centralizada em relação aos dados medidos, além de ter um número menor de modelos entre P10 e P90 (inicial: 194, final: 99).

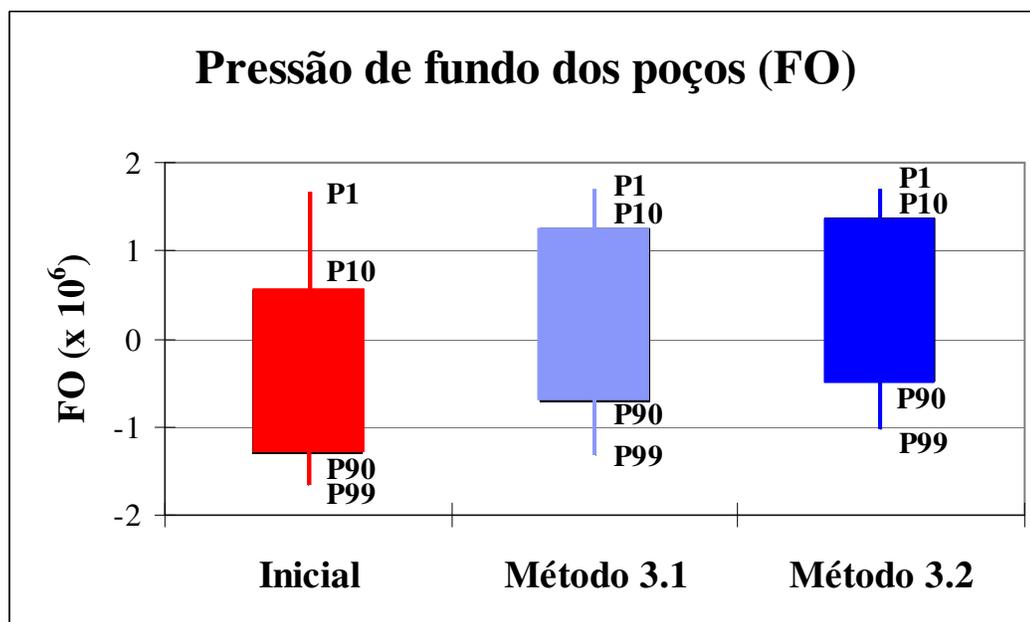


Figura 6.32 – Comparativo da FO de *PRF* dos poços antes e depois da aplicação do Método 3 – Caso A.

A Figura 6.33 ilustra a produção de água dos modelos situados entre os percentis P10 e P90 das curvas de incerteza final e inicial da combinação dos afastamentos das produções de água dos poços. Neste método houve uma redução mais significativa das incertezas do reservatório, com a eliminação de uma quantidade razoável de modelos mais distantes do histórico. O número de modelos selecionados nas curvas de incerteza foi reduzido de 194 para apenas 72 modelos, estando estes em torno dos dados de produção. Nos gráficos dos poços da Figura 6.34, traçados utilizando-se os mesmos modelos da Figura 6.33, é observada uma boa redução das incertezas para a vazão de água do poço PROA-4, no entanto, o poço PROA-5, não exhibe diminuição nas incertezas visto que as curvas iniciais e finais estão bastante misturadas.

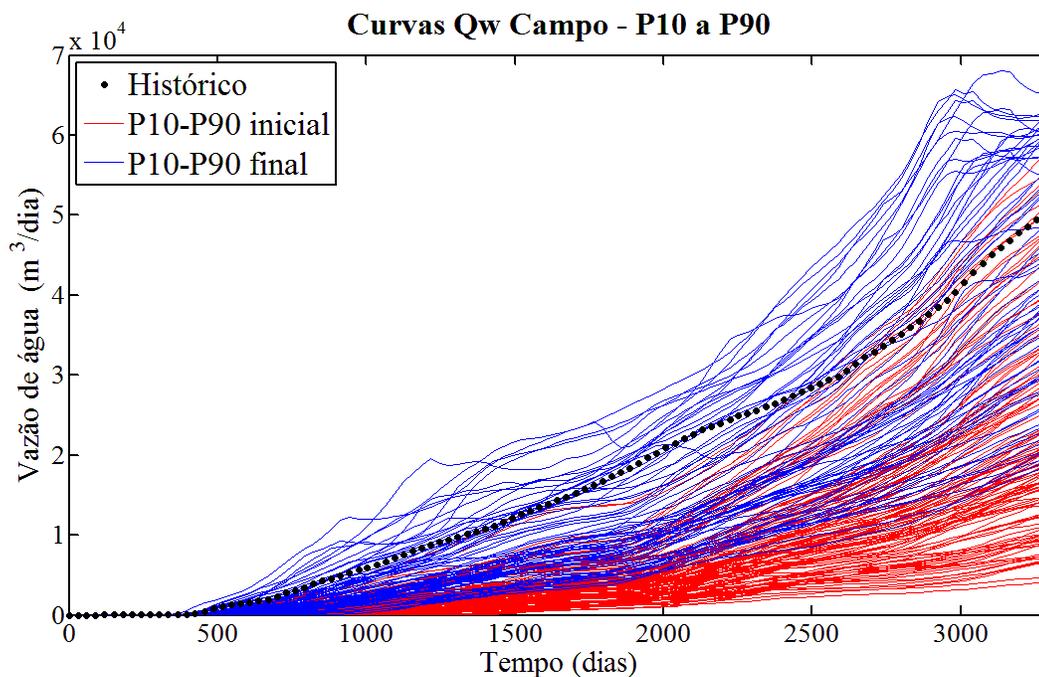


Figura 6.33 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.

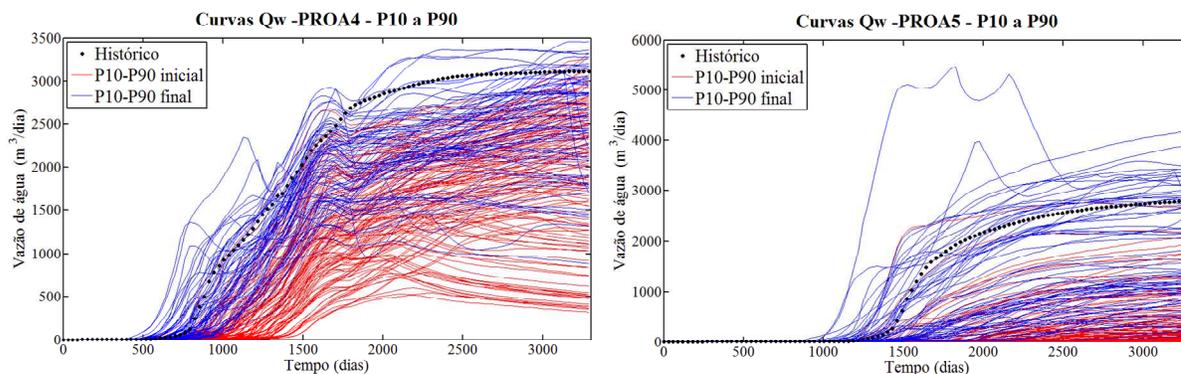


Figura 6.34 – Curvas de produção de água dos poços PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.

Vale ressaltar que os modelos acima foram escolhidos com base na curva de incerteza para a vazão de água dos poços, porém uma análise similar deve ser feita para as pressões dos poços. O número de modelos entre P10 e P90, neste caso, aumenta para 99, sendo os resultados parecidos com os mostrados acima, apesar do número maior de modelos.

Os gráficos da pressão do campo e pressões de fundo dos poços, com modelos obtidos da curva de incerteza das pressões, também mostram uma razoável redução das incertezas, como

exemplificado nas Figuras 6.35 e 6.36, para o campo e para os poços PROB-2 e PROC-4, respectivamente.

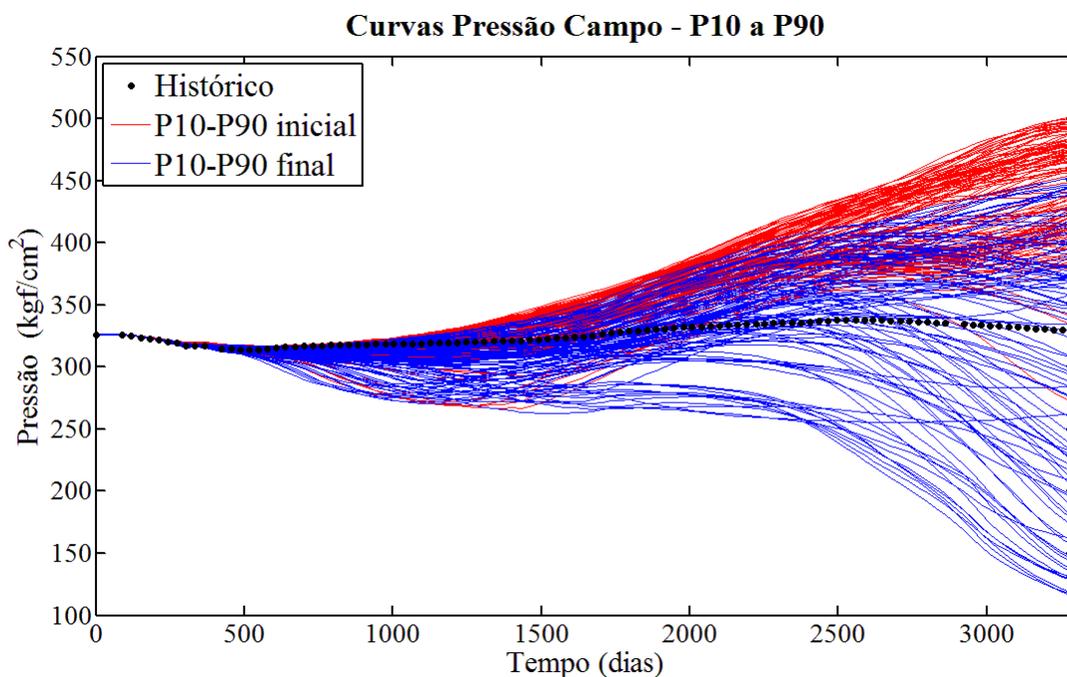


Figura 6.35 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.

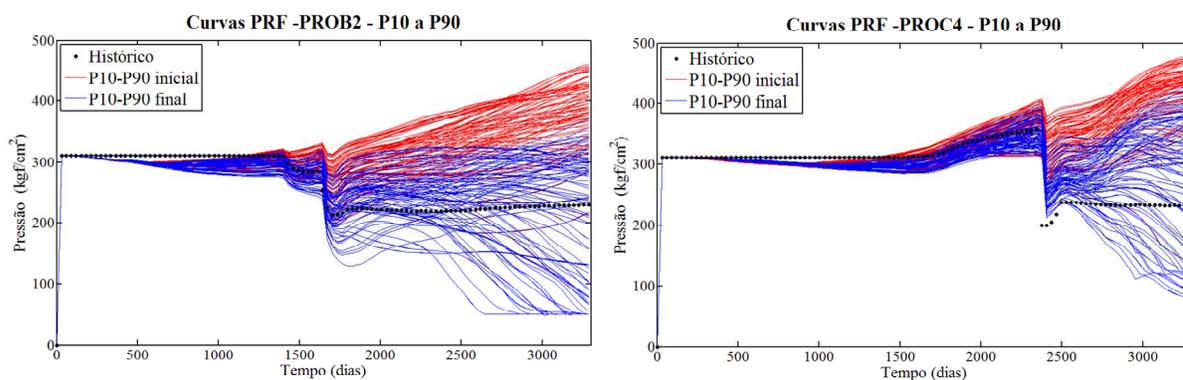


Figura 6.36 – Curvas de pressão de fundo dos poços PROB-2 e PROC-4 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso A.

Por fim, foi feita uma sensibilidade ao fator  $F$  e ao  $1/|S_n|_{máximo}$  das Equações 3.7 e 4.3, respectivamente. Os resultados da redistribuição de probabilidades pelo Método 3.2 para  $F=1, 2, 2,5, 3, 5$  e  $10$  sem alterar o  $1/|S_n|_{máximo} = 5$  estão na Tabela 6.6. Diferentemente do Método 2,

até para valores menores de  $F$  há uma redistribuição de probabilidades razoável, apenas os atributos Falhas e krw não possuem resultados tão bons. O primeiro porque a probabilidade continua praticamente uniforme e o segundo porque tem o nível 0 como resposta ao invés do nível 1, provavelmente pelos motivos já explicados anteriormente.

Ao elevar o fator  $F$  para valores superiores a 5, as probabilidades ficam praticamente constantes, porque as redistribuições para as funções individuais tendem para um resultado determinístico, ou seja, tem-se um modelo com probabilidade de 100%, então, a combinação delas passa a não variar. De forma similar ao Método 2, a utilização de  $F$  entre 2 e 3 gera bons resultados, priorizando os modelos com afastamentos pequenos, mas sem gerar resultados determinísticos.

Tabela 6.6 – Redistribuição de probabilidades pelo Método 3.2 para diferentes valores de  $F$  – Caso A.

F=1	Probabilidade			F=2	Probabilidade			F=2,5	Probabilidade		
	0	1	2		0	1	2		0	1	2
PhiA	69%	18%	13%	PhiA	79%	13%	8%	PhiA	81%	11%	7%
FAB	63%	20%	17%	FAB	69%	16%	15%	FAB	71%	15%	14%
Falhas	30%	36%	33%	Falhas	23%	46%	31%	Falhas	22%	48%	30%
PVT	9%	29%	62%	PVT	4%	27%	69%	PVT	3%	27%	70%
krw	43%	29%	28%	krw	42%	34%	24%	krw	40%	36%	24%
F=3	Probabilidade			F=5	Probabilidade			F=10	Probabilidade		
	0	1	2		0	1	2		0	1	2
PhiA	82%	11%	7%	PhiA	85%	10%	5%	PhiA	85%	12%	3%
FAB	72%	14%	14%	FAB	74%	11%	15%	FAB	74%	11%	15%
Falhas	22%	49%	29%	Falhas	21%	54%	25%	Falhas	19%	58%	23%
PVT	2%	27%	71%	PVT	1%	28%	71%	PVT	1%	28%	71%
krw	38%	38%	24%	krw	35%	40%	25%	krw	34%	41%	25%

Para o  $1/|S_n|_{\text{máximo}}$ , foram analisados os valores 1, 3, 5, 10, 20 e 50, estando na Tabela 6.7 os resultados da redistribuição de probabilidades para o Método 3.2, mantendo  $F=2,5$ . O objetivo do fator  $1/|S_n|$  da Equação 4.3 é dar um peso maior aos níveis com modelos mais simétricos em relação ao histórico. Ao se considerar  $1/|S_n|=1$ , os níveis de todos os atributos passam a ter o mesmo peso, ou seja, não se prioriza nenhum deles.

No entanto, ao aumentar este valor para 3 ou mais, as probabilidades calculadas ficam praticamente constantes, oscilando em alguns atributos de um ou dois pontos percentuais somente. Isso indica que acima deste valor de  $1/|S_n|_{máximo}$  os resultados ficam insensíveis ao peso dado pela simetria, ou seja, mesmo aumentando mais este termo, as distribuições não se alteram, pois provavelmente o valor da probabilidade é mais influenciado pela inversão dos afastamentos do que pela simetria. Desta forma, o uso de valores acima de 3 para o termo  $1/|S_n|_{máximo}$  garante resultados consistentes para a metodologia.

Tabela 6.7 – Redistribuição de probabilidades pelo Método 3.2 para diferentes valores de  $1/|S_n|_{máximo}$  – Caso A.

$1/ S_n =1$	Probabilidade			$1/ S_n =3$	Probabilidade			$1/ S_n =5$	Probabilidade		
	0	1	2		0	1	2		0	1	2
PhiA	77%	14%	9%	PhiA	81%	12%	7%	PhiA	81%	11%	7%
FAB	70%	14%	16%	FAB	71%	14%	15%	FAB	71%	15%	14%
Falhas	23%	52%	25%	Falhas	22%	50%	28%	Falhas	22%	48%	30%
PVT	3%	29%	68%	PVT	3%	27%	70%	PVT	3%	27%	70%
krw	35%	40%	25%	krw	39%	37%	24%	krw	40%	36%	24%
$1/ S_n =10$	Probabilidade			$1/ S_n =20$	Probabilidade			$1/ S_n =50$	Probabilidade		
	0	1	2		0	1	2		0	1	2
PhiA	82%	11%	7%	PhiA	82%	11%	7%	PhiA	81%	11%	7%
FAB	71%	15%	14%	FAB	71%	15%	14%	FAB	71%	15%	14%
Falhas	23%	47%	30%	Falhas	23%	46%	31%	Falhas	25%	45%	30%
PVT	4%	26%	70%	PVT	4%	26%	70%	PVT	4%	26%	70%
krw	41%	35%	24%	krw	42%	35%	23%	krw	43%	34%	23%

Os resultados obtidos mostram que o Método 3.2 é mais robusto que os demais, gerando respostas melhores e mais consistentes mesmo para casos complexos. Acredita-se que a utilização de um número maior de atributos incertos levaria a uma redução maior das incertezas, porém para isso é necessário um número elevado de simulações ou a utilização de métodos de amostragem, não tratados neste trabalho. Outra forma de refinar mais os resultados é a aplicação do Método 4, que é simplesmente uma nova aplicação do Método 3.2, reavaliando as faixas de incerteza dos parâmetros incertos, as quais podem estar superestimadas para alguns atributos.



#### 6.2.4 Método 4

Apesar das melhorias obtidas com os novos métodos, as curvas de produção de água e de pressão do campo e principalmente as dos poços (Figuras 6.34 e 6.36) ainda apresentam um espalhamento considerável e possuem algumas curvas bem diferentes do histórico de produção. Sendo assim, houve uma redefinição dos níveis dos cinco atributos e uma nova aplicação do Método 3.2, conforme mostrado na Figura 4.5 para refinar os resultados obtidos.

Para a porosidade do Bloco A antes de efetuar a redistribuição pelas Equações 4.4, 4.5 e 4.6, foram determinados os limites inferior e superior do atributo de acordo com seus valores iniciais, através de médias, estando o resultado na Figura 6.37. A partir destes valores e das probabilidades da Tabela 6.5 os novos valores dos níveis foram determinados conforme descrito no Item 4.3, sendo obtidos para os níveis 0, 1 e 2 os valores contidos na Tabela 6.8. De forma similar, os níveis do atributo FAB foram determinados respeitando-se os limites físicos dele, que não pode ser menor que zero e nem maior que 1.

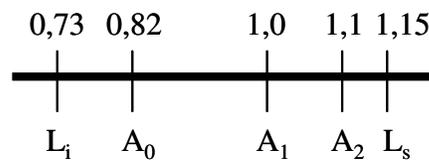


Figura 6.37 – Valores iniciais do atributo PhiA.

Tabela 6.8 – Novos níveis dos atributos – Caso A.

	Atributo			
		0	1	2
1	PhiA	0,78	0,83	0,93
2	FAB	0	0,05	0,1
3	Falhas	Modn0	Modelo 1	Modn2
4	PVT	PVT0	PVT1	PVT2
5	krw	krw0	krwn1	krw1

Os novos valores dos níveis dos modelos de Falhas e do krw foram obtidos a partir de interpolações dos dados iniciais. No caso das falhas, o modelo de maior probabilidade após a primeira aplicação é o Modelo 1, sendo assim, os outros níveis 0 e 2 foram obtidos de forma a se aproximarem deste modelo inicial, acrescentando e retirando falhas respectivamente. Os três

modelos estão na Figura 6.38. Como as probabilidades dos níveis 0 e 1 do  $kr_w$  foram próximas, os novos níveis passaram a ser as próprias curvas  $kr_w0$  e  $kr_w1$  (níveis 0 e 2, respectivamente), criando-se uma curva intermediária entre as duas (constituindo o novo valor do nível 1), como exemplificado na Figura 6.39.

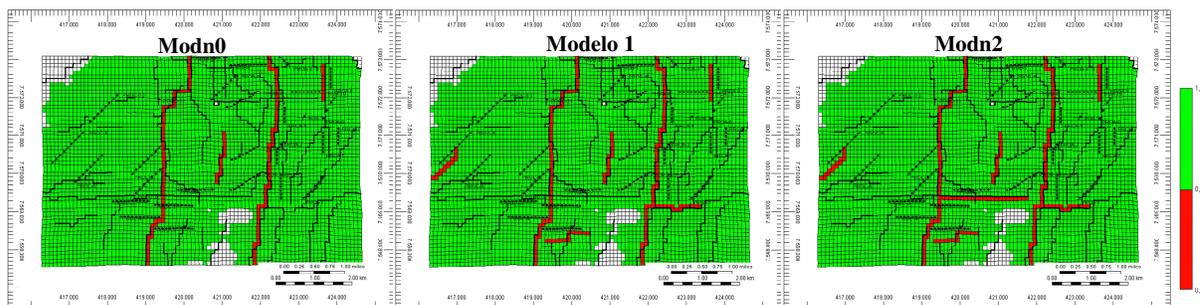


Figura 6.38 – Modelos novos de falhas internas – Caso A.

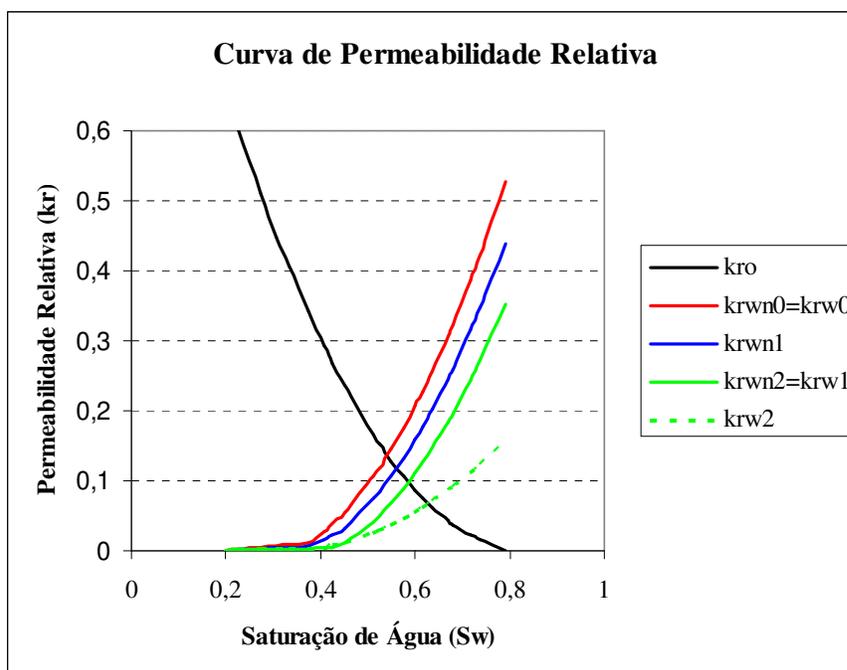


Figura 6.39 – Novas curvas de permeabilidade relativa à água – Caso A.

O último atributo analisado é a PVT, cujos níveis iniciais são diferentes tabelas obtidas de análises laboratoriais. Por ser uma variável discreta composta por diferentes dados tabulados, a interpolação ou extrapolação para criação de novas tabelas deveria ser feita em laboratório. Sendo assim, as três tabelas iniciais foram mantidas, mesmo com o nível 2 (PVT2) apresentando probabilidade de cerca de 70% após a aplicação do Método 3.2.

De posse dos resultados das simulações com os novos níveis dos atributos é aplicado o Método 3.2 conforme feito anteriormente. A Tabela 6.9 e a Figura 6.40 mostram os resultados da redistribuição de probabilidades para os cinco atributos após a aplicação do Método 4.

Tabela 6.9 – Resultados da aplicação do Método 4 – Caso A.

	Atributo	Probabilidade		
		0	1	2
1	PhiA	18%	42%	40%
2	FAB	59%	20%	21%
3	Falhas	26%	43%	31%
4	PVT	10%	24%	66%
5	krw	7%	29%	64%

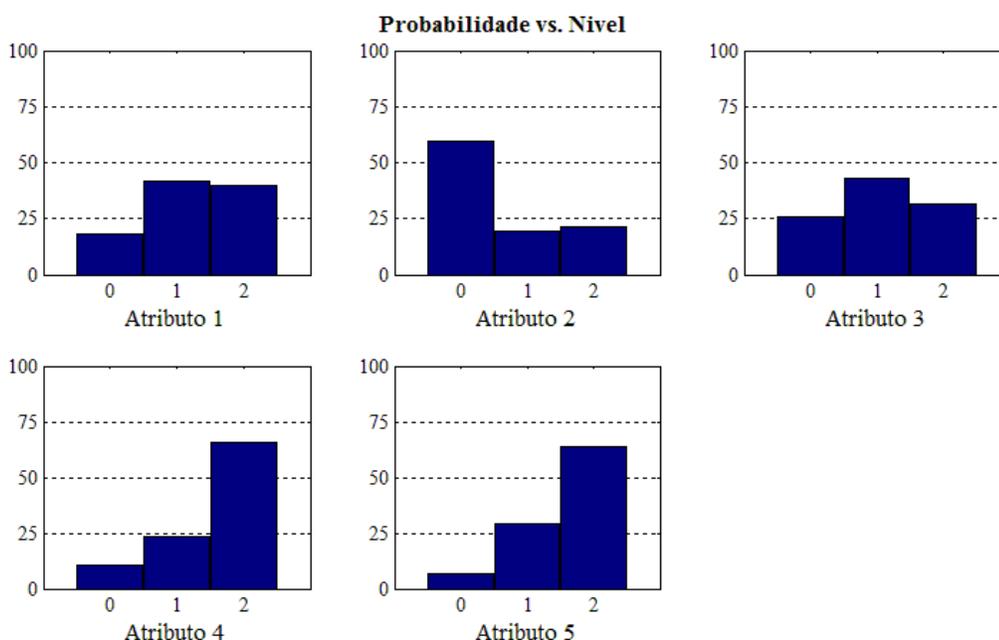


Figura 6.40 – Probabilidades após aplicação do Método 4 – Caso A.

As novas probabilidades obtidas para todos os atributos pelo Método 4 são coerentes com as respostas esperadas, dado que a combinação de parâmetros utilizada para gerar o histórico é conhecida. O atributo PhiA tem a probabilidade dos níveis 1 e 2 muito próximas, indicando que numa próxima iteração do método, os novos níveis devem ser definidos com valores mais próximos deles. O atributo Falhas tem sua resposta com probabilidade mais elevada no nível 1, porém os níveis 0 e 2 também apresentam valores consideráveis. Uma possível justificativa para

isso é a grande proximidade entre os modelos de falhas propostos para os níveis e, além disso, o fato das falhas locais alterarem o comportamento de alguns poços específicos.

A Figura 6.41 mostra a curva de incerteza para a produção de água, comparando-se a curva inicial (com probabilidades uniformes para os atributos – curva vermelha), após a aplicação do Método 3.2 (curva verde) e após o Método 4 (curva azul), indicando uma maior aproximação do eixo zero (histórico). Além disso, é importante observar que a curva final corta o eixo histórico aproximadamente no percentil 50%, ou seja, o modelo mais provável é o com menor afastamento.

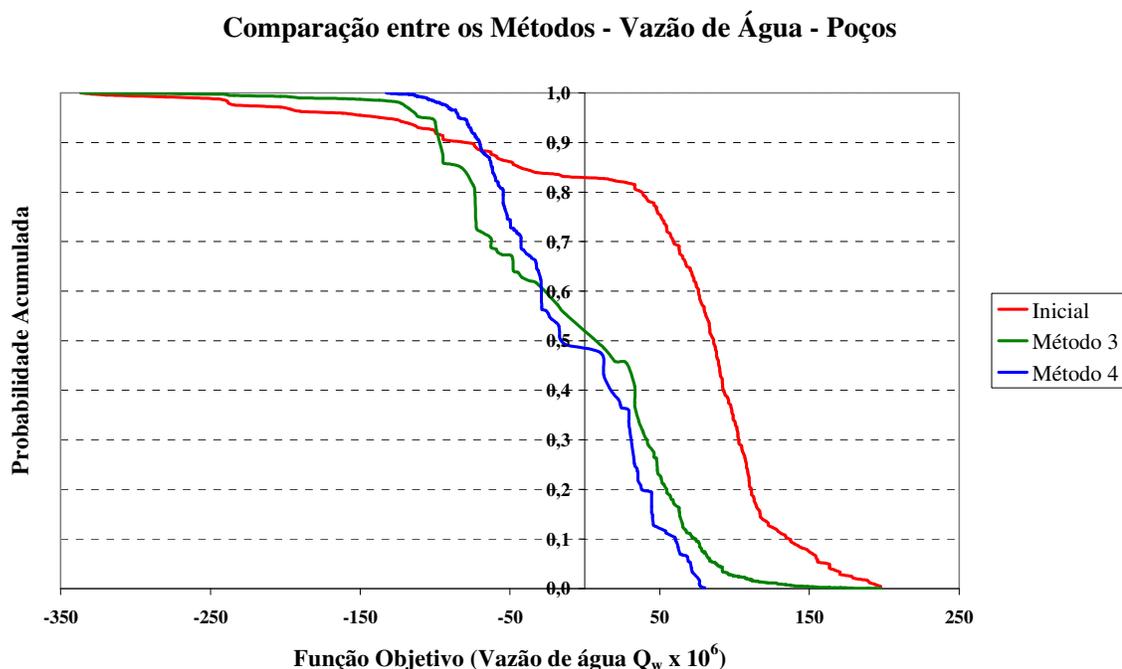


Figura 6.41 – Comparação entre as curvas de incerteza para vazão de água inicial e dos Métodos 3 e 4.

A curva de incerteza para a pressão dos poços da Figura 6.42 também mostra uma boa aproximação com relação ao eixo zero, ao longo de toda a curva. Vale ressaltar que os modelos com menor afastamento estão bem próximos do percentil 50%, apesar da centralização em torno do histórico não estar tão boa como a da vazão de água.

### Comparação entre os Métodos - Pressão de Fundo - Poços

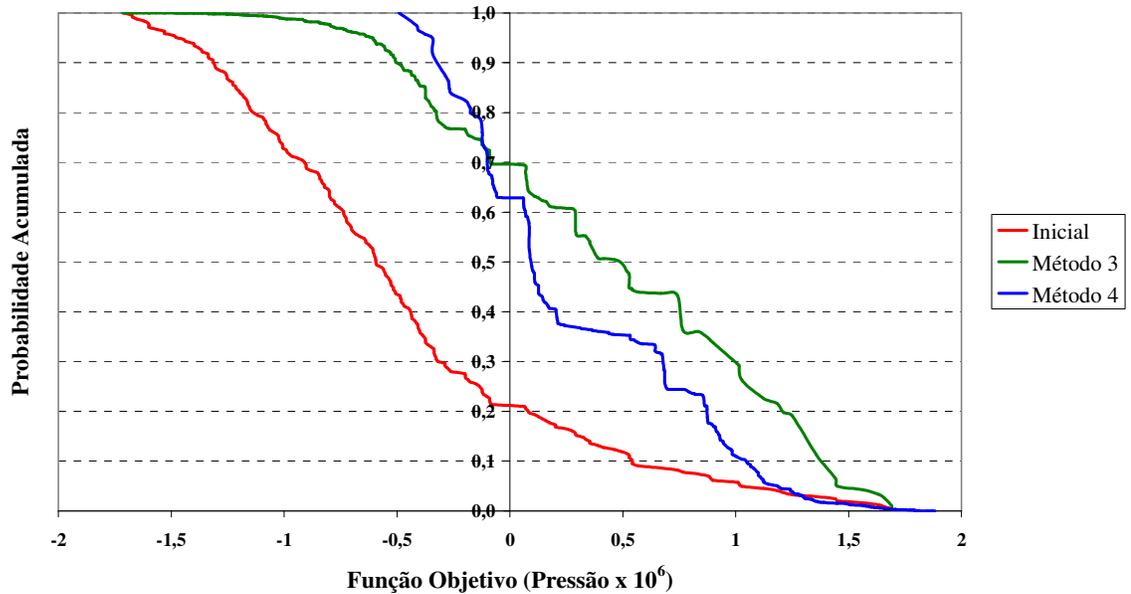


Figura 6.42 – Comparação entre as curvas de incerteza para pressão inicial e dos Métodos 3 e 4.

Conforme explicado no Capítulo 2, os afastamentos dos modelos representativos da faixa de incerteza P1, P10, P90 e P99 podem ser extraídos das curvas das Figuras 6.41 e 6.42 para traçar os gráficos que mostram o espalhamento e a centralização resultantes. A Figura 6.43 compara a dispersão resultante dos métodos 3 e 4 para a vazão de água e para a pressão.

Considerando-se a FO da produção de água dos poços, a redução da dispersão aumenta de 23% para 40% com relação ao caso inicial, havendo também uma melhoria na centralização em torno do histórico. Já para os dados de pressão dos poços, a dispersão diminuiu em 25% com relação ao caso inicial, fato observado na diminuição do corpo do “bastão” do gráfico. Quanto à centralização com relação do histórico há apenas uma pequena melhora com relação ao caso inicial.

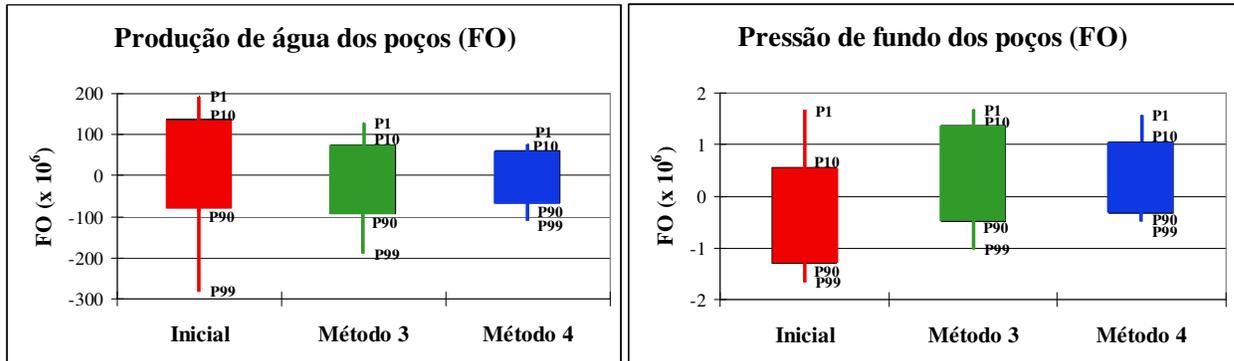


Figura 6.43 – Comparativo da FO de vazão de água e de pressão dos poços – Caso A.

A Figura 6.44 ilustra a produção de água dos modelos situados entre os percentis P10 e P90 das curvas de incerteza final e inicial da combinação dos afastamentos das produções de água dos poços. Há uma redução significativa das incertezas do reservatório, com a eliminação de modelos muito diferentes do histórico. O número de modelos aumenta com relação ao Método 3.2 de 72 para 121 modelos, porém, devido à redefinição dos níveis, eles estão mais concentrados em torno dos dados de produção.

O mesmo raciocínio é utilizado para traçar os gráficos de pressão, Figura 6.45, porém neste caso, são utilizados os modelos selecionados das curvas de incerteza inicial e final das pressões dos poços. Apesar do número de modelos entre P10 e P90 aumentar de 99 para 138 após o Método 4, há uma pequena melhoria no espalhamento das curvas, eliminando modelos com pressão acima do histórico.

Comparando-se o gráfico de pressão com o de vazão de água, observa-se um maior espalhamento das curvas de pressão. Uma possível explicação para isso é o fato da pressão ser mais sensível aos atributos, possibilitando reduzir ainda mais as incertezas em novas etapas do Método 4. Um dos responsáveis por essa maior incerteza na pressão é o atributo PhiA, que afeta de forma significativa a pressão, mesmo para pequenas variações dele.

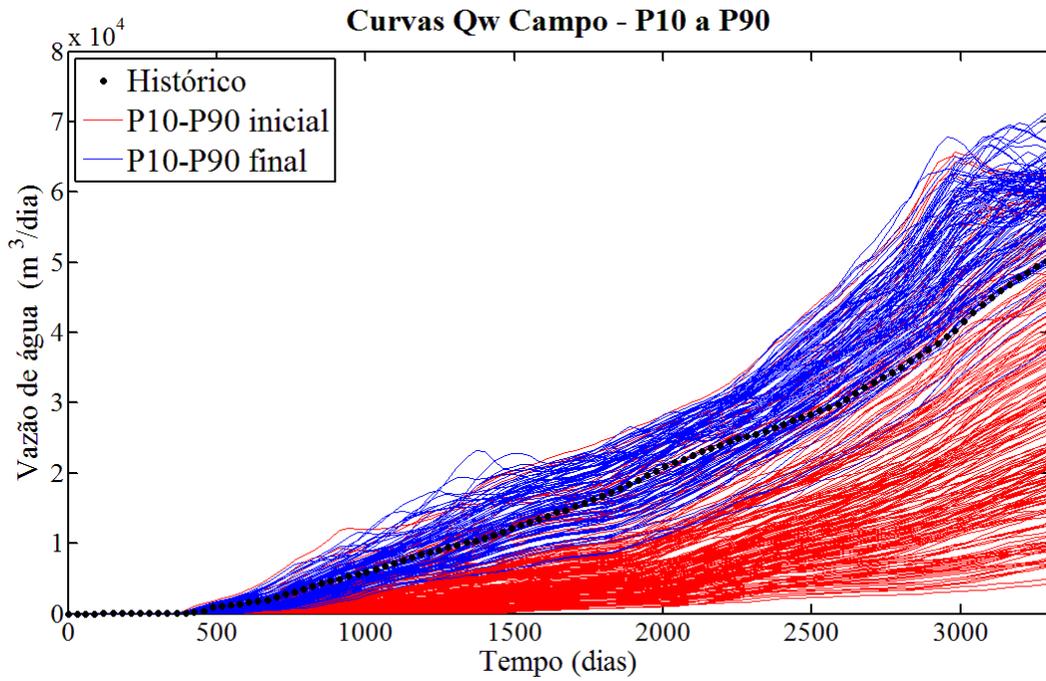


Figura 6.44 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 4 – Caso A.

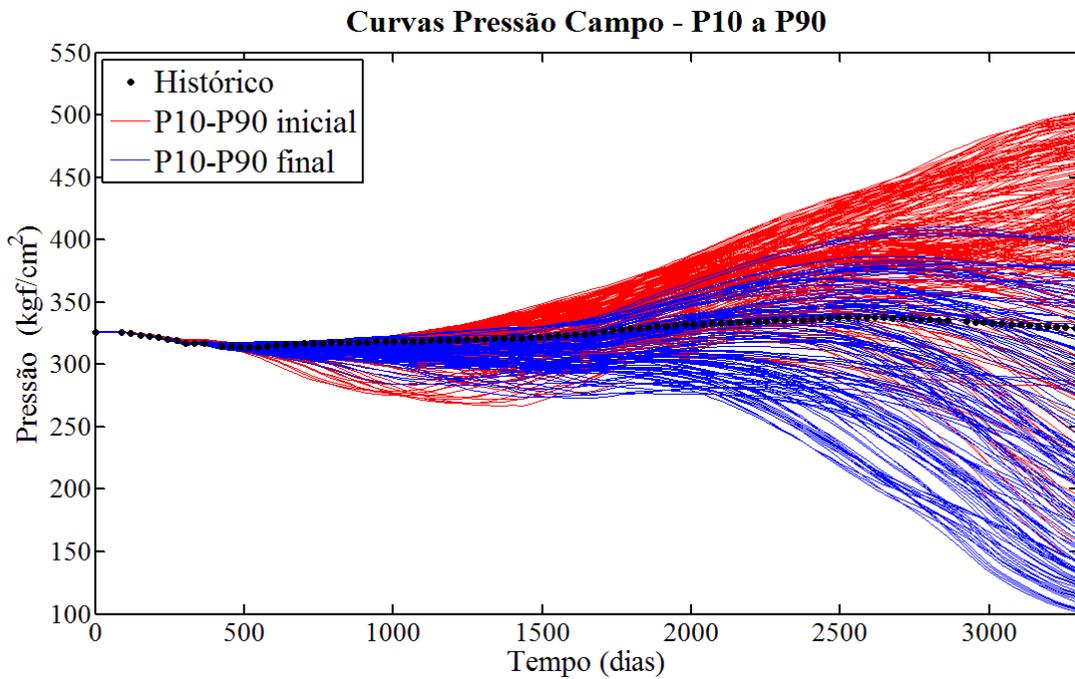


Figura 6.45 – Curvas de pressão do campo dos modelos entre P10 e P90, resultantes do Método 4 – Caso A.

Utilizando-se os mesmos modelos da Figura 6.44 foram traçados os gráficos de produção de água dos poços PROA-4 e PROA-5 na Figura 6.46, mostrando uma maior redução dos espalhamentos com relação à Método 3.2. O mesmo ocorre para a pressão dos poços, apesar da diminuição da faixa de incertezas ser menor que para a vazão de água. Isso é mostrado na Figura 6.47 para o PROB-2 e PROC-4, traçada com os mesmos modelos utilizados na Figura 6.45.

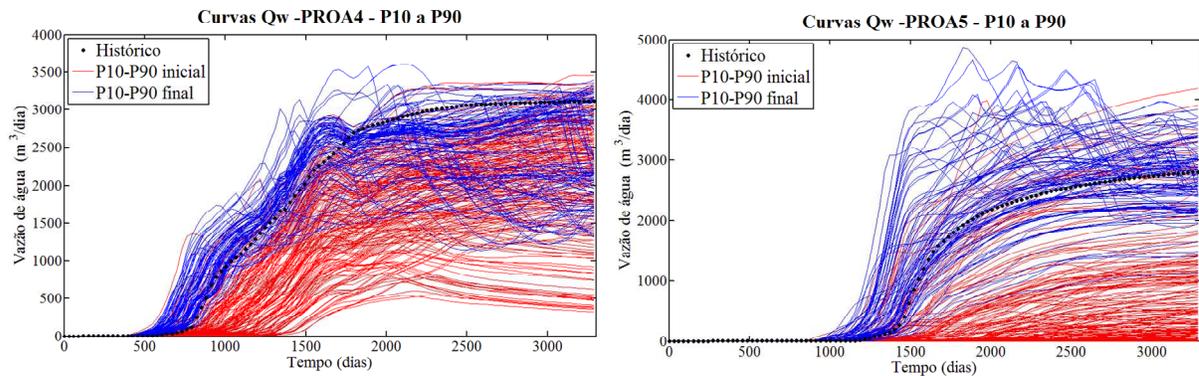


Figura 6.46 – Curvas de produção de água dos poço PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 4 – Caso A.

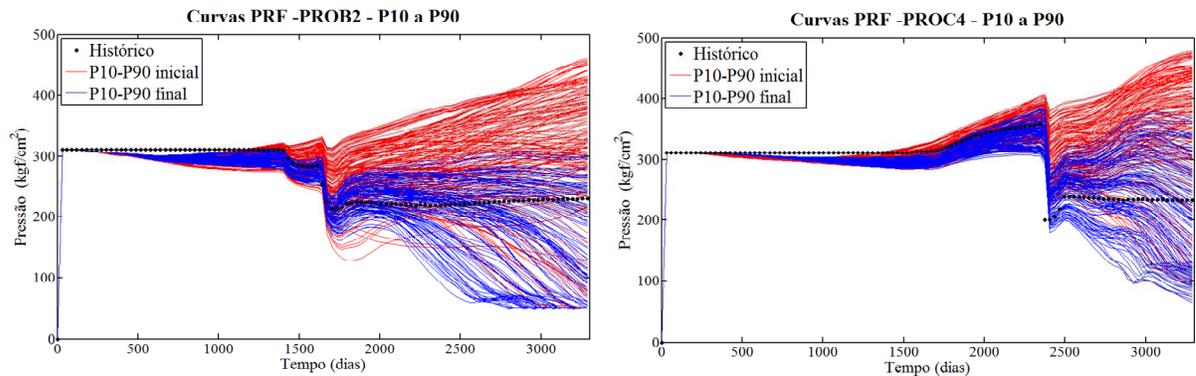


Figura 6.47 – Curvas de pressão de fundo dos poços PROB-2 e PROC-4 para os modelos entre P10 e P90, resultantes do Método 4 – Caso A

Para fazer uma análise final dos resultados e escolher alguns modelos para avaliação de projetos e previsões probabilísticas, pode-se selecionar uma faixa ao redor do P50 das curvas de incerteza inicial e final tanto da pressão quanto da vazão de água, escolhendo-se os modelos comuns as duas curvas. A escolha da faixa está relacionada com o número de modelos presentes e com a dispersão das curvas resultantes. O conjunto de modelos obtidos da combinação das duas variáveis em análise são os modelos representativos, os quais podem ser combinados com outros



parâmetros de incerteza (da previsão ou de um novo projeto) para gerar as previsões probabilísticas.

Utilizando-se o critério de seleção citado acima para o Caso A, uma faixa de 40% em torno do P50 foi utilizada (P30 a P70), obtendo-se uma redução no número de modelos representativos, de 54 modelos iniciais para 19 finais, os quais são utilizados para avaliações futuras. A Figura 6.48 mostra as curvas para a vazão de água do campo para os modelos iniciais e finais escolhidos e o histórico de produção. Observa-se que os modelos finais englobam melhor os dados de produção além de exibir uma significativa diminuição da dispersão das curvas. Vale destacar também que o conjunto de modelos iniciais não contém nele o histórico e que os modelos próximos ao P50 inicial não representam os menores afastamentos da curva de incerteza, evidenciando o grande desajuste inicial.

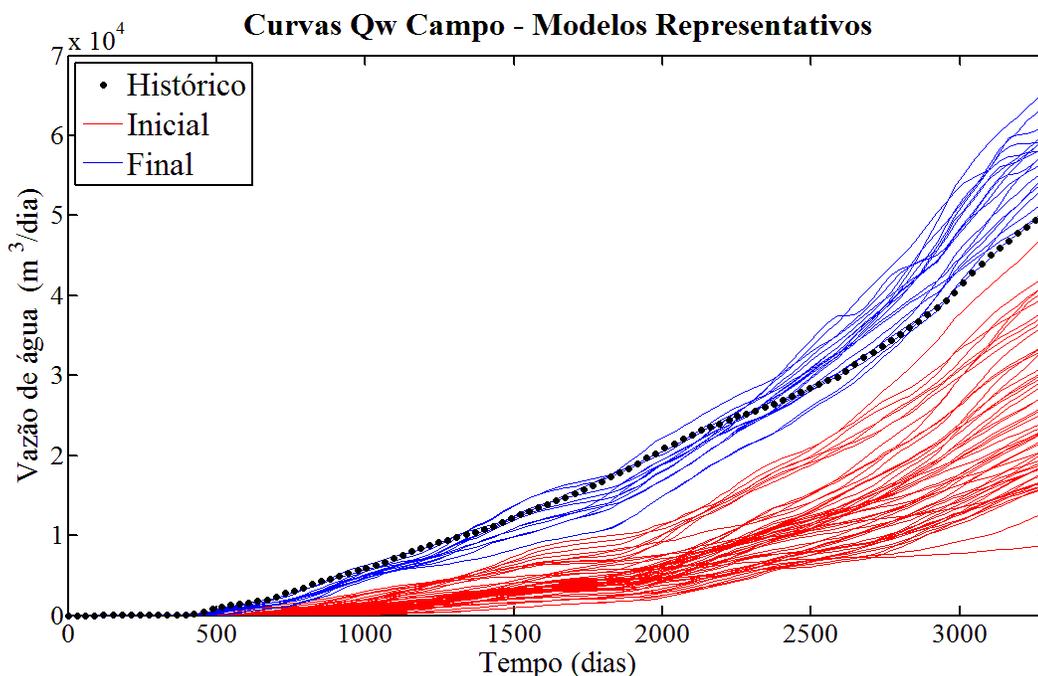


Figura 6.48 – Modelos representativos da vazão de água do campo antes e depois da aplicação do Método 4 – Caso A.

Para a pressão do campo, Figura 6.49, os resultados também são bons, visto que as curvas dos modelos iniciais se distanciam bastante do histórico de pressões no final. Conforme explicado acima, o espalhamento das curvas finais de pressão é maior que das curvas de vazão de água, devido à maior sensibilidade da pressão aos atributos incertos do modelo. Provavelmente,

com novas iterações do Método 4 ou com inserção de outros atributos, conseguir-se-ia um estreitamento maior da faixa.

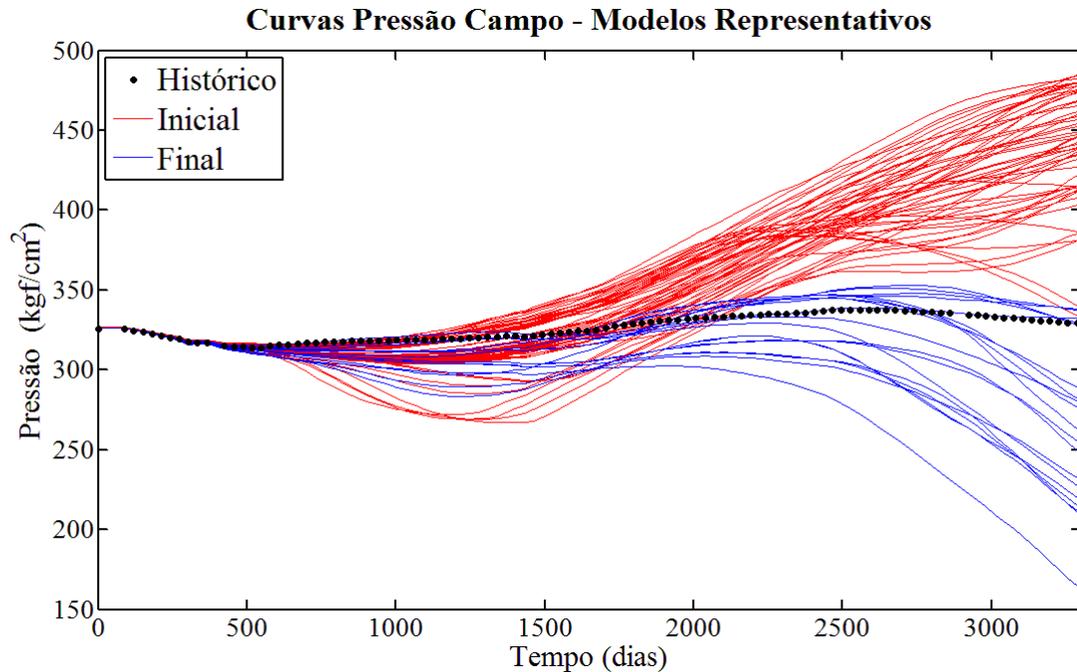


Figura 6.49 – Modelos representativos da pressão do campo antes e depois da aplicação do Método 4 – Caso A.

O comportamento da vazão de água e pressão de fundo de alguns poços é exibido nas próximas figuras, nas quais são traçados os gráficos dos modelos iniciais (54) e finais (19) selecionados das curvas de incerteza, como explicado anteriormente. A produção de água dos poços PROA-4 e PROA-7 (gráficos superiores da Figura 6.50) apresentam resultados similares ao do campo, com os modelos finais em torno do histórico de produção e o espalhamento deles bastante reduzido. Os modelos iniciais, em geral, não incluem o histórico e possuem um grande espalhamento das curvas.

Para os poços PROB-8 e PROC-3 (gráficos inferiores da Figura 6.50), apesar dos modelos finais não estarem englobando os dados medidos, eles estão mais próximos do histórico que os modelos iniciais. Além disso, eles apresentam uma dispersão bem menor, indicando uma melhora dos resultados e redução nas incertezas do modelo. Uma das possibilidades das respostas para estes poços não serem melhores é o fato de não se utilizar todos os atributos incertos, que permanecem no valor mais provável. Como na escolha dos atributos críticos foram priorizados os

que influenciavam mais o Bloco A, alguns atributos importantes para os demais blocos não foram analisados. Caso haja possibilidade de incorporação deles, acredita-se que os resultados ficariam mais refinados.

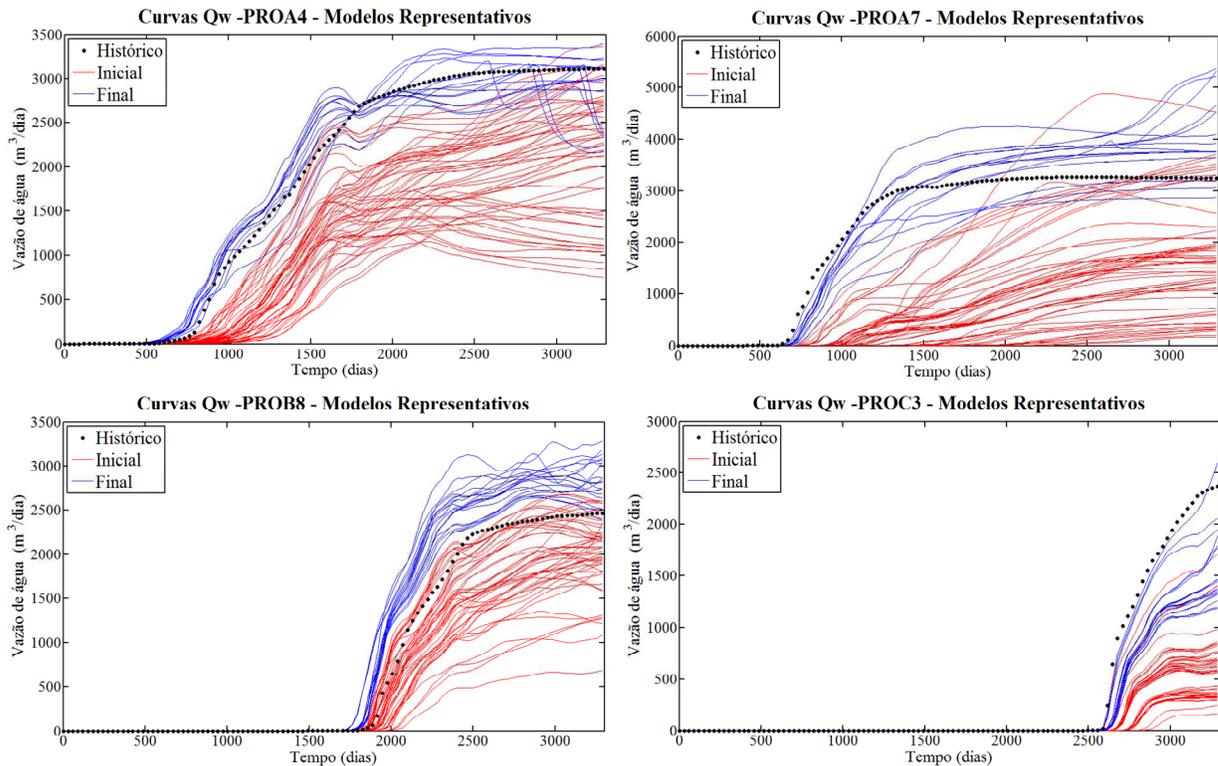


Figura 6.50 – Modelos representativos iniciais e finais da vazão de água dos poços PROA-4, PROA-7, PROB-8 e PROC-3 – Caso A.

Os gráficos de pressão de fundo dos modelos iniciais e finais dos poços, ilustrados na Figura 6.51, apresentam melhorias na resposta em termos de redução das incertezas (faixa menor) e de melhor centralização em torno dos dados de produção. Os resultados para os poços são bastante parecidos com os da pressão do campo. Os modelos iniciais, em geral, possuem curvas acima do histórico de pressão, e em alguns casos (PROA-1 e PROC-4), nem englobam esse histórico. O fato das curvas finais das pressões dos poços apresentarem dispersão maior que as de vazões pode ser justificado pela grande sensibilidade dessa função aos atributos críticos considerados, principalmente às porosidades dos blocos.

De forma geral, ao utilizar o critério de seleção de uma faixa em torno do P50 das curvas de incerteza, obtém-se um conjunto de modelos com um bom ajuste de histórico e boa

representatividade da incerteza, que pode ser utilizado para obter previsões probabilísticas do futuro.

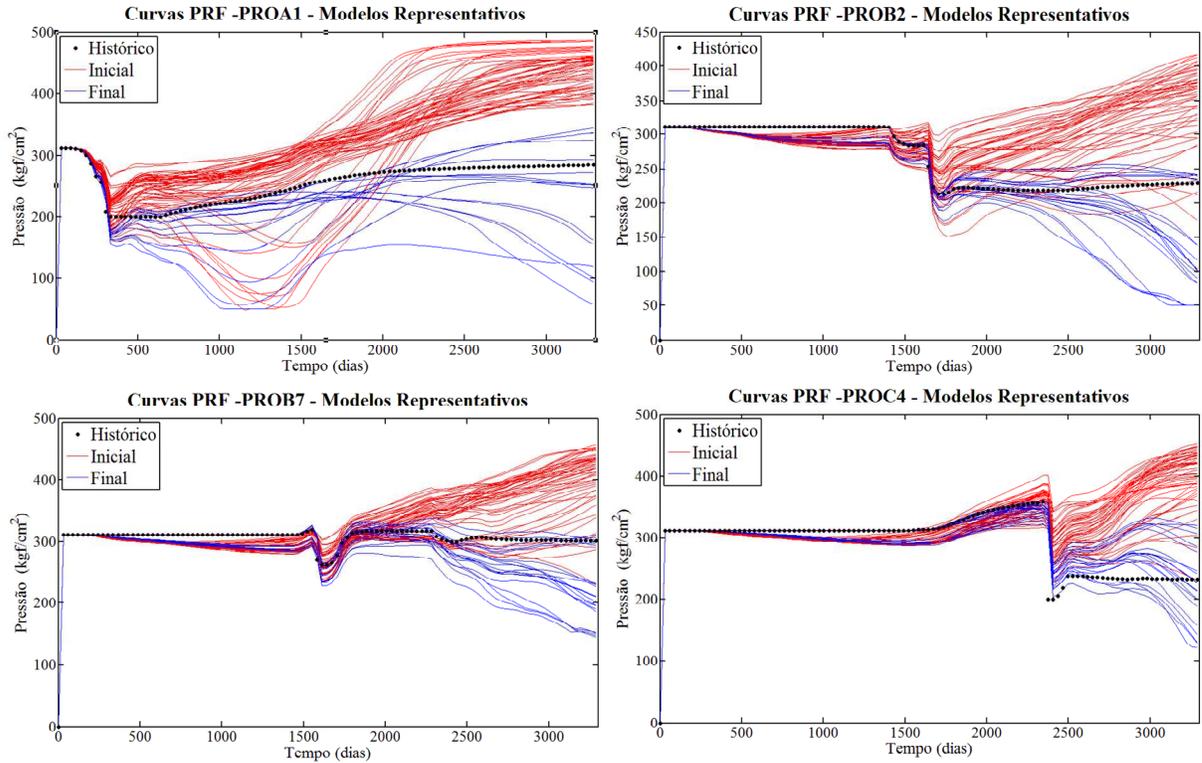


Figura 6.51 – Modelos representativos iniciais e finais da pressão de fundo dos poços PROA-1, PROB-2, PROB-7 e PROC-4 – Caso A.

### 6.2.5 Comparação dos Métodos

Neste item é feita uma comparação entre os resultados de todos os métodos aplicados para o Caso A. Para os Métodos 1 e 2 o principal problema está na combinação de todas as funções, tanto vazões de água como pressões, para a redistribuição das probabilidades. Os Métodos 3 e 4 apresentam soluções para isso, porém o fato de serem utilizados poucos atributos discretizados em apenas 3 níveis para viabilizar a aplicação da árvore de derivação, não permite uma excepcional melhoria dos resultados. O ideal seria a utilização de mais atributos incertos e a possibilidade de discretizar aqueles com maior influência em mais níveis, porém isso eleva de forma exponencial o número de simulações necessárias quando se trabalha com a árvore de derivação.

A Figura 6.52 mostra as curvas de incerteza para a vazão de água, sendo a FO a combinação dos afastamentos quadráticos das vazões de água de todos os poços. A melhor resposta é dada pelo Método 4 (curva preta), que além de reduzir a dispersão em cerca de 40% (diferença entre P10 e P90) centraliza melhor em relação ao eixo  $x=0$  que corresponde ao histórico de produção.

O Método 1 (curva laranja) centraliza bem com relação aos dados medidos, porém aumenta a dispersão. Já o Método 2 faz justamente o contrário, reduz a dispersão, mas não melhora a centralização em torno do eixo zero. Os outros dois métodos, 3.1 e 3.2 (curvas em azul) apresentam resultados bem parecidos, sendo o Método 3.2 o melhor em termos de redução da dispersão e centralização da curva de incerteza. Ao redefinir os níveis dos atributos e aplicar novamente o Método 3.2 (Método 4) há um aperfeiçoamento dos resultados, visto que a faixa de incertezas dos atributos é diminuída de acordo com as respostas da aplicação inicial do método.

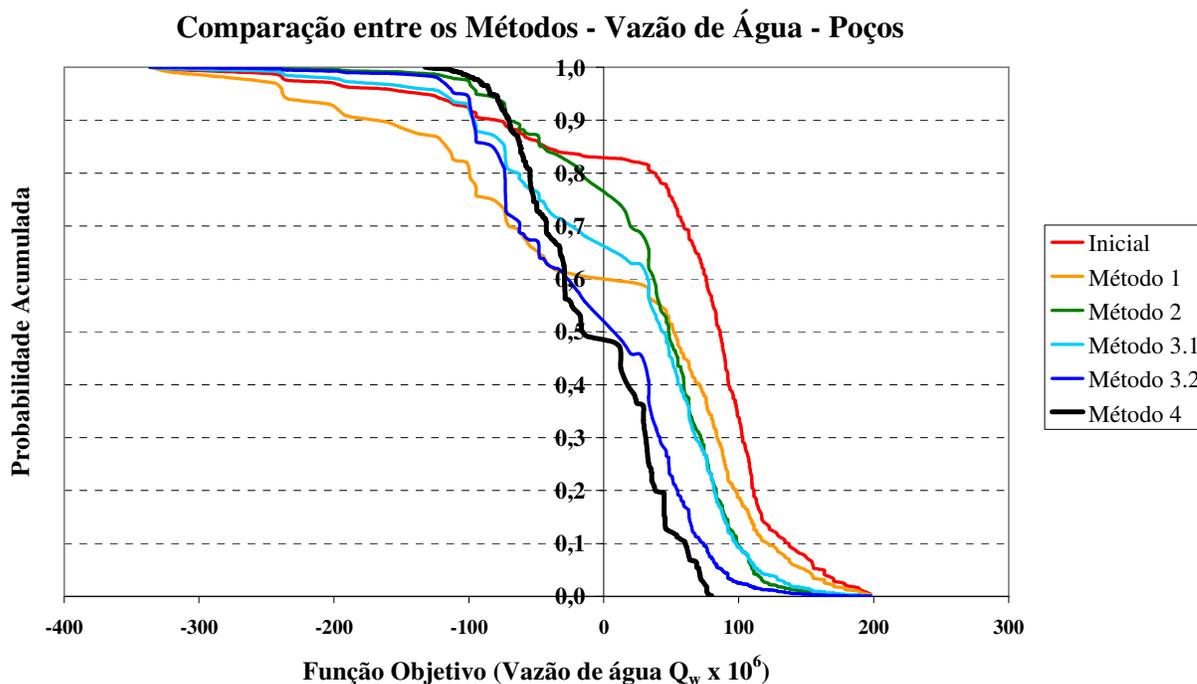


Figura 6.52 – Comparação das curvas de incerteza da vazão de água dos métodos – Caso A.

Para a combinação das pressões de fundo dos poços, ilustrada na Figura 6.53, o resultado é um pouco diferente, visto que somente o Método 4 consegue reduzir a dispersão da curva em

25%. Os demais métodos aumentam um pouco a dispersão e o Método 3.2 mantém a dispersão próxima da original. Quanto à centralização em torno do histórico os melhores métodos são o 3.1 e o 4, sendo que todos eles apresentam alguma melhoria com relação aos dados iniciais.

Sendo assim, o Método 4 gera os resultados mais consistentes para o campo, tanto para a produção de água como para as pressões. Ele consegue uma boa mitigação das incertezas a partir do histórico de produção, permitindo a escolha de um conjunto de modelos com bom ajuste para gerar projeções futuras. Apesar dos bons resultados, os gráficos ilustrados neste item indicam que a redução da dispersão não é muito elevada, principalmente com relação à pressão. Uma possível explicação para isso é o fato do modelo ser muito heterogêneo e terem sido utilizados somente 5 atributos dos 13 mapeados para fazer a redução de incertezas através dos dados de histórico.

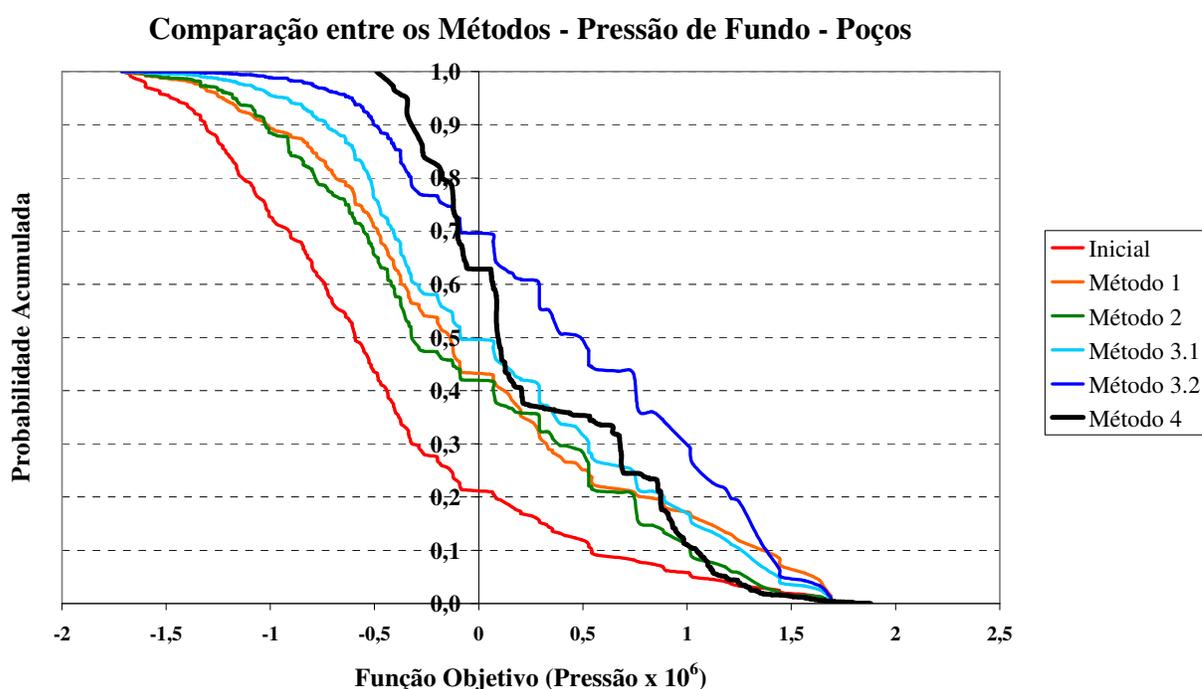


Figura 6.53 – Comparação das curvas de incerteza da pressão de todos os Métodos – Caso A.

Portanto, melhores resultados seriam obtidos utilizando-se mais atributos incertos, porém isto inviabiliza a aplicação da árvore de derivação. Uma opção é a utilização de técnicas de amostragem para que não seja necessário simular todas as combinações de modelos, mas isso não foi tratado neste trabalho. Então, buscando uma maneira para avaliar melhor o resultado da

formulação desenvolvida criou-se o Caso B, em que se elimina a incerteza dos 8 atributos considerados não críticos, ou seja, os modelos consideram esses atributos no valor do histórico, ao invés do mais provável.

### **6.3 Caso B**

Os resultados do Caso B serão apresentados somente para os Método 3 e 4, visto que, o Método 1 apresenta alguns problemas na formulação já citados anteriormente, gerando uma redistribuição praticamente uniforme, ou seja, os atributos não têm suas probabilidades redistribuídas. Já o Método 2 tem uma resposta aproximadamente determinística, porque há uma combinação de atributos cuja resposta é quase idêntica ao histórico. É importante lembrar que este caso não é prático, pois é bastante difícil conseguir mapear todas as incertezas existentes num reservatório real. Ele só foi criado para avaliação mais precisa das fórmulas criadas.

#### **6.3.1 Método 3**

Para obter a redistribuição final de probabilidades pelo Método 3 é feita uma combinação dos valores de cada função independente de duas formas diferentes, gerando as duas subdivisões, 3.1 e 3.2. Os resultados do Método 3.1, que utiliza a média aritmética não serão mostrados para o Caso B, já que a formulação do Método 3.2, utilizando como fator de ponderação da média o índice de sensibilidade, gera os melhores resultados.

##### **6.3.1.1 Método 3.2**

A melhor redistribuição das probabilidades dos atributos é obtida, utilizando-se uma média aritmética ponderada pelo índice de sensibilidade ( $IS$ ) da função considerada com relação ao atributo incerto. Assim, se um atributo não influencia uma função ( $Q_w$  e  $PRF$ ), o peso desta na redistribuição de probabilidade dele será bem pequeno, não influenciando a média final. A Figura 6.54 e a Tabela 6.10 mostram os resultados da redistribuição de probabilidades para os cinco atributos críticos, utilizando o Método 3.2. No caso em questão, é utilizado  $F$  de 2,5 (Método 2) na Equação 3.7 e  $1/|S_n|_{máximo}$  igual a 5 (Método 1).

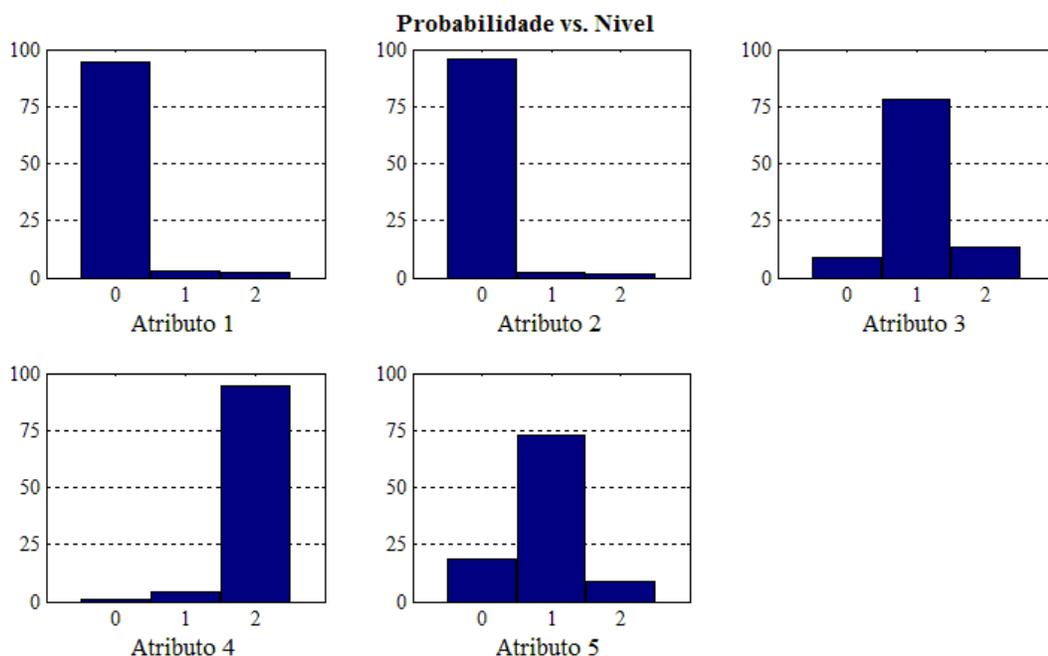


Figura 6.54 – Redistribuição de probabilidades pelo Método 3.2 – Caso B.

Tabela 6.10 – Resultados da aplicação do Método 3.2 – Caso B.

	Atributo	Probabilidade		
		0	1	2
1	PhiA	95%	3%	2%
2	FAB	96%	2%	2%
3	Falhas	9%	78%	13%
4	PVT	1%	4%	95%
5	krw	18%	73%	9%

Ao comparar com a Tabela 6.5 do Caso A, observa-se que as novas probabilidades obtidas para todos os atributos são bem mais consistentes com as respostas esperadas, dado que a combinação de parâmetros utilizada para gerar o histórico é conhecida. Dessa forma, o caso B leva a uma melhor redução das incertezas com o histórico de produção que o Caso A. Isso já era esperado, visto que neste novo caso as incertezas dos atributos não críticos são eliminadas.

No Caso A, o atributo krw apresentou probabilidades muito próximas para os níveis 0 e 1, o que foi explicado pela não utilização de todas as incertezas na metodologia, visto que 8 atributos incertos ficam no nível mais provável. Ao eliminar a incerteza destes 8 atributos no Caso B, obteve-se uma nova distribuição de probabilidades consistente para o atributo krw, indicando que os atributos não utilizados no Caso A realmente influenciavam os resultados do krw.



As curvas de incerteza para a produção de água e pressão dos poços estão na Figura 6.55. Elas foram obtidas de forma similar ao feito para os demais métodos, conforme a descrição do Item 2.2.3.

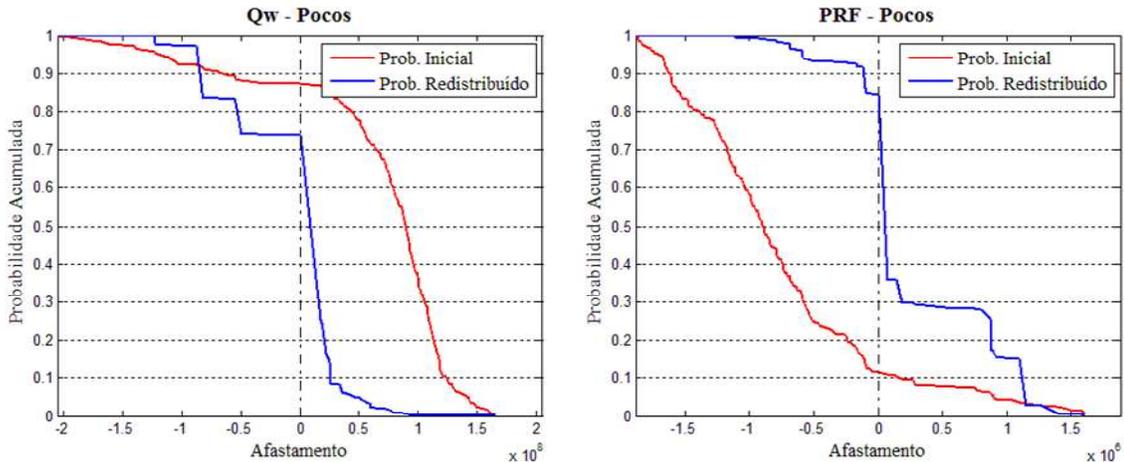


Figura 6.55 – Curvas de incerteza da vazão de produção de água e pressão dos poços – Método 3.2 – Caso B.

Para a produção de água dos poços há uma grande redução dos afastamentos nos percentis menores que 70%. Já para a pressão dos poços, tal redução ocorre em percentis acima de 30%. Além disso, em ambas as curvas observa-se uma melhor centralização em torno do histórico, com a curva se aproximando mais do eixo zero no percentil 50% e uma diminuição da dispersão (diferença entre os percentis P10 e P90).

Das curvas de incerteza final e inicial do Método 3.2 para os Casos A e B (Figuras 6.30 e 6.55), podem-se extrair os afastamentos dos modelos representativos da faixa de incerteza P1, P10, P90 e P99, conforme feito no Item 6.2.2 para traçar os gráficos de “bastão” que mostram o espalhamento e a centralização resultantes. Ao considerar a FO como a produção de água dos poços, observa-se na Figura 6.56 a melhora de um caso para o outro, principalmente na redução da dispersão, que praticamente dobrou do caso A para o B, passou de 23% para 44%. Os resultados da centralização em torno do histórico apresentaram uma pequena piora com relação ao Caso A.

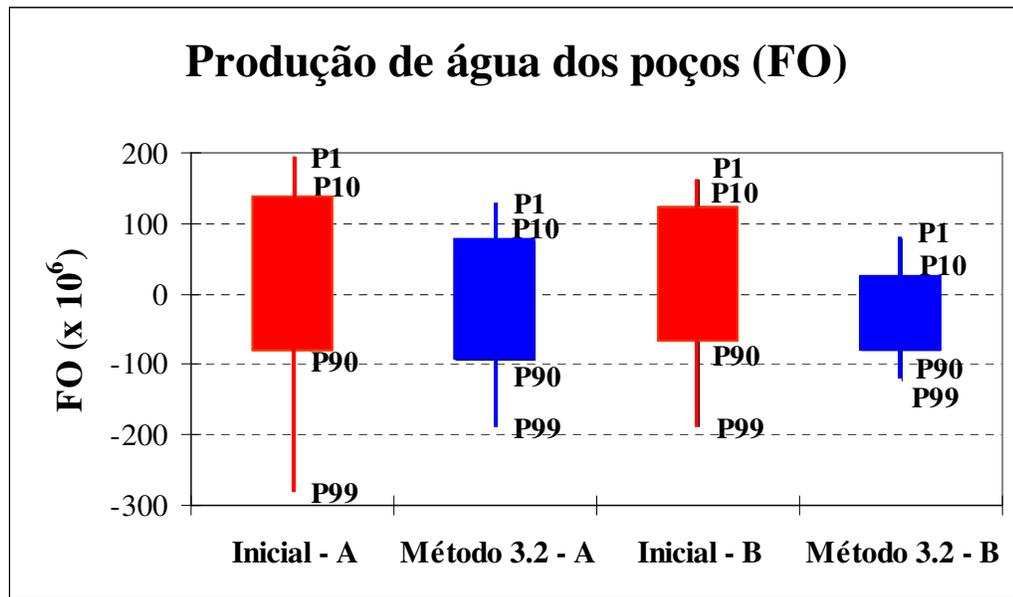


Figura 6.56 – Comparação da FO de vazão de água dos poços entre os Casos A e B – Método 3.2.

Para os dados de pressão dos poços (Figura 6.57), ao se comparar os dois casos, também é observada uma diminuição da dispersão em relação ao inicial. O Caso A não apresenta redução da dispersão, enquanto que o Caso B mostra uma redução de cerca de 32%. Quanto à centralização com relação ao histórico, os dois casos apresentam resultados semelhantes, ambos melhoram um pouco com relação à centralização inicial.

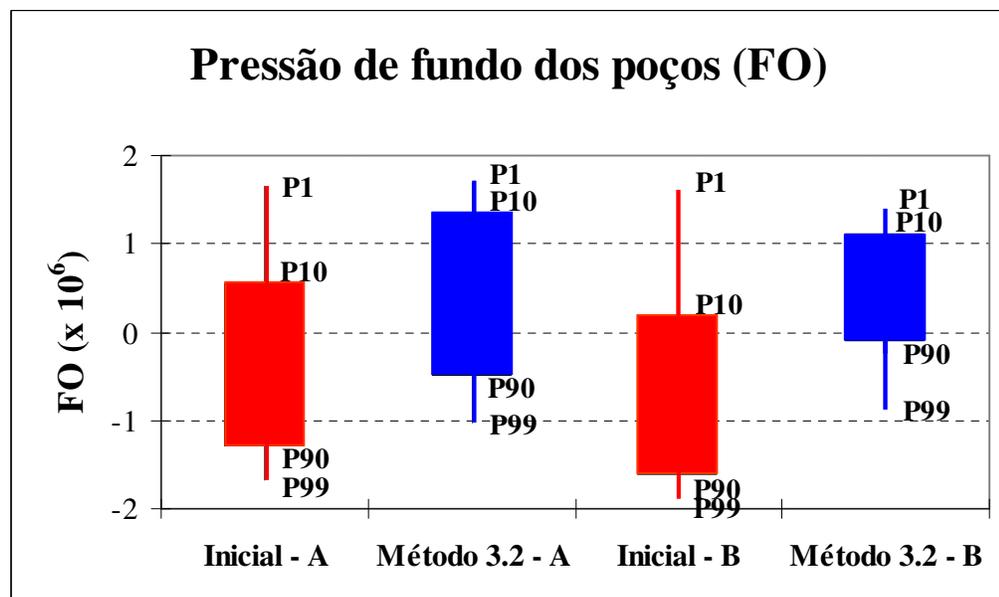


Figura 6.57 – Comparação da FO de pressão dos poços entre os Casos A e B – Método 3.2.

A Figura 6.58 ilustra a produção de água dos modelos situados entre os percentis P10 e P90 das curvas de incerteza da combinação dos afastamentos das produções de água dos poços inicial e após a aplicação do Método 3.2. É possível observar uma redução significativa das incertezas do reservatório, com a eliminação de uma grande quantidade de modelos mais distantes do histórico. O número de modelos selecionados diminui de 194 para apenas 18 modelos, os quais englobam os dados de produção.

Os gráficos de poços, traçados utilizando-se os mesmos modelos da Figura 6.58, também mostram uma boa redução das incertezas, porém ainda apresentam algumas curvas bem diferentes do histórico. Um exemplo disso são as vazões de água dos poços PROA-4 e PROA-5 na Figura 6.59. Ambos apresentam melhorias na resposta quando comparados ao Caso A, com destaque para o PROA-5, que antes não tinha bons resultados (Figura 6.34). Uma possível justificativa para a existência de algumas curvas ainda distantes do histórico é a faixa de incerteza dos atributos, que pode estar superestimada, daí a aplicação do Método 4, redefinindo esta faixa.

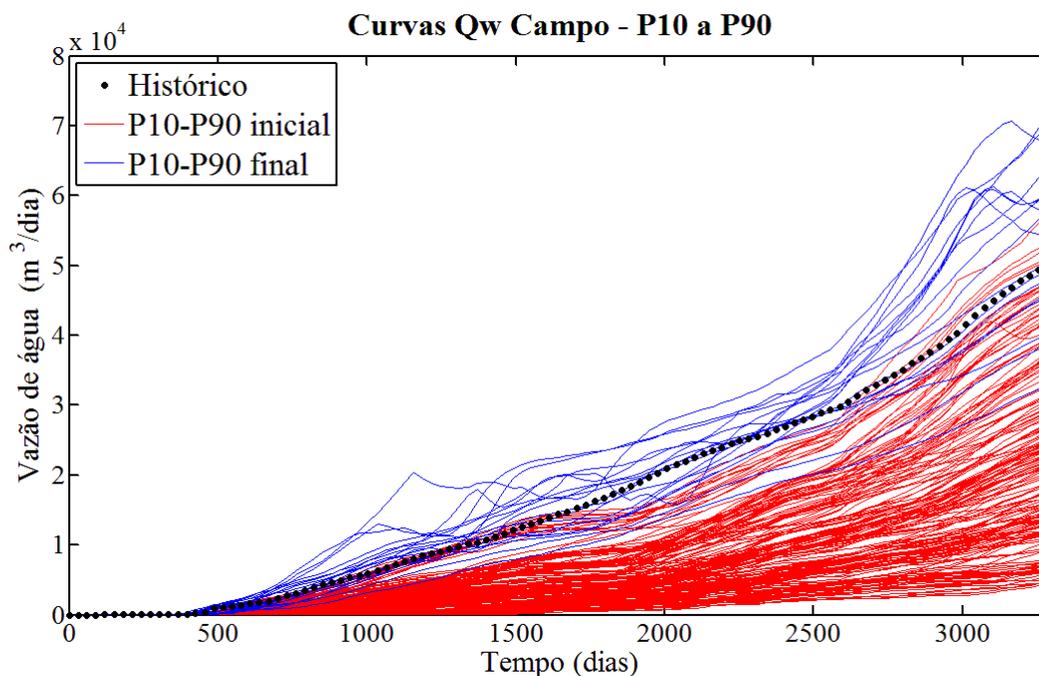


Figura 6.58 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B.

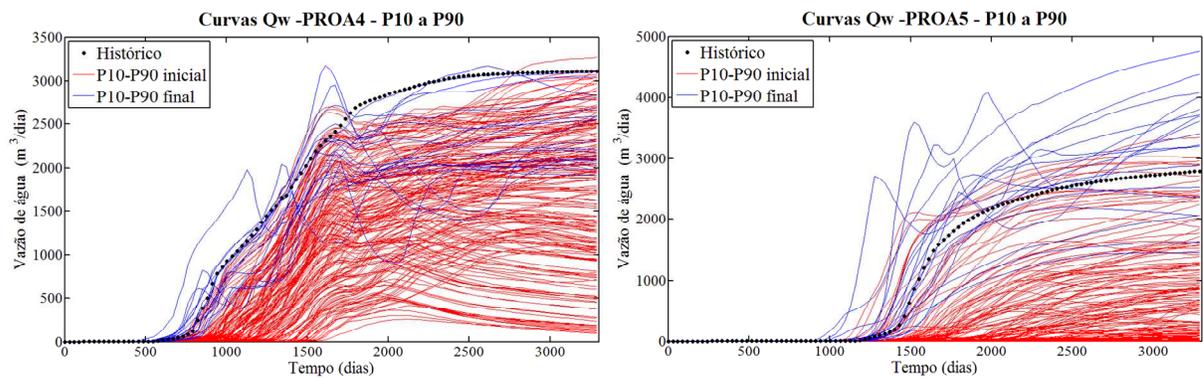


Figura 6.59 – Curvas de produção de água dos poços PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B.

Ao utilizar o mesmo raciocínio para os dados de pressão, podem-se traçar os modelos da faixa P10-P90 selecionados das curvas de incerteza inicial e final das pressões dos poços, sendo que, neste caso, após a aplicação do Método 3.2, esse número é de 28 modelos. Apesar da quantidade maior de modelos escolhidos, os resultados para a pressão do campo, em termos de redução de incertezas, são similares aos mostrados para a vazão de água, com uma dispersão um pouco maior.

Os gráficos da pressão do campo e pressões de fundo dos poços dos modelos obtidos da curva de incerteza das pressões exibem uma boa redução das incertezas além do englobamento do histórico por eles, como exemplificado nas Figuras 6.60 e 6.61 para o campo e para os poços PROB-2 e PROC-4, respectivamente. Ambos os poços apresentam melhorias na resposta quando comparados ao Caso A (Figura 6.36), principalmente na diminuição da dispersão das curvas.

Apesar das grandes melhorias encontradas com relação ao Caso A, as curvas de produção de água e de pressão do campo e principalmente as dos poços (Figuras 6.59 e 6.61) ainda apresentam algumas curvas bem diferentes do histórico de produção. Sendo assim, houve uma redefinição dos níveis dos cinco atributos e uma nova aplicação do Método 3.2, conforme mostrado na Figura 4.5 para refinar os resultados obtidos, constituindo o Método 4.

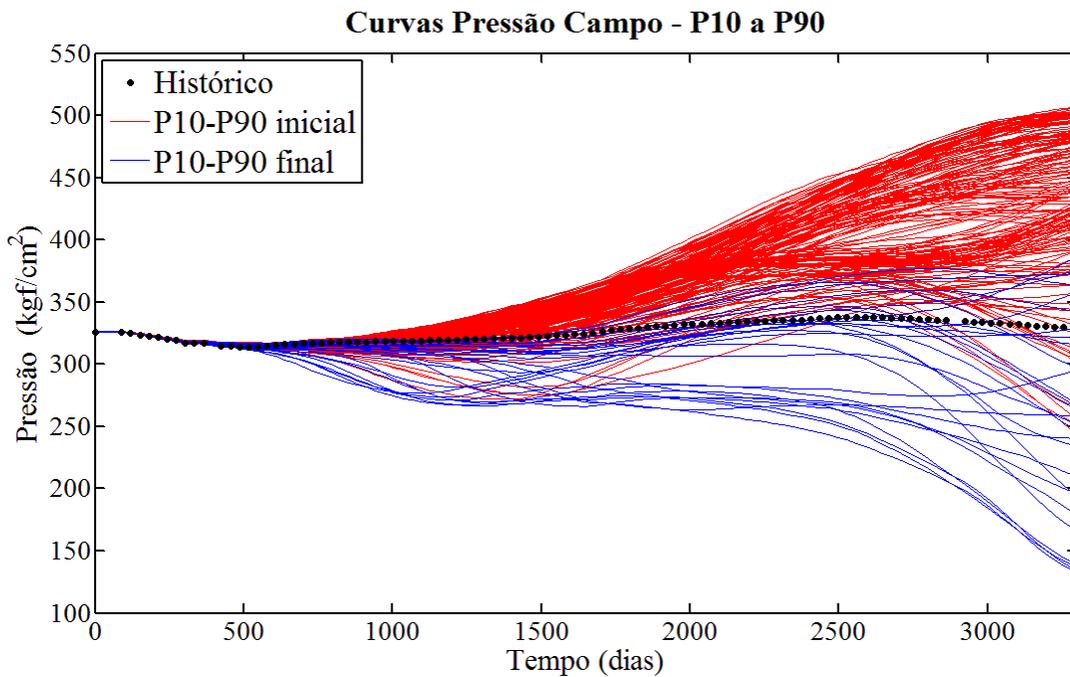


Figura 6.60 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B.

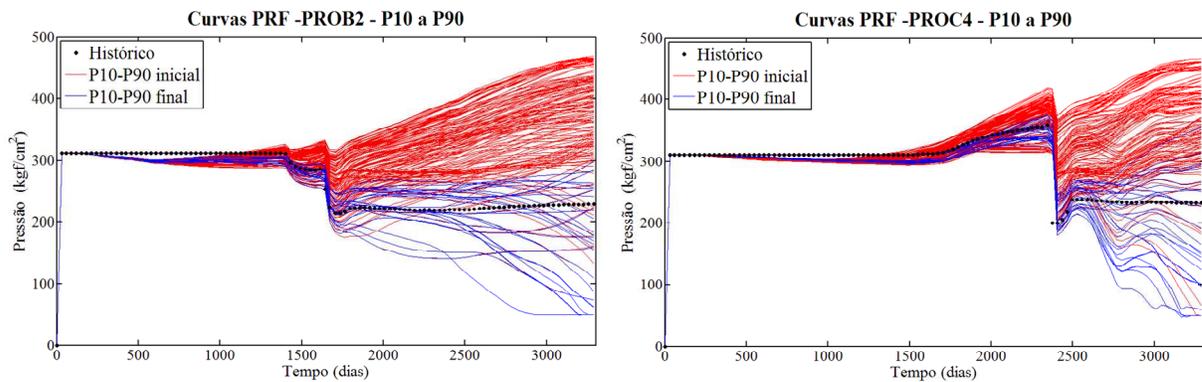


Figura 6.61 – Curvas de pressão de fundo dos poços PROB-2 e PROC-4 para os modelos entre P10 e P90, resultantes do Método 3.2 – Caso B

### 6.3.2 Método 4

De forma análoga a feita para o Caso A, os novos valores dos níveis do atributo PhiA foram determinados pelas Equações 4.4, 4.5 e 4.6, utilizando-se os mesmos limites da Figura 6.37 e as probabilidades da Tabela 6.10, sendo obtidos para os níveis 0, 1 e 2 os valores contidos na Tabela 6.11. Do mesmo modo, os níveis do atributo FAB foram calculados respeitando-se os limites físicos dele, que não pode ser menor que zero e nem maior que 1.

Tabela 6.11 – Novos níveis dos atributos – Caso B.

	Atributo			
		0	1	2
1	PhiA	0,77	0,81	0,94
2	FAB	0	0,05	0,1
3	Falhas	Modn0	Modelo 1	Modn2
4	PVT	PVT2		
5	krw	krwn0	krw1	krwn2

Os novos valores dos níveis dos modelos de Falhas e do krw foram obtidos a partir de interpolações dos dados iniciais. No caso das falhas, o modelo de maior probabilidade após a primeira aplicação é o Modelo 1, sendo assim, os outros níveis, 0 e 2, foram obtidos de forma a se aproximarem deste modelo inicial, acrescentando e retirando falhas respectivamente. Os três modelos estão na Figura 6.62. A probabilidade do nível 1 da curva de permeabilidade relativa à água também foi aumentada após a aplicação do Método 3.2, assim, as novas curvas dos níveis 0 e 2 (krwn0 e krwn2) foram obtidas através de interpolações lineares entre as curvas antigas (krw0 e krw2) e a curva do nível 1 krw1, como mostrado na Figura 6.63.

O último atributo analisado é a PVT, cujos níveis são diferentes tabelas obtidas de análises laboratoriais, não sendo aconselhável a criação de novas tabelas por interpolação. Como a aplicação do Método 3.2 no Caso B resultou numa probabilidade elevada de 95% para o nível 2 (PVT2), este atributo foi eliminado no Método 4, fixando-se seu valor na PVT2 e reduzindo o número de simulações necessárias na nova etapa (81 rodadas).

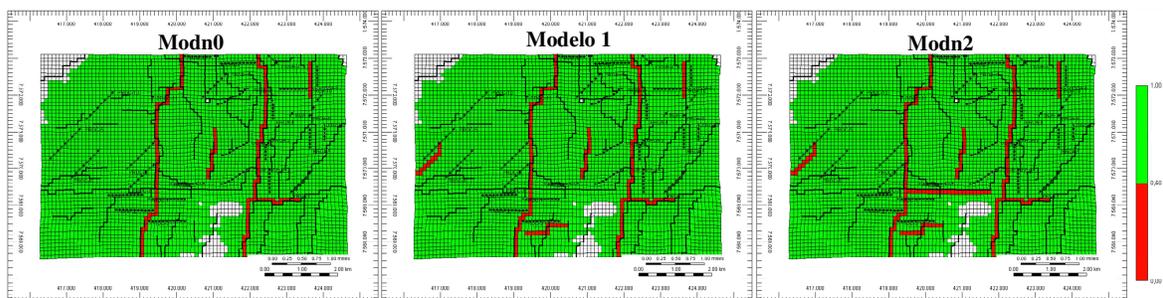


Figura 6.62 – Modelos novos de falhas internas – Caso B.

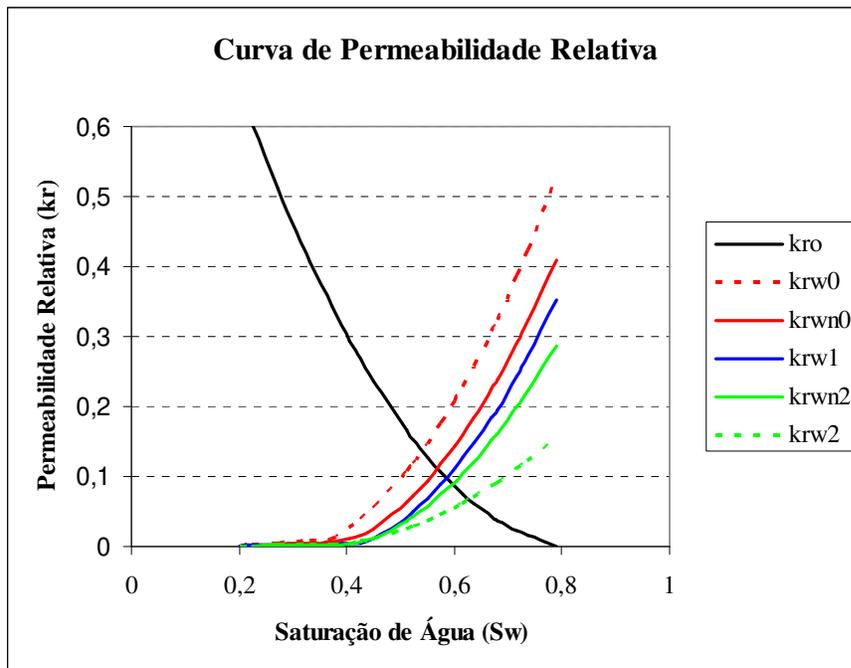


Figura 6.63 – Novas curvas de permeabilidade relativa à água – Caso B.

De posse dos resultados das simulações com os novos níveis dos atributos é aplicado o Método 3.2 conforme feito anteriormente. A Tabela 6.12 e a Figura 6.64 mostram os resultados da redistribuição de probabilidades para os quatro atributos após a aplicação do Método 4.

Tabela 6.12 – Resultados da aplicação do Método 4 – Caso B.

	Atributo	Probabilidade		
		0	1	2
1	PhiA	23%	74%	3%
2	FAB	72%	15%	13%
3	Falhas	37%	39%	24%
4	krw	11%	70%	19%

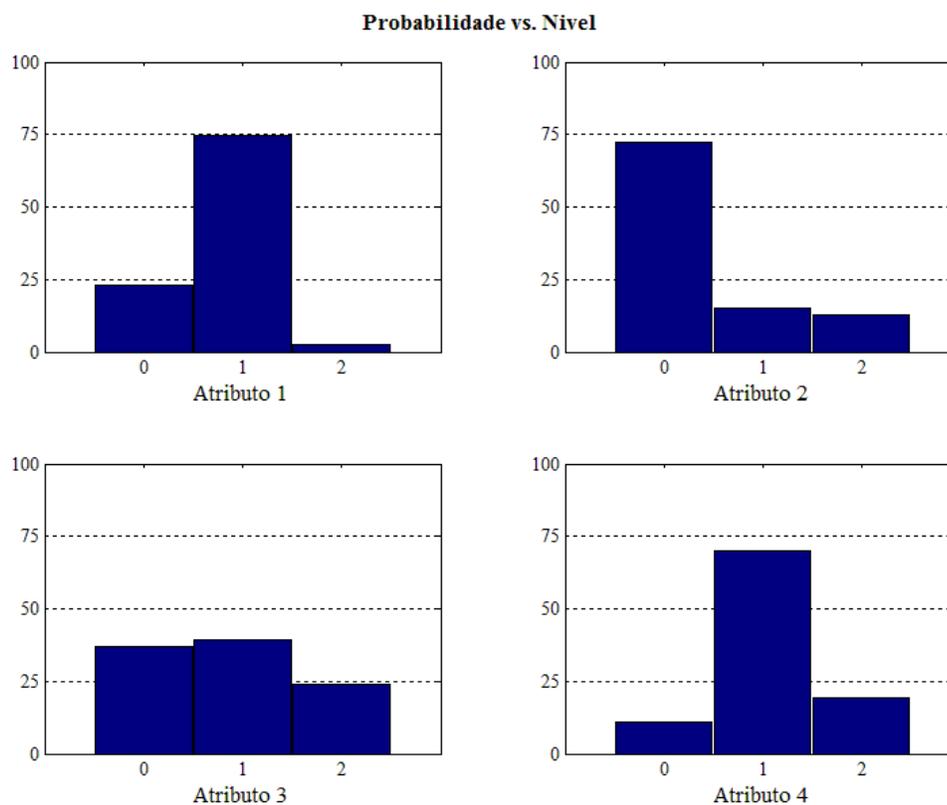


Figura 6.64 – Probabilidades após aplicação do Método 4 – Caso B.

Os resultados da aplicação do Método 4 mostram que os quatro atributos apresentam valores de probabilidade maiores para o nível mais próximo do utilizado para gerar o histórico, melhorando bastante a curva de incerteza tanto para a vazão de água como para a pressão (Figuras 6.65 e 6.66). O atributo Falhas tem sua resposta com probabilidade mais elevada no nível 1, porém os níveis 0 e 2 também apresentam valores consideráveis. Isso porque há uma grande proximidade entres os modelos de falhas propostos para os níveis e, além disso, as falhas locais alteram o comportamento de alguns poços específicos.

A Figura 6.65 mostra a curva de incerteza para a produção de água, comparando-se a curva inicial (com probabilidades uniformes – curva vermelha), curva após aplicação do Método 3.2 (curva verde) e a curva final, depois do Método 4 (curva azul), indicando uma grande aproximação do eixo zero (histórico), principalmente para os percentis menores que 80%. Além disso, é importante observar que a curva final corta o eixo histórico aproximadamente no percentil 50%, ou seja, o modelo mais provável é o com menor afastamento.



### Comparação entre os Métodos - Vazão de Água - Poços

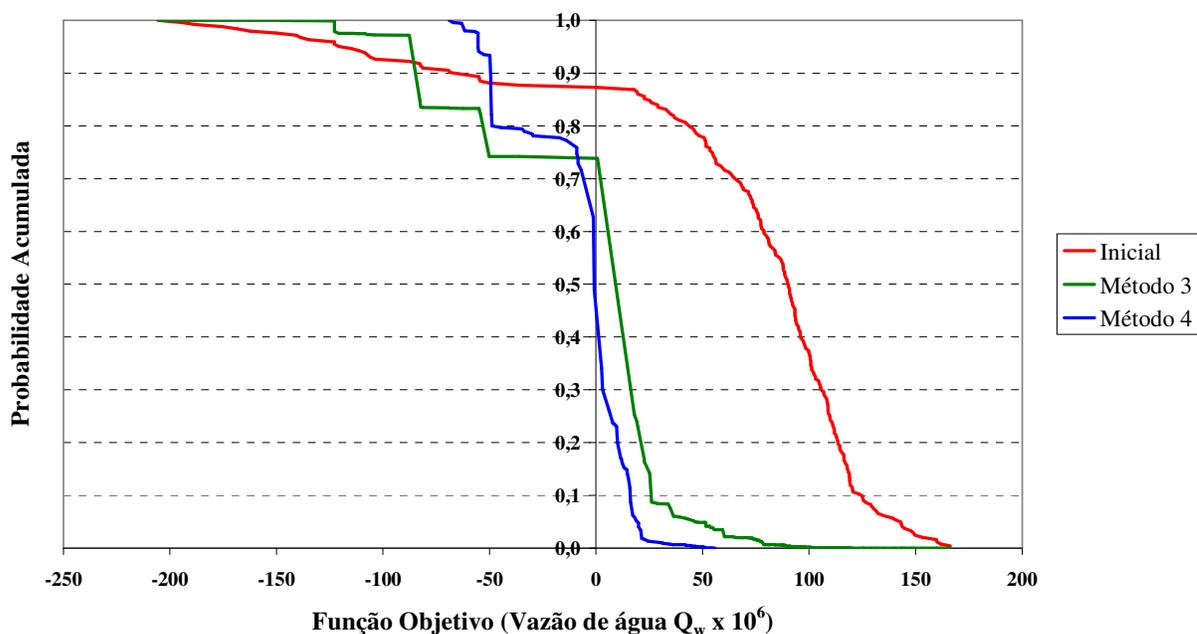


Figura 6.65 – Comparação entre as curvas de incerteza para vazão de água inicial e dos Métodos 3 e 4 – Caso B.

A curva de incerteza para a pressão dos poços da Figura 6.66 também mostra uma boa aproximação com relação ao eixo zero, principalmente para percentis maiores que 30%, além de uma melhor centralização em torno do histórico. Vale ressaltar que os modelos com menor afastamento estão bem próximos do percentil 50%, assim como na curva de incerteza para a produção de água dos poços.

Conforme explicado no Item 6.2.2, os afastamentos dos modelos representativos da faixa de incerteza P1, P10, P90 e P99 podem ser extraídos das curvas das Figuras 6.65 e 6.66 para traçar os gráficos de “bastão” que mostram o espalhamento e a centralização resultantes. A Figura 6.67 compara a dispersão resultante dos métodos 3 e 4 (corpo do “bastão”) para a vazão de água e para a pressão.

### Comparação entre os Métodos - Pressão de Fundo - Poços

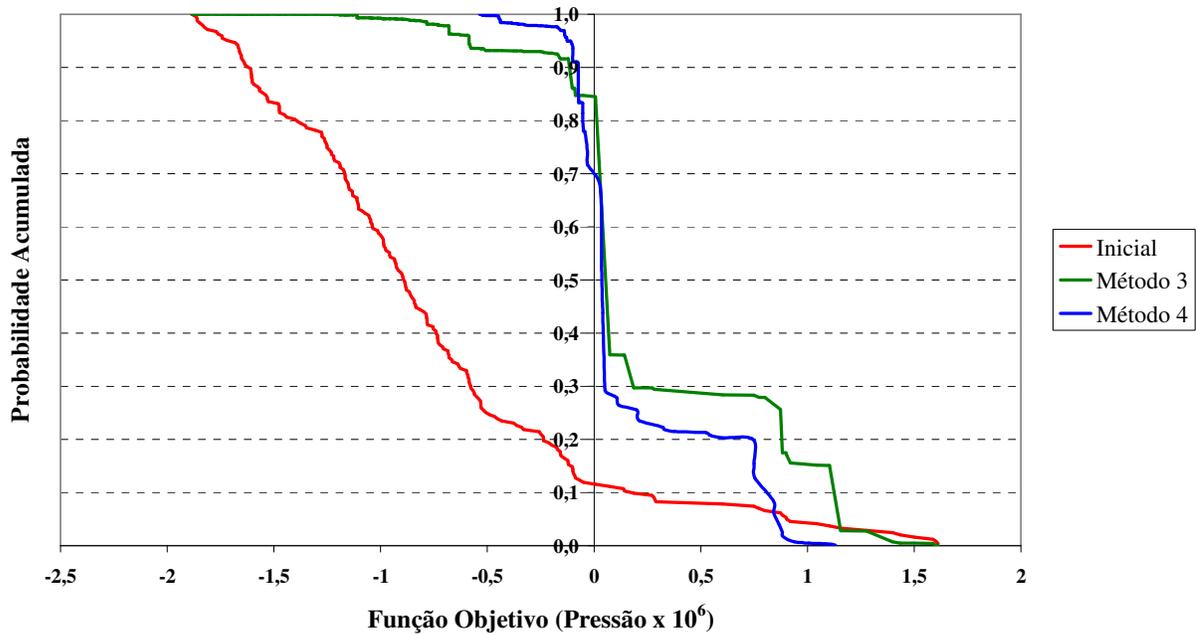


Figura 6.66 – Comparação entre as curvas de incerteza para pressão inicial e dos Métodos 3 e 4 – Caso B.

A análise para a FO da produção de água dos poços indica um aumento da redução da dispersão de 44% para 66% com relação ao caso inicial, havendo também uma melhor centralização em torno do histórico. Já para os dados de pressão dos poços, a diminuição da dispersão também melhora de 32% para 54% com relação ao caso inicial. Quanto à centralização com relação do histórico há apenas uma pequena melhora com relação ao caso inicial.

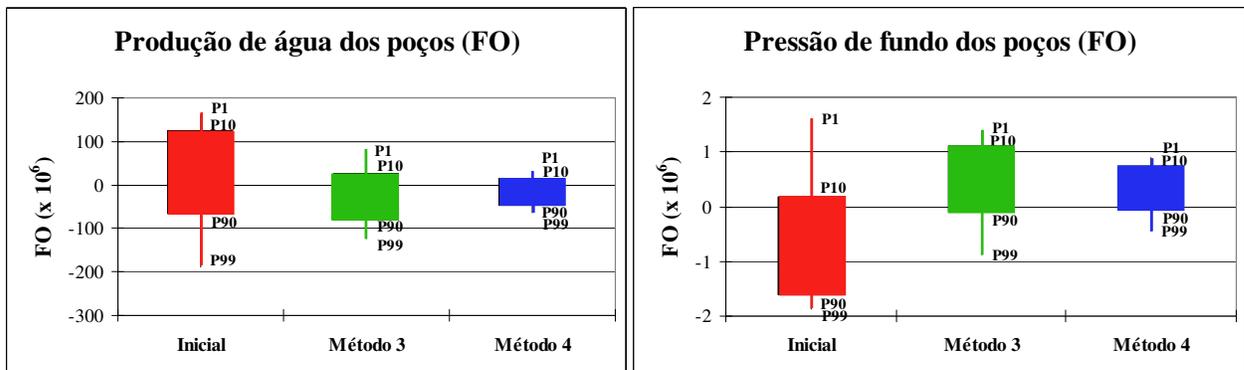


Figura 6.67 – Comparativo da FO de vazão de água e de pressão dos poços – Caso B.

A Figura 6.68 ilustra a produção de água dos modelos situados entre os percentis P10 e P90 das curvas de incerteza do Método 4 e inicial da combinação dos afastamentos das produções de água dos poços (Figura 6.65). Há uma redução significativa das incertezas do reservatório, com a eliminação de modelos muito diferentes do histórico. O número de modelos aumenta com relação ao Método 3.2 de 18 para 38 modelos, porém, devido à redefinição dos níveis, eles estão mais centrados em torno dos dados de produção.

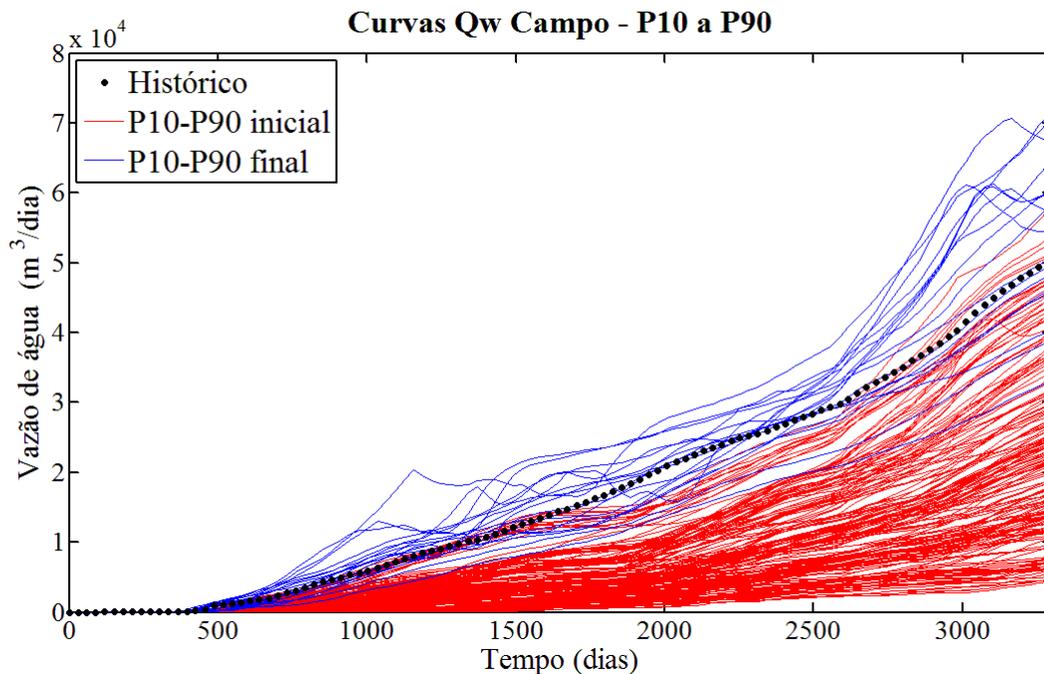


Figura 6.68 – Curvas de produção de água do campo para os modelos entre P10 e P90, resultantes do Método 4 – Caso B.

Utilizando-se os mesmos modelos da Figura 6.68 foram traçados os gráficos de produção de água dos poços PROA-4 e PROA-5 mostrando uma maior redução dos espalhamentos com relação ao método anterior (Figura 6.69), principalmente para o primeiro poço, que apresenta curvas mais parecidas com o histórico de produção.

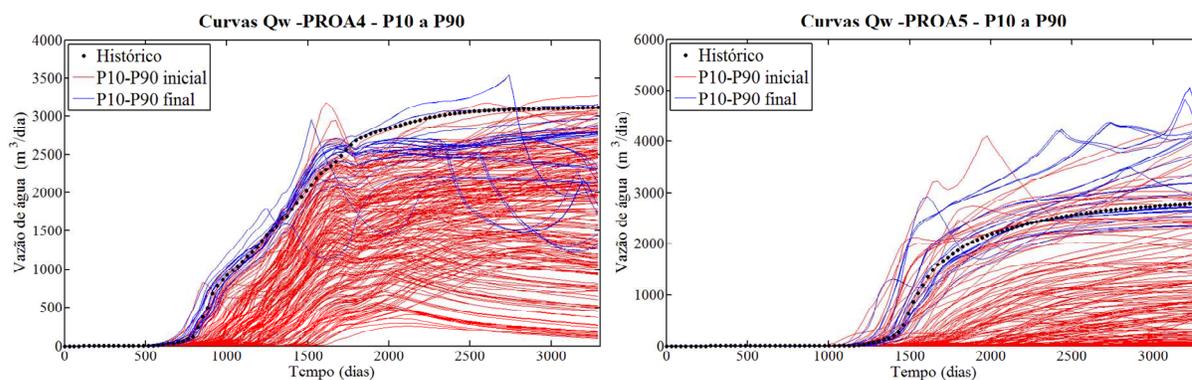


Figura 6.69 – Curvas de produção de água dos poços PROA-4 e PROA-5 para os modelos entre P10 e P90, resultantes do Método 4 – Caso B.

O mesmo raciocínio é utilizado para traçar os gráficos de pressão, porém neste caso, são utilizados os modelos selecionados das curvas de incerteza inicial e do Método 4 das pressões dos poços (Figura 6.66). Apesar do número de modelos entre P10 e P90 aumentar de 28 para 33 com o Método 4, há uma melhoria no espalhamento das curvas, as quais ficam mais próximas dos dados medidos (Figura 6.70). A Figura 6.71, com os gráficos de pressão dos poços PROB-2, PROC-4, PROA-1 e PROA-8 também mostram redução maior das incertezas quando comparados ao Método 3.2.

Analisando-se os gráficos de pressões abaixo, observa-se um maior espalhamento das curvas quando comparados com a vazão de água. Isso pode ser explicado pelo fato da pressão ser mais sensível aos atributos, possibilitando reduzir ainda mais as incertezas em novas etapas de redefinição de níveis e aplicação do Método 3.2. Um dos responsáveis por essa maior incerteza na pressão é o atributo PhiA, cuja faixa de incerteza ainda pode ser mais reduzida visto que a probabilidade redistribuída para o nível 2 foi bem baixa, 3%. Um fato que confirma a importância do atributo PhiA para a pressão é o maior espalhamento das curvas dos poços do Bloco A quando comparados com os outros blocos, pois eles são mais sensíveis a este atributo (Figura 6.71).

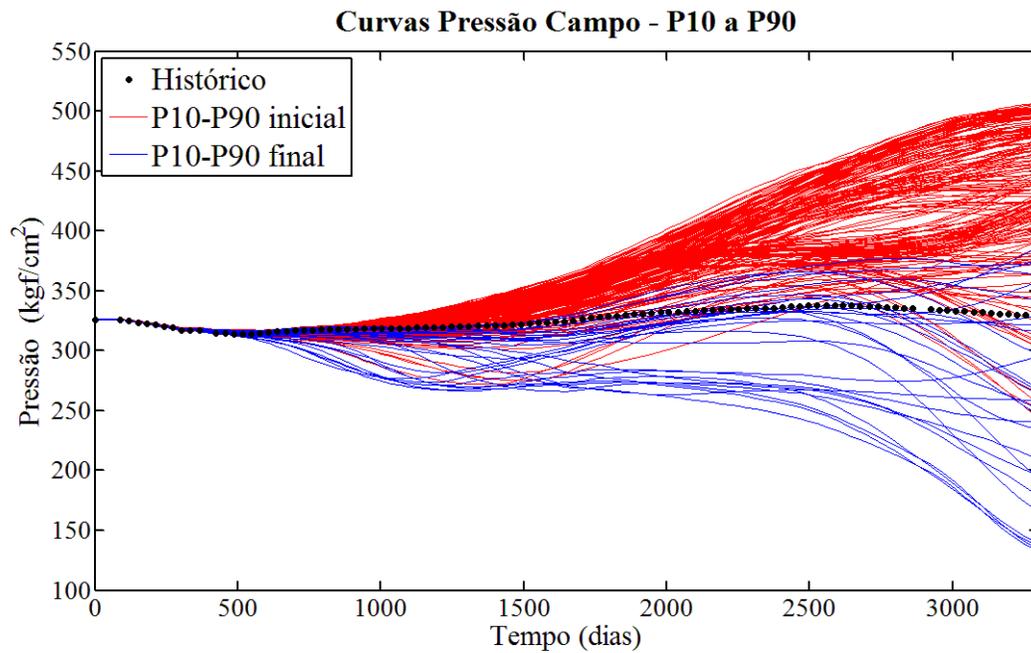


Figura 6.70 – Curvas de pressão do campo para os modelos entre P10 e P90, resultantes do Método 4 – Caso.

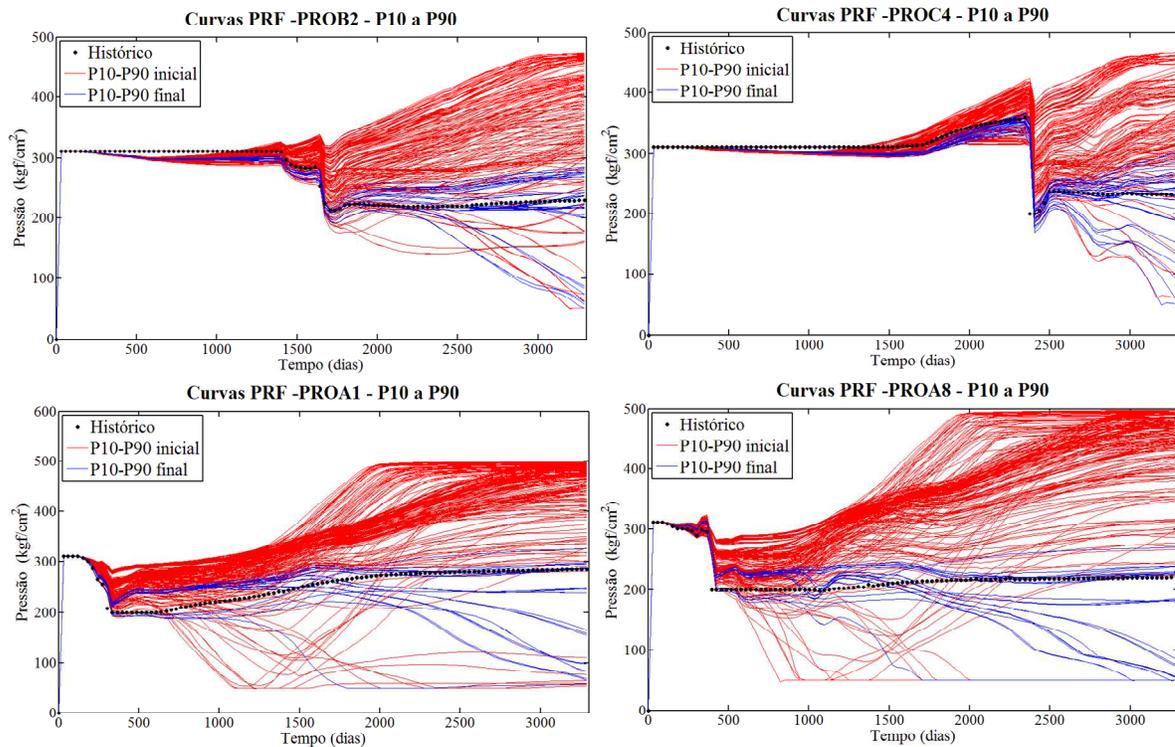


Figura 6.71 – Curvas de PRF dos poços PROB-2, PROC-4, PROA-1 e PROA-8 para os modelos entre P10 e P90, resultantes do Método 4 – Caso B.

De forma similar a feita para o Caso A, pode ser escolhido um conjunto de modelos representativos para as análises futuras, através da seleção de uma faixa centralizada no P50 das curvas de incerteza da vazão de água e da pressão, escolhendo-se os modelos comuns a ambas. Utilizando-se este critério de seleção para o Caso B, uma faixa de 60% em torno do P50 foi utilizada (P20 a P80), obtendo-se uma redução no número de modelos representativos, de 116 modelos iniciais para 20 finais, os quais são utilizados para avaliações futuras.

A Figura 6.72 mostra as curvas para a vazão de água do campo para os modelos iniciais e finais escolhidos na faixa de 60% e o histórico de produção. O conjunto de modelos finais engloba melhor os dados de produção, exibindo também dispersão pequena das curvas, indicando o bom funcionamento da metodologia. Além disso, destaca-se que os modelos iniciais não contêm o histórico, evidenciando o grande desajuste inicial e indicando que os modelos próximos ao P50 inicial não representam os menores afastamentos da curva de incerteza, como desejado.

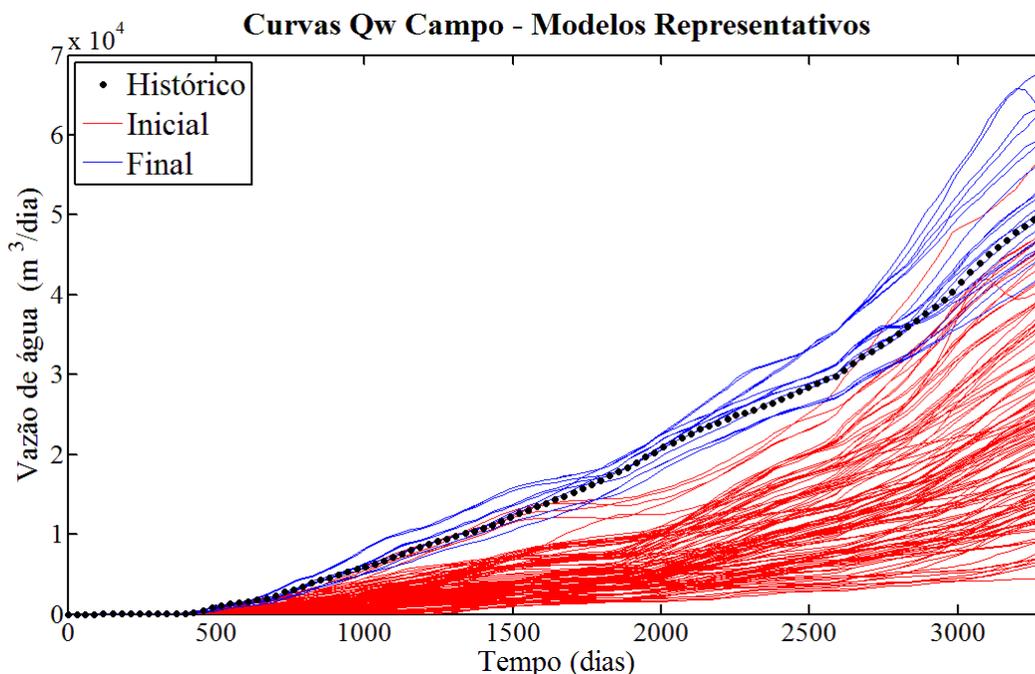


Figura 6.72 – Modelos representativos da vazão de água do campo antes e depois da aplicação do Método 4 – Caso B.

Os resultados para a pressão do campo, Figura 6.73, também são bons, visto que as curvas dos modelos iniciais se distanciam bastante do histórico de pressões no final. A dispersão das curvas finais de pressão é maior que das curvas de vazão de água com alguns modelos

registrando pressão menor. Isso provavelmente ocorre devido à maior sensibilidade da pressão aos atributos incertos, tendo-se uma melhora nos resultados com novas iterações do Método 4.

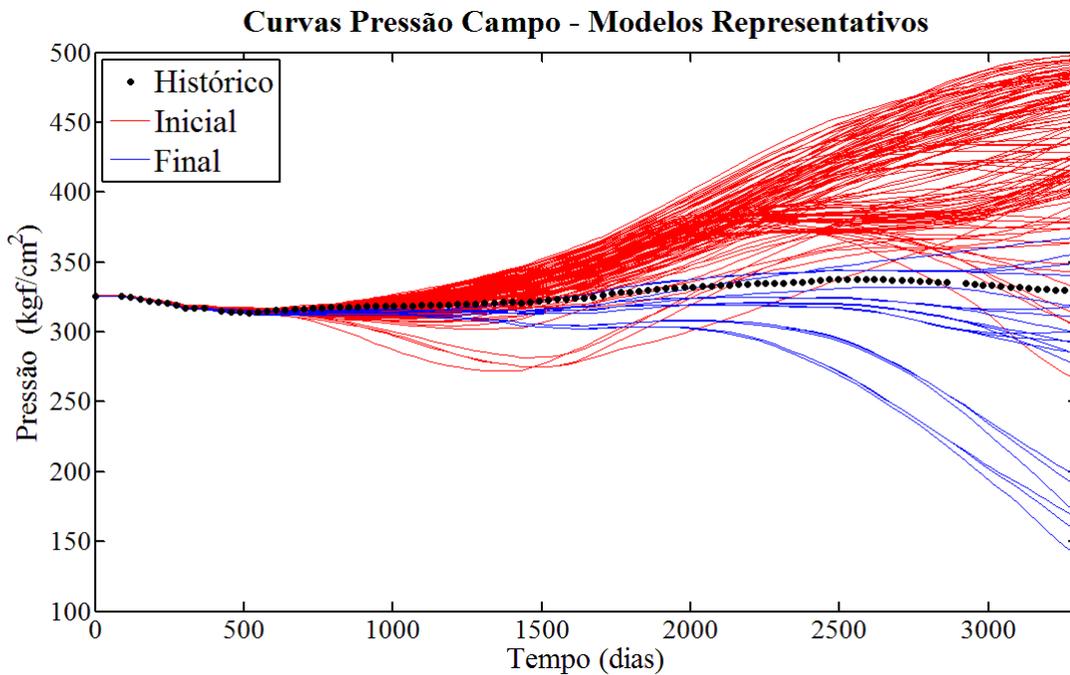


Figura 6.73 – Modelos representativos da pressão do campo antes e depois da aplicação do Método 4 – Caso B.

O comportamento da produção de água e pressão de fundo de alguns poços é exibido nas próximas figuras, nas quais são traçados os gráficos dos modelos iniciais (116) e finais (20) selecionados das curvas de incerteza, conforme explicado acima. A produção de água dos poços PROA-4 e PROC-3 (gráficos da Figura 6.74) apresentam resultados similares ao do campo, com os modelos finais em torno do histórico de produção e o espalhamento deles bastante reduzido. No caso do poço PROA-7, a maioria das curvas finais está bem distribuída em torno do histórico, estando algumas delas mais distantes dele no final da produção (Figura 6.74).

Para o poço PROB-8 (gráfico inferior da Figura 6.74), apesar dos modelos finais não estarem englobando os dados medidos, eles estão mais próximos do histórico que os modelos iniciais. Além disso, eles apresentam uma dispersão menor, indicando uma melhora dos resultados e redução nas incertezas do modelo. É importante salientar que para todos os poços, o espalhamento do conjunto de modelos iniciais é muito grande e, algumas vezes, nem envolve os dados de histórico.

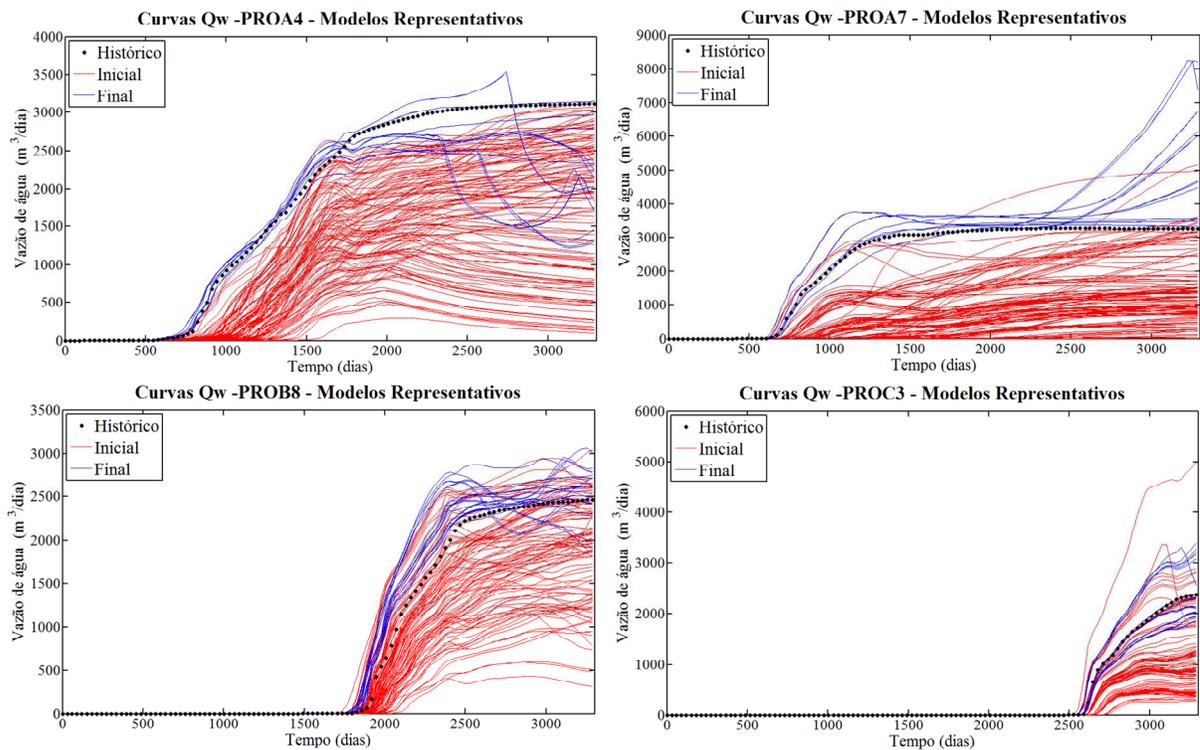


Figura 6.74 – Modelos representativos iniciais e finais da vazão de água dos poços PROA-4, PROA-7, PROB-8 e PROC-3 – Caso B.

Os gráficos de pressão de fundo dos modelos iniciais e finais dos poços, ilustrados na Figura 6.75, apresentam melhorias na resposta em termos de redução das incertezas e de melhor centralização em torno dos dados medidos. Os resultados para os poços são bastante parecidos com os da pressão do campo e indicam melhoria com relação ao Caso A. Os modelos iniciais, em geral, possuem curvas acima do histórico de pressão, e em alguns casos (PROA-1), nem englobam esse histórico. O fato das curvas finais das pressões dos poços serem mais dispersas que as de vazões é explicado possivelmente pela grande influência dos atributos críticos, principalmente  $\Phi A$ , nessa função. Os resultados podem ainda ser melhorados com novas etapas do Método 4 (redefinição dos níveis e aplicação do Método 3.2).

De forma geral, ao utilizar o critério de seleção de uma faixa em torno do P50 das curvas de incerteza, obtém-se um conjunto de modelos com um bom ajuste de histórico e boa representatividade da incerteza, o qual pode ser utilizado para obter previsões probabilísticas do futuro.



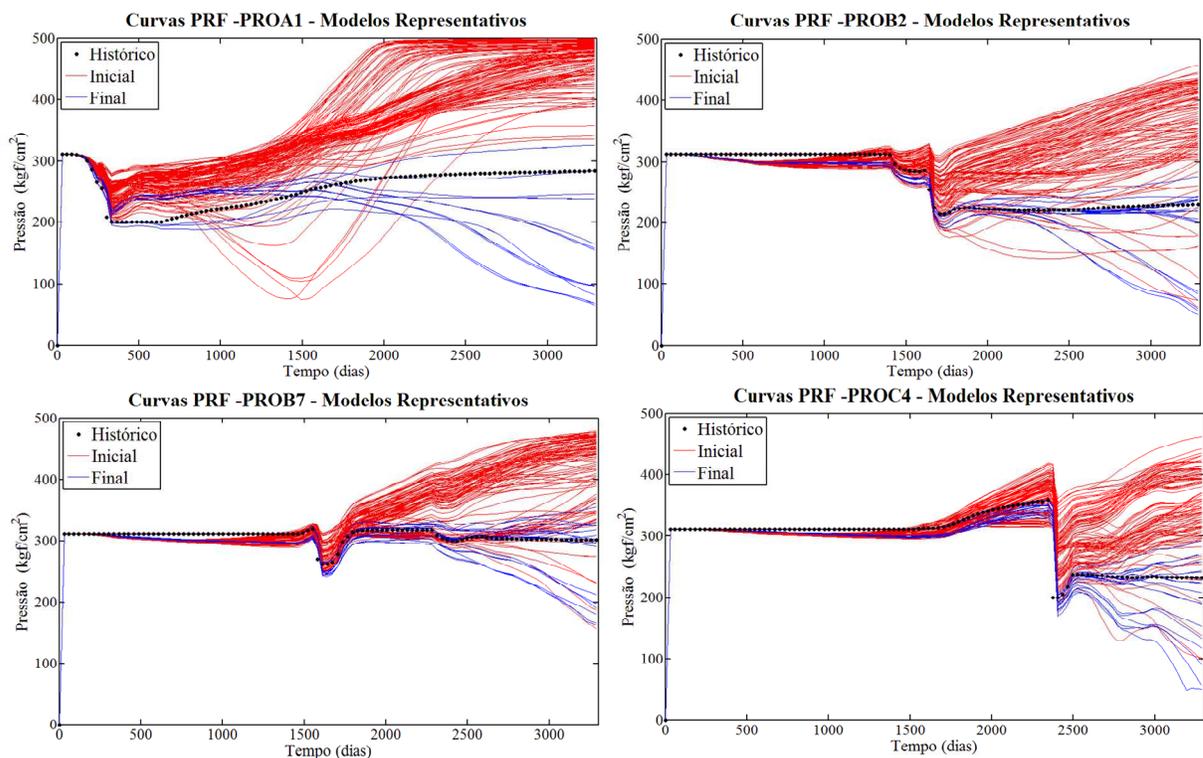


Figura 6.75 – Modelos representativos iniciais e finais da pressão de fundo dos poços PROA-1, PROB-2, PROB-7 e PROC-4 – Caso B.

Os resultados obtidos após a aplicação do Método 4 no Caso B foram bastante satisfatórios, levando a uma grande redução das incertezas e, conseqüentemente, uma diminuição do número de modelos representativos dentro de uma faixa maior em torno do percentil 50. A comparação do Caso B com o Caso A indica que, em modelos complexos e heterogêneos, é muito importante o mapeamento, a seleção dos atributos incertos e, principalmente a definição dos valores dos níveis. O ideal seria utilizar o Caso A com um maior número de atributos críticos, porém, como isso inviabilizaria a aplicação da árvore de derivação, foi criado o Caso B. Este eliminou as incertezas dos atributos não-críticos, gerando melhores respostas para a mitigação das incertezas através do ajuste de histórico e validando a formulação desenvolvida.

### 6.3.3 Comparação dos Métodos

Neste item é feita uma comparação entre os resultados dos métodos aplicados ao Caso B mostrados no item acima. As curvas de incerteza para a vazão de água, sendo a FO a combinação dos afastamentos quadráticos das vazões de água de todos os poços, estão na Figura 6.65. A melhor resposta é a obtida após a aplicação do Método 4 (curva azul escuro), que além de reduzir

a dispersão (diferença entre P10 e P90) em 66%, centraliza melhor em relação ao eixo  $x=0$  que corresponde aos dados de produção. O Método 3.2 (curva verde) apresenta resultados consistentes, porém um pouco piores, com uma menor diminuição da dispersão.

A melhor resposta do Método 4 com relação ao 3 ocorre por causa da redefinição das faixas de incerteza dos atributos incertos, que pelo não conhecimento do campo, podem estar superestimadas. Os resultados obtidos com a aplicação do Método 3 norteiam uma definição mais coerente dos níveis dos atributos para a aplicação do Método 4, alterando as faixas de incerteza e melhorando os resultados.

Para a combinação das pressões de fundo dos poços, ilustrada na Figura 6.66, o resultado quanto a dispersão é similar ao das vazões de água, visto que a maior redução do espalhamento, em cerca de 54%, ocorre com a aplicação do Método 4. Apesar do Método 3.2 apresentar uma melhoria na centralização em torno do histórico similar a do Método 4, aproximando mais o afastamento zero do percentil 50%, sua diminuição na dispersão é inferior.

Em uma análise total, o Método 4 é o que gera resultados mais consistentes para o reservatório, principalmente ao se tratar de modelos com um grande número de poços e grande quantidade de dados a analisar. Isso é explicado pelo uso da formulação do Método 3.2, que é mais robusta, além da utilização da redefinição dos níveis combinada com novas etapas de aplicação do Método 3.2, que leva a um bom refinamento dos resultados, reduzindo melhor a dispersão e centralizando em torno do histórico de produção de forma mais coerente. Sendo assim, consegue-se uma boa redução das incertezas a partir do histórico de produção, permitindo a escolha de um conjunto de modelos representativos com bom ajuste para utilização em análises futuras.

#### **6.4 Discussão Geral**

De forma geral, a metodologia desenvolvida apresenta bons resultados na mitigação das incertezas com o uso dos dados de histórico. Os Métodos 1 e 2, apesar de não apresentarem resultados bons, auxiliaram na definição de algumas falhas da metodologia que puderam ser corrigidas nos métodos propostos. Os Métodos 3 e 4 conseguiram respostas bem melhores, com reduções significativas da dispersão dos modelos em relação ao histórico.

A grande dificuldade está na combinação das diversas funções de ajuste e na parametrização dos atributos incertos, ou seja, na escolha do intervalo de incerteza e na sua discretização em níveis. O Método 4, com a redefinição dos valores dos níveis baseada numa aplicação do Método 3, ajuda a verificar atributos com faixas iniciais superestimadas.

Apesar das limitações encontradas pelo uso da árvore de derivação, quantidade pequena de atributos e utilização de poucos níveis, os resultados da redução das incertezas no caso complexo utilizado foram muito bons, obtendo-se um conjunto de modelos com menor dispersão em torno do histórico. Deste conjunto, podem ser escolhidos alguns modelos representativos, com os melhores ajustes, para a utilização em previsões futuras.

## 7. CONCLUSÕES E SUGESTÕES FUTURAS

A utilização do processo de ajuste de histórico convencional é bastante complexa e trabalhosa, gerando muitas vezes, um único modelo ajustado, que não necessariamente é o correto, devido à multiplicidade de soluções. A busca de novas metodologias para obtenção de melhores resultados no ajuste de histórico vem sendo discutida com frequência. Neste trabalho, foi estudada e melhorada uma metodologia que permite a integração da análise de incertezas com o ajuste de histórico, tendo como objetivo reduzir as incertezas restringindo os modelos incertos em função dos dados observados.

Dois métodos existentes na literatura foram aplicados a um caso complexo, similar a um modelo real de um campo, de forma a testá-los, validá-los e propor melhorias. A partir dos resultados encontrados, foram desenvolvidos dois novos métodos para a obtenção de respostas mais consistentes em reservatórios complexos. Neste capítulo, são resumidas as principais conclusões e são citadas as recomendações para trabalhos futuros.

### 7.1 Conclusões gerais

As principais conclusões do estudo desenvolvido foram:

- A metodologia proposta é capaz de reduzir as incertezas nos atributos a partir dos afastamentos em relação aos dados dinâmicos observados. A intenção não é obter o melhor ajuste determinístico e sim reduzir a variabilidade da previsão da produção a partir de uma redução na incerteza dos atributos;
- A formulação matemática envolvida nos métodos de redistribuição das probabilidades dos atributos com base nos afastamentos em relação ao histórico evoluiu para gerar resultados consistentes na redução de incertezas, mesmo para casos complexos;
- Os métodos apresentados são flexíveis e a programação desenvolvida é de fácil adaptação para cada problema, a função-objetivo adotada, o número de atributos e de níveis pode variar de um caso para outro;

- A análise de sensibilidade deve ser utilizada para detectar os atributos incertos críticos para a aplicação da metodologia, reduzindo o número de atributos e, conseqüentemente, o tempo de simulação;
- Os Métodos 1 e 2 apresentaram alguns problemas ao serem aplicados no caso complexo tratado, devido à grande quantidade de dados a serem tratados e elevado número de poços a ajustar. Os Métodos 3 e 4, propostos possuem uma formulação que incorpora as vantagens de cada um dos métodos anteriores, levando a bons resultados mesmo num caso complexo e com muitas heterogeneidades;
- A aplicação sucessiva do Método 3, com a redefinição dos níveis dos atributos (Método 4) consegue um maior refinamento dos resultados tanto para o ajuste de vazão de água quanto para o de pressão;
- A grande contribuição da formulação criada é a redução do peso do ajuste das funções não influenciadas por um determinado atributo no cálculo das probabilidades dele através do índice de sensibilidade;
- O desenvolvimento desta metodologia mudou o enfoque do ajuste de histórico, incorporando a análise de incertezas e obtendo um grupo de modelos com ajustes possíveis associados a uma probabilidade de ocorrência;
- A obtenção de curvas entre P10 e P90 do modelo do reservatório antes e depois da aplicação do método permite a avaliação da redução das incertezas. Contudo, a escolha final dos cenários representativos para avaliações futuras depende dos critérios adotados pelo engenheiro.

A utilização desta abordagem probabilística da redução das incertezas a partir dos dados de produção permite uma maior confiabilidade nos resultados gerados pela simulação de reservatórios. Com as incertezas mapeadas e avaliadas é possível estimar de forma mais precisa o risco de previsões futuras e de novos projetos.

### **7.1.1 Caso A**

As principais conclusões da aplicação dos quatro métodos no Caso A foram:

- O Método 1 apresentou problemas relativos ao cálculo da simetria, por causa da necessidade de combinar os afastamentos simples de séries de dados diferentes e que, na maioria das vezes, são contrárias – pressão e vazão. Com isso, os resultados para este método não mostraram redução das incertezas para o caso complexo estudado. Recomenda-se usar este método considerando apenas a simetria individualmente para cada função-objetivo;
- O Método 2 , com a inversão dos afastamentos dos modelos sendo feita antes da soma dos modelos de um nível, gerou resultados coerentes, apresentando uma redução pequena no número de modelos entre P10 e P90. Porém, com ele, níveis com mesmo afastamento em relação ao histórico têm a mesma probabilidade, independentemente de envolverem ou não os dados de produção, ou seja, ele não considera a simetria em relação ao histórico. Devido a essa simplificação, pode não apresentar bons resultados quando muitas funções e atributos são utilizados;
- O Método 3 apresentou resultados melhores quanto à redução das incertezas quando comparado com os anteriores, pois eliminou os problemas de combinação de funções com diferentes ordens de grandeza e sentidos contrários ao se calcular as redistribuições de probabilidade para cada função individual. Além disso, sua fórmula incorpora as vantagens de cada um dos métodos anteriores;
- As diferentes formas de se combinar as redistribuições de probabilidade, Métodos 3.1 e 3.2, apresentaram resultados diferentes com uma melhoria progressiva ao se passar de um método para outro. A média aritmética (3.1) é penalizada por funções que não dependem de determinado atributo. Já a média ponderada pela sensibilidade da função ao atributo (3.2) minimiza o problema citado, aplicando um peso maior às distribuições de probabilidades das funções influenciadas pelo atributo e resultando, com isso, em distribuições de probabilidade finais mais adequadas e maior redução do número de modelos situados na faixa P10-P90;
- Apesar dos bons resultados do Método 3.2, o atributo *krw* não teve uma distribuição final coerente com a resposta. Isto pode ser explicado pela não utilização de todas as incertezas na metodologia, visto que 8 atributos incertos ficam no nível mais provável que não necessariamente é o correto e eles provavelmente devem influenciar os resultados do *krw*;

- Com o Método 3.2 houve uma redução da dispersão de cerca de 23% para os dados de vazão de água, porém na pressão não se observou redução da dispersão;
- O Método 3 poderia apresentar resultados melhores se um número maior de níveis fosse utilizado, mas isso ficaria inviável para um número grande de atributos com a formulação de árvore de derivação. Uma forma de solucionar este problema é usar outras técnicas estatísticas como os trabalhos de Maschio et al. (2010) e Vasconcelos (2011). Assim, pode-se realizar o processo em etapas com a mudança gradativa na faixa de incerteza dos atributos, o que levou ao desenvolvimento do Método 4;
- A aplicação do Método 4 levou a um refinamento dos resultados, devido à redefinição dos intervalos de incerteza dos atributos. Ele gerou as melhores respostas, reduzindo a dispersão da vazão de água em 40% e da pressão em 25%;
- Os resultados encontrados mostraram que a metodologia de integração do ajuste de histórico com a análise de incertezas é consistente, apesar de não reduzir de forma excepcional as incertezas no Caso A. Uma possível explicação para isto é o fato de se ter um modelo com muitas heterogeneidades e estar utilizando somente 5 atributos críticos para a aplicação da metodologia.

### 7.1.2 Caso B

As principais conclusões da aplicação dos Métodos 3 e 4 no Caso B foram:

- O Caso B foi criado para testar a formulação da metodologia, pois nele o histórico é gerado a partir de uma combinação dos atributos críticos e, portanto, está contido nos intervalos de incerteza dos atributos. A diferença entre os 2 casos mostra a dificuldade adicional de ter outros atributos incertos além dos tratados na metodologia;
- A eliminação dos 8 atributos não-críticos, colocando-os no valor do histórico levou a uma grande melhoria dos resultados dos Métodos 3 e 4, havendo uma redução significativa das incertezas e do número de modelos na faixa P10-P90;
- A aplicação do Método 3.2 no Caso B mostrou uma redução de 44% da dispersão para os dados de vazão de água e de 32% para os de pressão, evidenciando a grande melhoria das respostas;

- O Método 4, com a redefinição dos níveis dos atributos a partir das probabilidades obtidas do Método 3.2 e aplicação de uma nova etapa deste método, permitiu um refinamento dos resultados, reduzindo ainda mais a dispersão das curvas dos modelos representativos tanto para vazão de água (66%), quanto para a pressão (54%);
- Os resultados do Caso B evidenciam a grande importância da escolha dos atributos e dos seus intervalos de variação, principalmente em casos complexos e com muitas heterogeneidades;
- As curvas entre P10 e P90 de vazão de água e pressão traçadas mostram a redução das incertezas tanto para o campo como para os poços, visto que a diminuição das incertezas foi feita com base nos afastamentos de cada poço individual;
- A escolha de um conjunto de modelos representativos situados numa faixa em torno dos menores afastamentos em relação ao histórico de vazão de água e de pressão (em torno do P50 das curvas de incerteza) permite a avaliação do risco de projetos futuros, garantindo um bom ajuste dos dados de histórico.

## 7.2 Recomendações

Em função dos resultados obtidos, são propostos alguns trabalhos futuros:

- Revisão das fórmulas desenvolvidas, a fim de verificar problemas na aplicação e propor melhorias;
- Incorporação da metodologia a programas computacionais, generalizando sua aplicação para qualquer modelo de reservatório;
- Desenvolvimento de metodologias para a seleção de alguns modelos dentre os representativos resultantes da aplicação dos métodos propostos e, realização de uma previsão de produção com os modelos escolhidos a fim de analisar riscos futuros;
- Utilização de uma maior quantidade de atributos incertos para se conseguir uma melhor redução da incerteza em um caso complexo com muitas heterogeneidades. Isto inviabiliza a aplicação da árvore de derivação devido ao grande número de simulações, sendo necessário utilizar técnicas de amostragem, como Monte Carlo ou Hipercubo Latino, para selecionar os modelos a serem simulados;



- A partir da implementação destas técnicas de amostragem, devem ser analisadas outras melhorias para dar uma maior flexibilidade à metodologia, como a divisão do processo em etapas, alterando a função-objetivo em cada uma delas; a incorporação de novos atributos no meio do processo, sem que seja necessário simular todas as combinações novamente como exige a árvore de derivação. Isto facilitaria a adição de incertezas descobertas ao longo do tempo de produção do campo, Outra melhoria a ser considerada é a alteração dos valores dos níveis a cada iteração de cálculo de probabilidades em função da probabilidade anterior.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA NETTO, S. L. DE., **Redução de Incerteza na Previsão de Comportamento de Reservatórios Utilizando Histórico de Produção e Simulação Numérica**. Campinas, 2003. 147pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

ALPAK, F. O., KATS, F. van, HOHL, D., **Stochastic History Matching of a Deepwater Turbidite Reservoir**. SPE 119030, SPE Reservoir Simulation Symposium, The Woodlands, Texas, 2-4 Fevereiro, 2009.

ALVARADO, M. G., MCVAY, D. A., LEE, W. J., **Quantification of Uncertainty by Combining Forecasting with History Matching**. Journal of Petroleum Science and Technology, 23 (3-4), 445-462, 2005.

BALLIN, P. R., AZIZ, K., JOURNAL, A. G., **Quantifying the Impact of Geological Uncertainty on Reservoir Performing Forecast**. SPE 25238. Symposium on Reservoir Simulation, New Orleans, Louisiana, Fevereiro, 1993.

BECERRA, G. G., **Mitigação de Incertezas Através da Integração com Ajuste de Histórico de Produção**. Campinas, 2007. 193pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

BENNETT, F., GRAF, T., **Use of Geostatistical Modeling and Automatic History Matching to Estimate Production Forecast Uncertainty – A Case Study**. SPE 74389. International Petroleum Conference and Exhibition, México, 10-12 Fevereiro, 2002.

BUSBY, D., FERAILLE, M., GERVAIS, V., **Uncertainty Reduction by Production Data Assimilation Combining Gradual Deformation with Adaptive Response Surface Methodology**. SPE 121274. EUROPEC/EAGE Conference and Exhibition, Amsterdam, The Netherlands, 8-11 Junho, 2009.

CHRISTIE, M., MACBETH C., SUBBEY S., **Multiple History-Matched Models for Teal South the Leading Edge**. Journal of Petroleum Science and Technology, 21. (I3), pp. 286-289, Março, 2002.

COSENTINO, L., **Integrated Reservoir Studies**. Paris: Technip, 2001.

COSTA, A. P. A., SCHIOZER, D. J., POLETTI, C. A., **Use of Uncertainty Analysis to Improve Production History Matching and the Decision Making Process**. SPE 99324. SPE Europec/EAGE Annual Conference and Exhibition, Vienna, Áustria, 12-15 Junho, 2006.

FERAILLE, M., MANCEAU, E., ZABALBA-MEZGHANI, I., ROGGERO, F., HU, L. Y., REIS, L. C., **Integration of Dynamic Data in a Mature Oil Field Reservoir Model to Reduce Uncertainty on Production Forecasting**. AAPG Annual Convention, Salt Lake City, Utah, 11-14 Maio, 2003.

GU, Y., OLIVER, D. S., **History Matching of the PUNQ-S3 Reservoir Model Using the Ensemble Kalman Filter**. SPE 89942. Annual Conference and Exhibition, Houston, Texas, 26-29 Setembro, 2004.

HEGSTAD, B. K., MORE, H., **Uncertainty in Production Forecasts Based on Well Observations, Seismic Data and Production History**. SPE 74699. SPE Journal, vol. 6, Número 4, p. 409-424, Dezembro, 2001.

HU, L. Y., RAVELEC, G. B., ROGGERO, F., NOETINGER, B., HAAS, A., CORRE, B., **Reducing Uncertainties in Production Forecasts by Constraining Geological Modeling to Dynamic Data**. SPE 56703. Annual Technical Conference and Exhibition, Houston, Texas, 3-6 Outubro, 1999.

JENSEN, T. B., **Estimation of Production Forecast Uncertainty for a Mature Production License**. SPE 49091. Annual Technical Conference and Exhibition. New Orleans, Louisiana, Setembro, 1998.

KASHIB, T., SRINIVASAN, S., **Probabilistic Approach to Integrating Dynamic Data in Reservoir Models**. Journal of Petroleum Science and Engineering, vol. 5 (3-4), p. 241-257, Março, 2006.

LANDA, J. L., GUYAGULER, B., **A Methodology for History Matching and the Assessment of Uncertainties Associated with Flow Prediction**. SPE 84465. Annual Technical Conference and Exhibition. Denver, Colorado, 5-8 Outubro, 2003.

LANDA, J. L., KALIA, R. K., NAKANO, A., NOMURA, K., VASHISHTA, U., **History Match and Associated Forecast Uncertainty Analysis – Practical Approaches Using Cluster Computing**. International Petroleum Technology Conference, Doha, Qatar, 21-23 Novembro, 2005.

LEITÃO, H.C., **Ajuste de Histórico Automatizado através de Otimização Multivariada e Paralelização Externa**. Campinas, 1997. 145pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

LÉPINE, O. J., BISSEL, R. C., AANONSEN, S. I., PALLISTER, I.C., BARKER, J. W., **Uncertainty Analysis in Predictive Reservoir Simulation Using Gradient Information**. SPE 57594. SPE Journal, 4 (3), 251-259, 1999.

LOSCHIAVO, R., **Estimativa de Incertezas na Previsão de Desempenho de Reservatórios**. Campinas, 1999. 86pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

MANCEAU, E., MEZGHANI, M., ZABALBA-MEZGHANI, I., ROGGERO, F., **Combination of Experimental Design and Joint Modeling Methods for Quantifying the Risk Associated with Deterministic and Stochastic Uncertainties – An Integrated Study**. SPE 71620. Annual Technical Conference and Exhibition, New Orleans, Louisiana, 30 Setembro- 3 Outubro, 2001.

MASCHIO, C., CARVALHO, C. P. V., SCHIOZER, D. J., **A New Methodology to Reduce Uncertainties in Reservoir Simulation Models Using Observed Data and Sampling Techniques**. Journal Petroleum Science and Engineering, vol. 72, p. 110-119, Maio, 2010.

MASCHIO, C., SCHIOZER, D. J., **Integration of Streamline Simulation and Automatic History Matching**. SPE 89850. SPE Annual Technical Conference and Exhibition, Houston, Texas, 26-29 Setembro, 2004.

MASCHIO, C., SCHIOZER, D. J., MOURA FILHO, M. A. B. de, BECERRA, G. G., **A Methodology to Reduce Uncertainty Constrained to Observed Data**. SPE Reservoir Evaluation & Engineering. 12 (1), p. 167-180 (2009).

MOURA FILHO, M. A. B. de, **Integração de Análise de Incertezas e Ajuste de Histórico**. Campinas, 2006. 131pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

NICOTRA, G., GODI, A., COMINELLI, A., CHRISTIE, M., **Production Data and Uncertainty Quantification: A Real Case Study**. SPE 93280. Reservoir Simulation Symposium, Houston, Texas, 31 Janeiro- 02 Fevereiro, 2005.

PORTELLA, R. C. M., PRAIS, F., **Use of Automatic History Matching and Geostatistical Simulation to Improve Production Forecast**. SPE 53976. Latin American and Caribbean Petroleum Engineering Conference, Caracas, Venezuela, 21-23 Abril, 1999.

OUENES, A., BREFORT, B., MEUNIER, G. DUPERE, S., **A New Algorithm for Automatic History Matching: Application of Simulated Annealing Method (SAM) to Reservoir Inverse Modeling.** SPE 26297, Maio, 1993.

OVREBERG, O., DAMSLETH, E., HALDORSEN, H.H., **Putting Error Bars on Reservoir Engineering Forecast.** SPE 20512. Annual Technical Conference and Exhibition. New Orleans, Louisiana, Setembro, 1990.

REIS, L. C., **Quantificação de Incertezas Volumétricas Condicionada aos Dados Dinâmicos Observados.** Seminário de Reservas e Reservatórios. Salvador, Bahia, 25-29 Setembro, 2005.

ROGGERO, F., HU, L.Y., **Gradual Deformation of Continuous Geostatistical Models for History Matching.** SPE 49004. Annual Technical Conference and Exhibition, New Orleans, Louisiana, 27-30 Setembro, 1998.

SCHAAF, T., LABAT, N., COUREAUD, B., **Using Experimental Designs, Assisted History Matching Tools and Bayesian Framework to Get Probabilistic Production Forecasts.** SPE 113498. 70th EAGE Conference & Exhibition, Roma, Itália, Junho, 2008.

SCHIOZER, D. J., ALMEIDA NETTO, S. L., LIGERO, E. L., MASCHIO, C., **Integration of History Matching and Uncertainty Analysis.** Journal of Canadian Petroleum Technology, v 44, n 7, p 41-46, Julho, 2005.

SOUSA, S. H. G., **Aplicação da Metaheurística Busca Dispersa ao Problema de Ajuste de Histórico.** Campinas, 2007. 128pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

VASCONCELOS, D. D. S., **Mitigação de Incertezas através da Integração com Ajuste de Histórico de Produção e Técnicas de Amostragem.** Campinas, 2011. 104pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP.

WILLIAMS, G. J. J., MANSFIELD, M., MACDONALD, D. G., BUSH, M. D., **Top-Down Reservoir Modeling**. SPE 89974, Annual Technical Conference and Exhibition, Houston, Texas, 26-29 Setembro, 2004.