

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

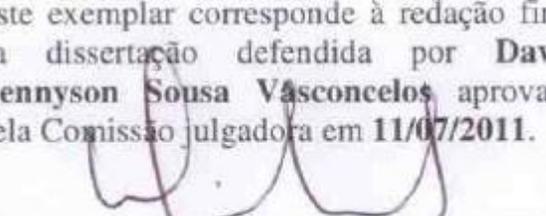
DAVID DENNYSON SOUSA VASCONCELOS

# Mitigação de Incertezas através da Integração com Ajuste de Histórico de Produção e Técnicas de Amostragem

CAMPINAS

2011

Este exemplar corresponde à redação final da dissertação defendida por **David Dennyson Sousa Vasconcelos**, aprovada pela Comissão julgadora em 11/07/2011.

  
Orientador

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

# **Mitigação de Incertezas através da Integração com Ajuste de Histórico de Produção e Técnicas de Amostragem**

Autor: **David Dennyson Sousa Vasconcelos**  
Orientador: **Prof. Dr. Denis José Schiozer**  
Co-orientador: **Pesq. Dr. Célio Maschio**

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

V441m Vasconcelos, David Dennyson Sousa  
Mitigação de incertezas através da integração com  
ajuste de histórico de produção e técnicas de amostragem  
/ David Dennyson Sousa Vasconcelos. --Campinas, SP:  
[s.n.], 2011.

Orientadores: Denis José Schiozer, Célio Maschio.  
Dissertação de Mestrado - Universidade Estadual de  
Campinas, Faculdade de Engenharia Mecânica e Instituto  
de Geociências.

1. Reservatórios (Simulação). 2. Incerteza. 3.  
Amostragem (Estatística). 4. Engenharia de reservatório  
de óleo. I. Schiozer, Denis José. II. Maschio, Célio. III.  
Universidade Estadual de Campinas. Faculdade de  
Engenharia Mecânica e Instituto de Geociências. IV.  
Título.

Título em Inglês: Uncertainty mitigation through integration with history  
matching and sampling techniques

Palavras-chave em Inglês: Reservoirs (Simulation), Uncertainty,  
Sampling (statistics), Oil reservoir  
engineering

Área de concentração: Reservatórios e Gestão

Titulação: Mestre em Ciência e Engenharia do Petróleo

Banca examinadora: Rosângela Barros Zanoni Lopes Moreno, Ana Paula  
Araújo Costa

Data da defesa: 11/07/2011

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

# Mitigação de Incertezas através da Integração com Ajuste de Histórico de Produção e Técnicas de Amostragem

Autor: **David Dennyson Sousa Vasconcelos**  
Orientador: **Prof. Dr. Denis José Schiozer**  
Co-orientador: **Pesq. Dr. Célio Maschio**

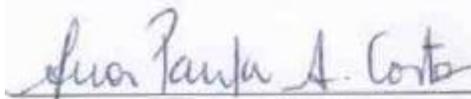
A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:



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



Prof. Dr.<sup>a</sup>. Rosângela Barros Zanoni Lopes Moreno  
DEP/FEM/UNICAMP



Dr.<sup>a</sup>. Ana Paula Araújo Costa  
PETROBRÁS/UN-RNCE/ENGP/CER

Campinas, 11 de julho de 2011.

## **DEDICATÓRIA**

Dedico esse trabalho aos meus pais, Amadeu de Vasconcelos Filho (*in memorian*) e Solemar Vasconcelos, pelo exemplo de perseverança e grandioso esforço para tornar esse momento possível.



## AGRADECIMENTOS

Ao longo dessa jornada muitos contribuíram, direta ou indiretamente, para possibilitar esse momento, a concretização de um sonho. Agradeço primeiramente a Deus, pela família que tenho e pelas experiências que tenho vivido.

À minha família, meus pais Solemar e Amadeu (*in memoriam*), meus irmãos Katy, Keith e Diego, o meu cunhado Sidclay, meus sogros Ivanilda (*in memoriam*) e Sandro, e a minha namorada Dávilla, por todo amor, carinho, esforço e confiança. Também por terem me proporcionado uma base moral e emocional para superar todos os desafios e adversidades da vida.

Ao Prof. Dr. Denis José Schiozer pela competência, profissionalismo, paciência, compreensão e orientação nesses anos de mestrado. Agradeço também pelo exemplo de dedicação a vida profissional e busca pelo equilíbrio com a vida pessoal.

Ao Pesq. Dr. Célio Maschio por tanta dedicação, atenção, competência e por ser altamente prestativo sempre.

Aos amigos Cássio Pettan, Fernando Perin e Calos Barreto pela disponibilidade e auxílio na programação dos algoritmos usados na dissertação e no desenvolvimento deste trabalho.

Aos pesquisadores e funcionários do UNISIM pelo suporte e colaboração prestados.

À Sônia, Michelle e Guilherme Tonin pela atenção e toda ajuda prestada ao longo do curso.

À Alice Obata, Délcio, Fátima, Giselle, Leandro, professores, alunos e demais funcionários do DEP pela ajuda direta ou indireta na realização deste trabalho.

Aos amigos que me proporcionaram um crescimento pessoal e enriquecimento cultural, em um ambiente agradável, durante o mestrado: Ortelan, Humberto (Beto), Alexandre (Cabs), Fernando (Fifí), Luis (Naga), André Bertolini, Rafael (Gaúcho), Avansi, André Machado (Pocotó), Manuel, Philippe, Marcos C., Márcio, Alê Cruz, Carol Badin, Cynthia, Ju Diniz, Marcelo Zampieri, Vinícius Botechia, Henrique Cotrim, Alexandre Milagres e demais com quem convivi.

À CNPq (Conselho Nacional de Desenvolvimento e Científico e Tecnológico) e ao CEPETRO (Centro de Estudos de Petróleo) pelo suporte financeiro para a realização deste trabalho.



*“Muitos são os obstinados que se empenham no caminho que escolheram, poucos os que se empenham no objetivo.”*

Friedrich Nietzsche

## RESUMO

VASCONCELOS, David Dennyson Sousa. *Mitigação de Incertezas através da Integração com Ajuste de Histórico de Produção e Técnicas de Amostragem*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2011. 104p. Dissertação de Mestrado.

As incertezas geológicas influenciam diretamente a previsão de comportamento de reservatórios de petróleo, podendo, muitas vezes, tornar mais complexo o uso de ferramentas como simuladores de fluxo. A integração de técnicas de redução de incertezas e ajuste de histórico ganha um importante destaque neste processo, principalmente devido às limitações apresentadas pelas técnicas tradicionais de ajuste de histórico, sobretudo em campos com poucos dados de produção e maiores incertezas. O objetivo principal desse trabalho é obter um ajuste de histórico probabilístico a partir da redução das incertezas do modelo de reservatório. A proposta desse estudo é apresentar contribuições a uma metodologia existente, com o objetivo de possibilitar o tratamento de um elevado número de atributos incertos e aumentar a eficiência do processo. O método consiste em um procedimento dinâmico de calibração de propriedades do reservatório, utilizando dados observados e técnicas de amostragem. Os atributos considerados, discretizados em níveis de incertezas (com uma probabilidade associada), são submetidos a um processo de amostragem, com o método de Hipercubo Latino e, posteriormente combinados estatisticamente. Cada combinação entre níveis dos diferentes atributos resulta em um modelo de simulação e, após realizadas as simulações, novas probabilidades são estimadas, para cada nível, a partir de um procedimento que utiliza a diferença entre os dados observados e simulados, relativos a cada modelo. A qualidade do ajuste obtido pode ser avaliada a partir das curvas de incertezas, compostas por modelos representativos das probabilidades iniciais e finais de cada atributo e através dos indicadores propostos nesse trabalho, como variabilidade das probabilidades e afastamentos por poço. Os resultados obtidos indicam um método capaz de fornecer resultados confiáveis no processo de mitigação de incertezas, quando há dados de

histórico disponíveis. O aumento na qualidade dos resultados com esse método, para as situações onde os atributos possuem mais níveis discretos que o convencional (normalmente são 3 níveis), depende do esforço computacional (em termos do número de simulações). Contudo, não há um aumento expressivo do número de simulações, como ocorre na técnica de árvore de derivação usada em trabalhos anteriores.

*Palavras-Chave*

Simulação de Reservatórios, Ajuste de Histórico, Mitigação de Incertezas, Técnicas de Amostragem e Hipercubo Latino.

## ABSTRACT

VASCONCELOS, David Dennyson Sousa Vasconcelos. *Uncertainty Mitigation through Integration with History Matching and Sampling Techniques*. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2011. 104p. Dissertação de Mestrado.

The geological uncertainties influence directly the prediction of reservoir behavior, making more complex the use of tools such as flow simulators. The integration between mitigation uncertainties techniques and history matching gains an important emphasis in this process, mainly due to the limitations presented by history matching traditional techniques, especially in areas with little observed data and greater uncertainties. The main objective of this work is to set a probabilistic history matching from the mitigation of reservoir uncertainty. The purpose of this study is to provide input to an existing methodology, in order to allow treatment of a large number of uncertain attributes and increase process efficiency. The method involves a dynamic procedure of global and local calibration of the geological model, using observed data and sampling techniques. The considered attributes, discretized into uncertainty levels (with an associated probability), are undergoing a sampling process, with Latin Hypercube method and then statistically combined. Each combination among levels of different attributes results in a complete simulation model, and after the simulations are performed, new probabilities are estimated for each level, from a procedure that uses the difference between observed and simulated data for each model. The quality of the history matching process can be evaluated from the uncertainty curves, composed of representative models of initial and final probabilities of each attribute, and using the indicators proposed in this work, as probabilities variability and the difference between observed and simulated data by well. The results obtained with this methodology indicate a tool capable of providing reliable results in the uncertainty mitigation process, when there is observed data available. The increase in quality of results with this method, for situations where the attributes has a number of discrete levels higher than the

conventional technique (3 levels) depends on the computational effort (in terms of simulations number), but without the significant increase in the simulations number, as in the derivation tree technique used in previous works.

*Key Words*

Reservoir Simulation, History Matching, Uncertainty Mitigation, Sampling Techniques and Latin Hypercube.

## SUMÁRIO

DEDICATÓRIA.....	v
AGRADECIMENTOS.....	vii
RESUMO.....	xi
ABSTRACT.....	xiii
SUMÁRIO.....	xv
LISTA DE FIGURAS.....	xix
LISTA DE TABELAS.....	xxiii
LISTA DE NOMENCLATURAS.....	xxv
1. INTRODUÇÃO.....	1
1.1 Motivação/Desafio.....	4
1.2 Objetivos.....	5
1.3 Premissas.....	5
1.4 Organização da Dissertação.....	6
2. FUNDAMENTAÇÃO TEÓRICA.....	7
2.1 Ajuste de Histórico.....	7
2.1.1 Função Objetivo ( <i>FO</i> ).....	8
2.1.2 Ajuste de Histórico Assistido.....	10
2.2 Análise de Incertezas.....	11
2.2.1 Análise de Sensibilidade.....	14
2.2.2 Métodos estatísticos de avaliação do impacto de incertezas.....	15

2.2.3	Curva de Incertezas .....	19
3.	REVISÃO BIBLIOGRÁFICA .....	23
3.1	Análise de Incertezas de Reservatórios .....	23
3.2	Uso de Métodos Estatísticos para Estimativa de Incertezas e Perfis Probabilísticos .	24
3.3	Uso de Hipercubo Latino em Estudos na Área de Petróleo.....	25
3.4	Integração entre técnicas de análise de incertezas e ajuste de histórico .....	26
3.5	Linha de Pesquisa de Referência .....	31
3.5.1	Função Objetivo de Referência.....	33
3.5.2	Estimativa de novas probabilidades .....	35
4.	METODOLOGIA .....	39
4.1	Metodologia Geral .....	39
4.2	Características comuns com o método de referência.....	40
4.3	Metodologia Proposta .....	41
4.3.1	Algoritmo de Amostragem.....	43
4.3.2	Indicadores de Qualidade do Resultado e Critérios de Parada.....	46
5.	APLICAÇÃO .....	51
5.1	Descrição dos Casos .....	51
5.1.1	Caso A: Modelo de Simulação Simples.....	52
5.1.2	Caso B: Modelo de Simulação Complexo .....	54
6.	RESULTADOS E DISCUSSÕES .....	59
6.1	Caso A – Modelo de Simulação Simples .....	59
6.1.1	Caso A1 – 3 níveis discretos .....	59
6.1.2	Caso A2 – 5 níveis discretos .....	65
6.1.3	Caso A3 – 7 níveis discretos .....	69

6.1.4	Análise Comparativa dos Resultados do Caso A.....	73
6.2	Caso B – Modelo de Simulação Complexo.....	76
6.2.1	Caso B1 – 3 níveis discretos .....	77
6.2.2	Caso B2 – 5 níveis discretos .....	80
6.2.3	Caso B3 – 7 níveis discretos .....	84
6.2.4	Análise Comparativa dos Resultados do Caso B .....	87
6.3	Discussões.....	93
7.	CONCLUSÃO E RECOMENDAÇÕES .....	95
7.1	Conclusões Gerais .....	95
7.2	Conclusões Específicas.....	96
7.3	Recomendações .....	97
	REFERÊNCIAS BIBLIOGRÁFICAS .....	99



## LISTA DE FIGURAS

Figura 2.1 – Ilustração de múltiplas respostas obtida com técnica de ajuste de histórico.....	10
Figura 2.2 – Ilustração esquemática da distribuição de probabilidades de um atributo discretizado em 3 níveis de incertezas.....	13
Figura 2.3 – Gráfico tipo tornado (Diagrama de Pareto).....	14
Figura 2.4 – Diagrama esquemático de uma árvore de derivação.....	16
Figura 2.5 – Esquema de sorteio por Hipercubo Latino, dividindo os níveis em intervalos.....	19
Figura 2.6 – Ilustração de uma curva de incertezas.....	20
Figura 3.1 – Ilustração da composição de modelos de simulação com 2 atributos incertos discretizados em 3 níveis cada.....	32
Figura 3.2 – Esquemático da seleção dos atributos por nível.....	32
Figura 3.3 – Posição das Curvas de Produção em Relação aos Dados Observados. ....	34
Figura 3.4 – Mapa de dispersão do erro médio (afastamento quadrático) por nível. ....	36
Figura 3.5 – Ilustração de dispersão do inverso do erro médio por nível (elevado ao fator peso) e as probabilidades finais do atributo.....	36
Figura 4.1 – Ilustração do fluxograma simplificado das características comuns. ....	40
Figura 4.2 – Fluxograma da metodologia proposta.....	42
Figura 4.3 – Fluxograma do algoritmo de amostragem.....	44
Figura 4.4 – Ilustração da eliminação precoce de um nível, a partir de uma amostra muito pequena, sem as equações de redistribuição gradativa.....	46
Figura 4.5 – Ilustração da representação da variabilidade das probabilidades por nível. ....	47
Figura 4.6 – Ilustração da seleção dos modelos representativos das incertezas inicial e final.....	48
Figura 4.7 – Ilustração <i>FO</i> do campo antes e após a aplicação da metodologia.....	49

Figura 4.8 – Ilustração dos afastamentos dos poços.....	49
Figura 5.1 – Perspectiva do modelo de simulação do Caso A. ....	53
Figura 5.2 – Destaque das 8 regiões de diferentes permeabilidades (Caso A).....	53
Figura 5.3 – Perspectiva do modelo de simulação do Caso B.....	55
Figura 5.4 – Fáceis do reservatório. ....	56
Figura 6.1 – Probabilidades Caso A1: 200 Simulações.....	60
Figura 6.2 – Variabilidade das Probabilidades de $K_{x1}$ (Caso A1).....	61
Figura 6.3 – Variabilidade das Probabilidades de $K_{x2}$ (Caso A1).....	61
Figura 6.4 – Variabilidade das Probabilidades de $K_{x3}$ (Caso A1).....	62
Figura 6.5 – Curva de Incertezas do Caso A1. ....	63
Figura 6.6 – Comparativo da $FO$ antes e após a redução de incertezas (Caso A1).....	64
Figura 6.7 – Afastamento por poço (Caso A1).....	65
Figura 6.8 – Probabilidades Caso A2: 300 Simulações.....	66
Figura 6.9 – Variabilidade das Probabilidades de $K_{x1}$ (Caso A2).....	67
Figura 6.10 – Variabilidade das Probabilidades de $K_{x3}$ (Caso A2).....	67
Figura 6.11 – Comparativo da $FO$ antes e após a redução de incertezas (Caso A2): 300 simulações. ....	68
Figura 6.12 – Afastamento por poço (Caso A2).....	69
Figura 6.13 – Probabilidades Finais 8 Atributos 7 níveis (1000 Iterações). ....	70
Figura 6.14 – Variabilidade das Probabilidades de $K_{x3}$ (Caso A3).....	71
Figura 6.15 – Comparativo da $FO$ antes e após a redução de incertezas (Caso A3).....	72
Figura 6.16 – Afastamento por poço (Caso A3).....	72
Figura 6.17 – Resumo $FO$ inicial e final dos modelos representativos das incertezas dos Caso A1, Caso A2 e Caso A3 para 400 simulações. ....	73
Figura 6.18 – Curvas de Produção dos Poços 2 e 4 (Caso A1). ....	74

Figura 6.19 – Curvas de Produção dos Poços 2 e 4 (Caso A2).	75
Figura 6.20 – Curvas de Produção dos Poços 2 e 4 (Caso A3).	76
Figura 6.21 – Variabilidade das Probabilidades (Por2), Caso B1.	77
Figura 6.22 – Variabilidade das Probabilidades do atributo TF4, Caso B1.	78
Figura 6.23 – Curva de Incertezas para o para 3 níveis.	79
Figura 6.24 – Comparativo da <i>FO</i> antes e após a redução de incertezas (Caso B1).	79
Figura 6.25 – Afastamento por poço (Caso B1).	80
Figura 6.26 – Variabilidade das Probabilidades (Por2), Caso B2.	81
Figura 6.27 – Variabilidade das Probabilidades (Por3), Caso B2.	81
Figura 6.28 – Variabilidade das Probabilidades de Kx1 (Caso A2).	82
Figura 6.29 – Comparativo da <i>FO</i> antes e após a redução de incertezas (Caso B2).	83
Figura 6.30 – Afastamento por poço (Caso B2).	83
Figura 6.31 – Variabilidade das Probabilidades (Por2), Caso B3.	84
Figura 6.32 – Variabilidade das Probabilidades (Kx1), Caso B3.	85
Figura 6.33 – Variabilidade das Probabilidades de TF4 (Caso B3).	85
Figura 6.34 – Comparativo da <i>FO</i> antes e após a redução de incertezas (Caso B3).	86
Figura 6.35 – Afastamento por poço (Caso B3).	87
Figura 6.36 – Resumo <i>FO</i> inicial e final dos modelos representativos das incertezas dos Caso B1, B2 e B3 para 800 simulações.	88
Figura 6.37 – Curvas de Produção dos Poços 4 e 7 (Caso B1).	89
Figura 6.38 – Curvas de Produção dos Poços 4 e 7 (Caso B2).	90
Figura 6.39 – Curvas de Produção dos Poços 1 a 3 (Caso B3).	91
Figura 6.40 – Curvas de Produção dos Poços 4 a 6 (Caso B3).	92
Figura 6.41 – Curvas de Produção dos Poços 7 e 8 (Caso B3).	93



## LISTA DE TABELAS

Tabela 2.1 – Quantidade de modelos em relação à quantidade de atributos e níveis.....	17
Tabela 5.1 – Resumo dos 3 cenários com diferentes níveis de discretização (Caso A).....	54
Tabela 5.2 – Resumo geral dos atributos incertos considerados. ....	56
Tabela 5.3 – Resumo dos 3 cenários com diferentes níveis de discretização (Caso B). ....	57



## LISTA DE NOMENCLATURAS

### Letras Latinas

$\beta$

### Subscritos

ini – inicial

min – mínimas

n – níveis

it – iterações

obs – observados

sim – simulados

s – com sinal

### Siglas

A – número de atributo

AS – análise de Sensibilidade

D – erro ou afastamento simples

$d^{\text{obs}}$  – dados observados

$d^{\text{sim}}$  – dados simulados

E – erro quadrático

$E_s$  – erro quadrático com sinal

E&P – exploração e produção na indústria do petróleo

F – peso atribuído a cada erro quadrático

FO – função objetivo

HL – hipercubo latino

$IE_n^e$  – inverso do erro médio do nível

I – índice de proporcionalidade das probabilidades

it – iterações

$it_{min}$  – quantidade mínima de iterações

MC – Monte Carlo

$Mn$  – número de máximo de modelos que um nível pode participar

n – número de níveis

$Np$  – produção de óleo

$P_n$  – probabilidade estimada a partir do  $IE_n^e$

$P_{ini}$  – probabilidade inicial

$P_{nit}$  – probabilidade proporcional ao número de modelos sorteados em relação ao  $it_{min}$

S – quantidade de fatores com  $E_s$  calculado

# 1. INTRODUÇÃO

A previsão de comportamento de reservatórios tem papel fundamental na avaliação de projetos de exploração e produção (E&P) de petróleo. As informações obtidas neste processo podem minimizar os riscos e auxiliar a tomada de decisão. No entanto, esta tarefa apresenta dificuldades devido à quantidade de incertezas provenientes dos parâmetros envolvidos e, por isso, a avaliação de diferentes cenários é necessária. Previsões de produção e/ou reservas provenientes da avaliação de um único cenário (determinístico) podem, muitas vezes, proporcionar resultados não correspondentes ao comportamento do reservatório posteriormente.

Na indústria petrolífera moderna, o simulador de fluxo apresenta-se como ferramenta importante para o gerenciamento de reservatórios. Sua importância pode ser destacada desde a descoberta até o abandono (descomissionamento). Com a finalidade de representar o comportamento de reservatórios, através de modelos de simulação, essa ferramenta torna possível a avaliação de diferentes cenários para previsão de comportamento. Por outro lado, a quantidade elevada de incertezas inerentes a um reservatório torna sua aplicação bastante complexa e, para obter resultados mais confiáveis, os modelos de simulação necessitam passar por um processo de calibração (ajuste de histórico).

As principais dificuldades existentes na aplicação de métodos para minimizar incertezas consistem na insuficiência de dados e informações disponíveis do reservatório, associadas à elevada quantidade de atributos incertos existentes. Em um processo de ajuste de histórico, por exemplo, essa dificuldade torna-se evidente uma vez que quantidades elevadas de atributos incertos, aliada à quantidade reduzida de dados de produção disponíveis, podem levar a múltiplas soluções; combinações entre diferentes atributos incertos podem gerar resultados semelhantes para um mesmo histórico de produção disponível.

A técnica de ajuste de histórico de produção tem como objetivo principal calibrar os modelos de simulação, a partir da alteração dos dados de entrada (atributos incertos, tais como permeabilidade, permeabilidade relativa, porosidade, entre outros), respeitando os limites estabelecidos na fase de caracterização, de modo a tornar os dados de saída coerentes com os

dados observados do reservatório (Sousa, 2007). Normalmente, esta técnica consiste em minimizar uma função objetivo (*FO*), que é basicamente a diferença (ou afastamento) entre os dados observados e dados simulados. A definição da função objetivo é um importante passo neste processo.

Por se tratar de um problema inverso, com muitos atributos a serem ajustados e muitas funções objetivo, o ajuste de histórico tradicional é uma técnica bastante complexa e apresenta algumas dificuldades. Conforme citado anteriormente, a quantidade elevada de atributos incertos pode levar a múltiplas respostas, onde um mesmo histórico de produção pode ser ajustado para diferentes cenários (modelos de simulação). Quanto menor a quantidade de dados de produção disponíveis, maior a possibilidade de serem aceitos diferentes cenários como resposta. O elevado esforço computacional e o tempo envolvido na análise do problema são outros fatores que devem ser destacados.

Muitos trabalhos vêm sendo desenvolvidos para minimizar essas limitações, porém grande parte desses trabalhos é pouco eficiente para a maioria dos problemas, sendo mais adequada para alguns casos específicos.

Técnicas de análise de incertezas (*AI*) também são bastante utilizadas para composição e avaliação de diferentes cenários sob incertezas. Segundo Loschiavo (1999), as incertezas provenientes da caracterização dos reservatórios podem ser tratadas como um problema probabilístico, onde os atributos incertos são discretizados em níveis de incertezas (respeitando os limites estabelecidos na fase de caracterização). A combinação entre os diferentes níveis desses atributos resulta em um modelo de simulação completo, com uma probabilidade associada.

Para Moura Filho (2006), o uso da técnica de *AI* isoladamente (não associado à técnica de ajuste de histórico, por exemplo) pode muitas vezes levar a avaliação de cenários pouco representativos das incertezas envolvidas em um determinado projeto, ou seja, cenários muito afastados dos dados reais observados.

Com base nos problemas e limitações apresentados pelas técnicas de ajuste de histórico e análise de incertezas, a integração entre os aspectos positivos de cada uma delas resulta em um método mais eficiente para a redução de incertezas. Essa integração proporciona a avaliação de cenários com maior representatividade das incertezas envolvidas em um projeto, uma vez que

possibilita a definição de uma faixa alvo próxima aos dados observados. A partir de um método que utiliza o afastamento entre os dados observados e os dados simulados, novas probabilidades são estimadas para cada um dos cenários. Conseqüentemente, são obtidos modelos de simulação que correspondem a uma faixa de incertezas com maior representatividade.

Moura Filho (2006) apresentou uma metodologia que possibilita essa integração. Os dados observados e os dados simulados são comparados. Em seguida, as probabilidades dos cenários com maior afastamento são reduzidas e os cenários com menor afastamento têm suas probabilidades ampliadas. Essa metodologia foi validada e aplicada em um caso teórico simples. Posteriormente, Becerra (2007) proporcionou contribuições a essa metodologia a partir da sua aplicação em um caso mais complexo, onde também foi realizado o ajuste simultâneo com atributos globais e regionais/locais. Contudo, essas metodologias têm algumas limitações devido ao uso da técnica de árvore de derivação, que se torna inviável para um número elevado de atributos e/ou níveis discretos.

Maschio *et al.* (2010) apresentaram contribuições à metodologia de Moura Filho (2006) e Becerra (2007) a partir de uma nova abordagem para o método de redução de incertezas, uma alternativa ao uso da técnica de árvore de derivação. Essa nova abordagem consiste na integração entre as técnicas de análise de incertezas, ajuste de histórico e técnicas de amostragem. Os níveis discretos dos atributos incertos são sorteados aleatoriamente a partir do método de Monte Carlo (*MC*) e combinados. Cada combinação resulta em um modelo de simulação completo. Em seguida, novas probabilidades são estimadas para cada nível a partir de indicadores baseados na *FO* de cada cenário considerado.

O trabalho de Maschio *et al.* (2010) apresentou alguns avanços em relação aos anteriores, uma vez que a quantidade de cenários possíveis deixa de ser um fator limitante nesse método, além de possibilitar a estimativa de novas probabilidades a partir de um número reduzido de simulações (quando comparado ao uso da árvore de derivação). Por outro lado, a possibilidade de melhorias é aceitável. Devem ser considerados critérios para a definição da quantidade de cenários sorteados, a utilização de outras técnicas de amostragem, criação de indicadores para avaliar os resultados e revisão no procedimento de estimativa de novas probabilidades.

O tema proposto neste trabalho é a continuação da pesquisa iniciada por Moura Filho (2006), aprimorada por Becerra (2007) e mais recentemente por Maschio *et al.* (2010), sendo essa

última a principal referência utilizada e que será melhor abordada no Capítulo 3 (revisão bibliográfica). Esta metodologia tem como foco um ajuste probabilístico, proporcionando a redução das incertezas provenientes da fase de caracterização do reservatório, baseado no uso de ajuste de histórico, análise de incertezas e técnicas de amostragem. Diferentemente do que acontece no método de ajuste de histórico tradicional, onde normalmente se busca a definição de um modelo determinístico para realizar previsões.

Esta metodologia parte da ideia geral dos trabalhos anteriormente citados e consiste basicamente na estimativa de novas probabilidades para cada nível discreto dos atributos incertos considerados, a partir de indicadores baseados na *FO* de cada cenário (modelo de simulação). Assim como no trabalho apresentado por Maschio *et al.* (2010), os níveis dos atributos incertos são amostrados e combinados estatisticamente, porém com o método de Hipercubo Latino (*HL*). A combinação entre os diferentes níveis de cada atributo resulta em modelos de simulação completos. Em seguida, novas probabilidades são estimadas para cada nível discreto (baseado na *FO* de cada cenário). O processo de redução de incertezas é finalizado quando as novas probabilidades apresentarem baixa variabilidade em relação às probabilidades anteriores, sendo esse aspecto (critério de parada) uma das melhorias propostas.

## **1.1 Motivação/Desafio**

A principal motivação para o desenvolvimento deste trabalho consiste no desafio de contribuir com melhorias de metodologias já consolidadas, como o trabalho apresentado por Maschio *et al.* (2010), a partir do desenvolvimento de métodos e procedimentos mais eficientes para redução de incertezas em reservatórios com elevada quantidade de atributos incertos. A necessidade por métodos mais precisos (que proporcione resultados mais confiáveis) para estimativa de novas probabilidades dos atributos incertos avaliados, baseada no uso de técnicas de amostragem e dados de histórico, complementa este desafio.

As principais metodologias utilizadas como referência para o desenvolvimento deste trabalho apresentaram importantes avanços no processo de mitigação de incertezas utilizando dados de histórico de produção. Contudo, é importante ressaltar que apesar desses avanços, essas metodologias indicaram a necessidade de melhoria em seus métodos.

Outro fator importante para a motivação deste estudo consiste na necessidade de tornar essa metodologia menos subjetiva e, conseqüentemente, mais quantitativa. A fim de obter maior confiabilidade na aplicação desse método, a definição de critérios para avaliação da quantidade de cenários sorteados e a criação de indicadores de qualidade do método de redistribuição de probabilidades devem ser consideradas.

## **1.2 Objetivos**

Este trabalho tem como objetivo principal apresentar contribuições a metodologia de mitigação de incertezas desenvolvida por Moura Filho (2006), aprimorada por Becerra (2007) e Maschio *et al.* (2010). Pretende-se aumentar a eficiência e a confiabilidade do método de calibração de modelos de simulação com elevado número de atributos incertos, a partir de um ajuste probabilístico dos modelos de simulação, sem o aumento significativo no número de simulações e, se possível, redução deste número.

A partir de sugestões de trabalhos anteriores, alguns pontos importantes também são objetivos deste trabalho:

- Dar maior consistência ao método de redistribuição de probabilidades, com o desenvolvimento de um procedimento para redistribuição gradativa;
- Criar e testar indicadores para medir a variabilidade das probabilidades obtidas e definir esses indicadores como critério de parada do processo;
- Avaliar a possibilidade de trabalhar com uma discretização dos atributos incertos em uma quantidade maior de níveis discretos (normalmente são utilizados 3 níveis discretos).

## **1.3 Premissas**

O escopo deste trabalho é restrito à etapa de redução de incertezas provenientes da fase de caracterização do reservatório, a fim de obter um ajuste probabilístico. Portanto, não contempla os procedimentos de modelagem e parametrização do reservatório, tais como:

- Definição dos atributos;

- Discretização em níveis de incerteza; e
- Tipo de distribuição de probabilidades (uniforme, normal, lognormal etc).

Assume-se ainda que os atributos incertos, considerados, são independentes em relação ao seu comportamento, ou seja, não são consideradas as influências ou correlação entre eles.

#### **1.4 Organização da Dissertação**

Este trabalho está dividido em sete capítulos. No Capítulo 1 é realizada uma breve introdução sobre o tema proposto, são apresentados também as motivações/desafios, os objetivos deste trabalho e as premissas.

No Capítulo 2 é apresentada uma fundamentação teórica, com conceitos importantes sobre o tema proposto, que possibilita um melhor entendimento do texto. São abordados conceitos como ajuste de histórico, análise de incertezas, análise de sensibilidade, técnicas de amostragem e curva de incertezas e risco.

O Capítulo 3 consiste em uma revisão bibliográfica, onde são apresentados diversos trabalhos que abordam os temas de ajuste de histórico, redução de incertezas, o uso de técnicas de amostragem aplicado a métodos de mitigação de incertezas e a integração entre essas diferentes técnicas.

A metodologia desenvolvida neste trabalho é apresentada no Capítulo 4 onde as semelhanças com trabalhos de referências e as particularidades são abordadas de forma detalhada e ilustrada.

No Capítulo 5 são apresentados e detalhados os dois casos considerados para essa fase do trabalho, as características de cada modelo, especificidades da aplicação da metodologia para cada caso e critérios que devem ser considerados na avaliação dos resultados.

No Capítulo 6 são apresentados os resultados que são analisados e discutidos.

Finalmente, o Capítulo 7 consiste nas conclusões deste trabalho, com o foco nas principais contribuições deste estudo. São apresentadas também recomendações para trabalhos futuros.

## **2. FUNDAMENTAÇÃO TEÓRICA**

Este capítulo contém uma abordagem sobre alguns conceitos importantes para o entendimento das etapas seguintes do trabalho. São apresentadas definições sobre a técnica de ajuste de histórico de produção (Item 2.1), análise de incertezas (Item 2.2), redução de incertezas através da integração com ajuste de histórico de produção, técnicas de amostragem e curva de incertezas.

### **2.1 Ajuste de Histórico**

No estudo de projetos de E&P de petróleo, decisões são tomadas baseadas nas previsões de comportamento de reservatórios, na maioria dos casos, provenientes de modelos de simulação. Destaca-se então a importância de obter modelos de simulação que representem o mais próximo possível um reservatório real. Com este enfoque, são observados e avaliados parâmetros incertos provenientes da fase de caracterização dos reservatórios e dados de histórico de produção. Posteriormente, essas informações são utilizadas em técnicas que tem por finalidade proporcionar modelos de simulação mais confiáveis, através do ajuste de histórico de produção.

A técnica de ajuste de histórico de produção tradicional consiste em um procedimento manual de modificação de atributos incertos, dos modelos de simulação, a fim de tornar os dados de saída dos simuladores mais próximos dos dados reais, observados ao longo do tempo de produção do reservatório. Essa técnica tem como objetivo encontrar uma combinação (dentro de uma determinada faixa) que resulta no melhor ajuste, além de reduzir o número de simulações sempre que possível. Esse procedimento é finalizado quando os objetivos são atingidos, ou quando os recursos e tempo disponíveis sejam esgotados. A aplicação desta técnica geralmente resulta na escolha de um modelo de simulação determinístico, que é utilizado para realizar as previsões e estudos de projetos.

Para a aplicação dessa técnica, os dados petrofísicos, geológicos e propriedades de rocha e fluido (oriundos da fase de caracterização do reservatório) são fundamentais. Os dados obtidos

através de poços (produtores e injetores), tais como: vazão de fluido (água, óleo e gás), pressão do reservatório e pressão dinâmica de escoamento também são de grande importância para o ajuste. Dados de produção de fluidos do campo, região ou de poços, provenientes de modelos de simulação e dados observados, são normalmente comparados a fim de encontrar os modelos que apresentem menor afastamento ou maior concordância entre eles.

### 2.1.1 Função Objetivo (*FO*)

A comparação realizada entre dados de simulação e os dados observados é denominada função objetivo (*FO*) e, pode ser classificada como função objetivo simples, quando composta por dados de uma única natureza (vazão de água, óleo, ou pressão do reservatório, por exemplo) ou função objetivo composta, quando composta pela combinação de dados de natureza diferente (vazão de água e óleo; vazão de água, óleo e pressão do reservatório, por exemplo). Esta função tem por finalidade representar o erro ou grau de aproximação entre os dados de simulação e dados observados, de modo a avaliar quantitativamente a qualidade do ajuste (Kabir *et al.*, 2003). Dependendo do caso, a *FO* pode ser expressa por umas das equações apresentadas a seguir (Equação 2.1 ou Equação 2.2).

$$FO(x_1, x_2, \dots, x_n) = \sum_{i=1}^m \beta_i |d_i^{sim} - d_i^{obs}| \quad 2.1$$

ou

$$FO(x_1, x_2, \dots, x_n) = \sum_{i=1}^m \beta_i (d_i^{sim} - d_i^{obs})^2 \quad 2.2$$

onde  $x_i$  representa qualquer atributo do modelo com influência significativa sobre a função objetivo,  $\beta_i$  é o peso a ser imposto a um determinado dado  $i$ ,  $d_i^{obs}$  o valor observado da propriedade ajustada e,  $d_i^{sim}$  o valor calculado da propriedade ajustada, que pode ser qualquer dado de produção de um ou um conjunto de poços. A Equação 2.2 é normalmente utilizada em métodos de regressão não linear, como mínimos quadrados. A definição de qual *FO* deve ser utilizada depende do propósito do estudo e tipo de problema (Costa, 2003).

A técnica de ajuste de histórico tradicional apresenta algumas dificuldades e limitações. Por tratar-se de um problema inverso e, portanto, como todo problema dessa natureza altamente complexa, uma das dificuldades consiste na ocorrência de múltiplas soluções. Essa dificuldade torna-se ainda mais impactante quando há uma quantidade elevada de atributos incertos e/ou poucos dados de histórico disponíveis, além de uma função objetivo composta. Tais características podem proporcionar o ajuste de diversos cenários para um mesmo conjunto de dados de histórico, quanto menor a quantidade de dados de produção disponíveis, maior a possibilidade de serem aceitos diferentes cenários como resposta.

Quando há uma grande quantidade de modelos ajustados, qual modelo escolher? O “melhor modelo”? Estudos recentes, como apresentado por Reis *et al.* (2009) descreve que o “melhor modelo” depende do objetivo do estudo (previsão de produção de poços existentes e projeto para perfuração e completação exigem diferentes níveis de qualidade do modelo). Além disso, a escolha do “melhor modelo” significa escolha de único modelo, que não corresponde à necessidade da empresa (pois é insuficiente para representar as incertezas existentes nos reservatórios), pode muitas vezes ser útil, entretanto é insuficiente. Na prática, novos dados devem ser incorporados ao longo do processo e, muitas vezes, mudanças significativas têm que ser feitas. Ao incorporar novas informações o modelo utilizado pode não ser o “melhor” modelo, múltiplos modelos deveriam ser considerados na fase anterior.

O elevado esforço computacional e o tempo dedicado à análise do problema também devem ser destacados como problemas relacionados ao ajuste de histórico tradicional, uma vez que é sempre necessário um julgamento final do engenheiro de reservatório para a escolha de soluções coerentes com as informações disponíveis (Leitão, 1997).

De modo a ilustrar a principal dificuldade anteriormente citada, a Figura 2.1 apresenta um cenário com ocorrência de múltiplas soluções para um caso hipotético. Nesta ilustração são apresentadas algumas curvas de produção de água em função do tempo. O caso base representado pela curva verde, dois cenários provenientes de um processo de ajuste de histórico, Ajuste 1 (curva azul) e Ajuste 2 (curva vermelha) respectivamente, cujos parâmetros de entrada tiveram seus valores alterados, e os dados observados em preto. É possível verificar que a curva proveniente do Ajuste 2 apresenta maior concordância no início da produção, enquanto a curva proveniente do Ajuste 1 apresenta maior concordância após um certo tempo.

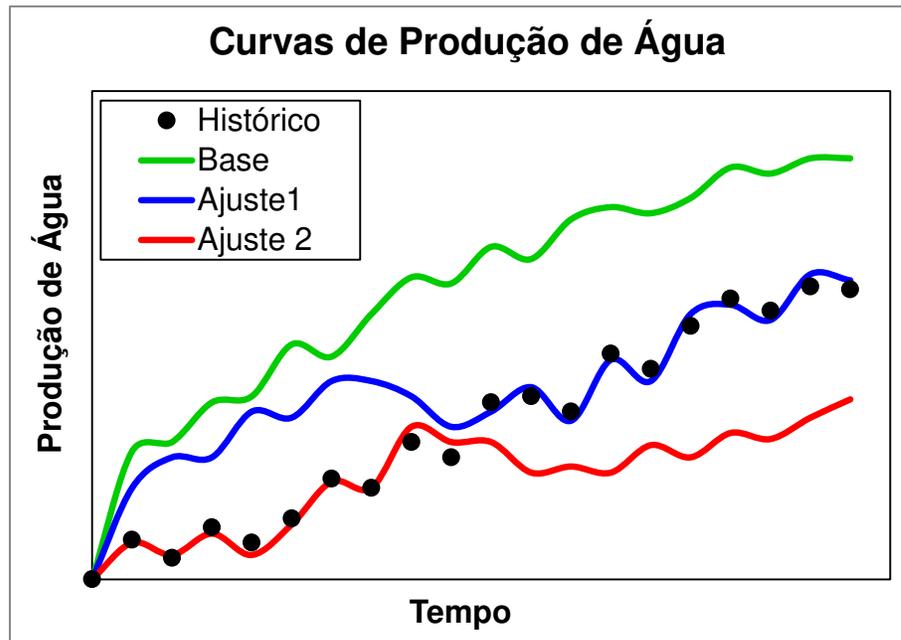


Figura 2.1 – Ilustração de múltiplas respostas obtida com técnica de ajuste de histórico.

Ao analisar as curvas ilustradas na Figura 2.1 é possível notar que ambas as curvas provenientes do ajuste (Ajuste 1 e Ajuste 2) apresentaram concordância com os dados observados em algum momento, ao longo da produção. Entretanto, não é possível definir qual modelo apresenta melhor ajuste. Neste exemplo, foi utilizado um caso hipotético simples, onde as curvas de produção representam dois cenários possíveis apenas, porém na prática, a quantidade de cenários possíveis com respostas semelhantes pode ser bem maior. Pode-se observar ainda que nenhum dos modelos apresenta um ajuste perfeito, indicando que ainda há incertezas no modelo; por isso, ao invés de escolher um modelo para representar o problema, pode escolher faixas de valores nas quais os atributos implicam em comportamento do reservatório próximo do real observado.

### 2.1.2 Ajuste de Histórico Assistido

O processo de ajuste de histórico manual é bastante demorado e ineficiente para maioria dos casos, principalmente em casos mais complexos. Desta forma, a automatização parcial desta técnica destaca-se como uma medida atraente, sobretudo, com os excelentes avanços na área

computacional (Leitão, 1997). Para Ma (2008), a técnica de ajuste de histórico parcialmente automatizado, ou ajuste assistido, é semelhante à técnica de ajuste de histórico tradicional, exceto pela utilização de programas para ajustar alguns parâmetros do reservatório, em vez da intervenção direta do profissional responsável (substituindo algumas etapas manuais no processo de ajuste do reservatório). Esse procedimento tende a acelerar o processo de ajuste a partir da redução do esforço manual, além de possibilitar a avaliação de uma quantidade maior de combinações de atributos. Normalmente o ajuste assistido proporciona um maior esforço computacional.

Segundo Sousa (2007), uma importante característica da adoção do método de ajuste assistido é o aumento da produtividade do profissional envolvido no processo, possibilitando a eliminação de tarefas repetitivas, como a geração de casos de simulação e a avaliação da qualidade do ajuste obtido. Contudo, é importante reforçar que assim como no ajuste manual, o julgamento final da equipe técnica de estudo do reservatório, para a escolha de uma solução coerente com os dados disponíveis e com os objetivos do estudo, é sempre necessária (Maschio e Schiozer, 2003).

Apesar dos avanços nos estudos de técnicas mais eficientes para o ajuste de histórico, a falta de segurança nas previsões de comportamento de reservatório, proveniente de um modelo determinístico, é a principal limitação desta técnica. A não unicidade da resposta no ajuste de histórico implica na necessidade de se avaliar uma gama de cenários possíveis, bem como o uso de métodos estatísticos para análise dos atributos incertos.

## **2.2 Análise de Incertezas**

Embora haja diferentes definições para incertezas, na indústria de petróleo a mais comum descreve incertezas como uma grandeza associada à falta de conhecimento de atributos (geológicos, tecnológicos ou econômicos) à qual não é possível atribuir um valor de maneira precisa (Loschiavo, 1999).

A complexidade intrínseca aos reservatórios de petróleo faz com que muitas incertezas estejam envolvidas na sua caracterização. Essas incertezas muitas vezes são provenientes da maioria das técnicas disponíveis hoje, como:

- Medições indiretas das propriedades (como perfis elétricos, radioativos e magnéticos);
- Análise de testemunho para ensaios e determinação direta de propriedades;
- Levantamentos sísmicos 2D e 3D (interpretação da estrutura presente no sub-superfície); e
- Testes de longa duração.

Em cada uma dessas técnicas as incertezas podem ser geradas por diferentes fatores, a precisão dos equipamentos utilizados e simplificações matemáticas podem ser citadas como exemplos.

A quantidade elevada de incertezas envolvidas em um projeto de E&P de petróleo pode influenciar diretamente nas decisões de gerenciamento de um campo. Portanto, a quantificação do impacto dessas incertezas é de extrema importância e relevância para aumentar a confiabilidade dos resultados e auxiliar nas decisões.

Os atributos incertos a serem considerados em uma análise de incertezas devem ser definidos e selecionados na etapa inicial da fase de caracterização do reservatório. Geralmente os dados disponíveis são insuficientes para o conhecimento dos atributos analisados. A equipe responsável pela fase de caracterização estabelece então os limites (mínimo e máximo) dos valores possíveis de cada atributo, normalmente através de técnicas de geoestatística, analogias com outros campos e com base em suas experiências.

A técnica de análise de incertezas pode ser definida como a avaliação do impacto dos atributos incertos no comportamento de um reservatório. As incertezas relativas aos valores dos atributos incertos podem ser expressas através de distribuições probabilísticas, onde cada atributo incerto pode ser discretizado em níveis de incerteza, segundo uma função de densidade de probabilidades (fdp) e honrando os limites previamente estabelecidos.

Sabe-se, porém, que nem sempre se dispõe de dados objetivos que permitam identificar a distribuição de probabilidades de um determinado atributo. Entretanto, para fins de estimativa, cada atributo é geralmente discretizado em três níveis de incertezas (Øvreberg *et al.*, 1992; Jensen, 1998; Loschiavo, 1999), representando os valores das classes otimistas, prováveis,

pessimistas ( $P_{10}$ ,  $P_{50}$  e  $P_{90}$  respectivamente), a probabilidade de cada nível é definida a partir de uma *fdp* (Figura 2.2).

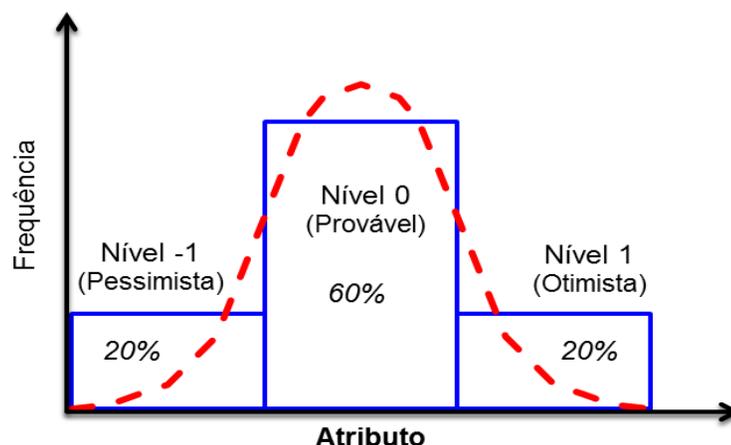


Figura 2.2 – Ilustração esquemática da distribuição de probabilidades de um atributo discretizado em 3 níveis de incertezas.

Loschiavo (1999) ressalta ainda que a discretização da *fdp* dos atributos em apenas três níveis é uma simplificação geralmente válida para fins de estimativa. Todavia, tal simplificação pode levar a distorções nos resultados finais. Costa (2003) conclui que esse efeito pode ser pequeno quando um grande número de atributos for considerado, mas pode ser mais significativo quando esse número for menor. Ballin (1993) sugere a utilização de até cinco níveis.

Em um estudo de caso Loschiavo *et al.* (2000) cita a ocorrência de agrupamento de perfis probabilísticos de produção condicionados a três níveis do parâmetro mais crítico e, sugere um maior número de níveis de discretização, nestes casos.

Devido à quantidade elevada de atributos incertos envolvidos em uma modelagem de reservatório, a avaliação e classificação dos impactos destes atributos na função objetivo devem ser consideradas, uma vez que, o número de simulações está diretamente relacionado à quantidade de atributos incertos e níveis discretos. Logo, o uso técnicas de qualificação dos atributos incertos, como de análise de sensibilidade (AS, Item 2.2.1), é fundamental na análise de incertezas.

### 2.2.1 Análise de Sensibilidade

O objetivo principal da análise de sensibilidade é a redução do número de atributos, através da escolha dos mais críticos (Steagall, 2001). Neste contexto, cada atributo é avaliado e classificado em relação ao impacto (positivo ou negativo) que produz na *FO* ao assumir seus valores extremos (máximo e mínimo) individualmente, enquanto os demais atributos permanecem com seus valores prováveis (centrais). Este procedimento deve ser realizado para cada atributo individualmente, permitindo identificar os atributos com maior influência no resultado final.

Cada atributo avaliado na análise de sensibilidade têm seus valores normalizados em relação ao seu maior valor, obtendo índices que variam de zero a um (insensível à máxima sensibilidade, respectivamente) e são normalmente representados em um diagrama de Pareto (gráfico do tipo “tornado”). Esse tipo de diagrama é usado para estabelecer as prioridades em um número variado de dados e informações. Isso facilita a identificação e classificação de cada atributo em relação ao seu impacto (Figura 2.3).

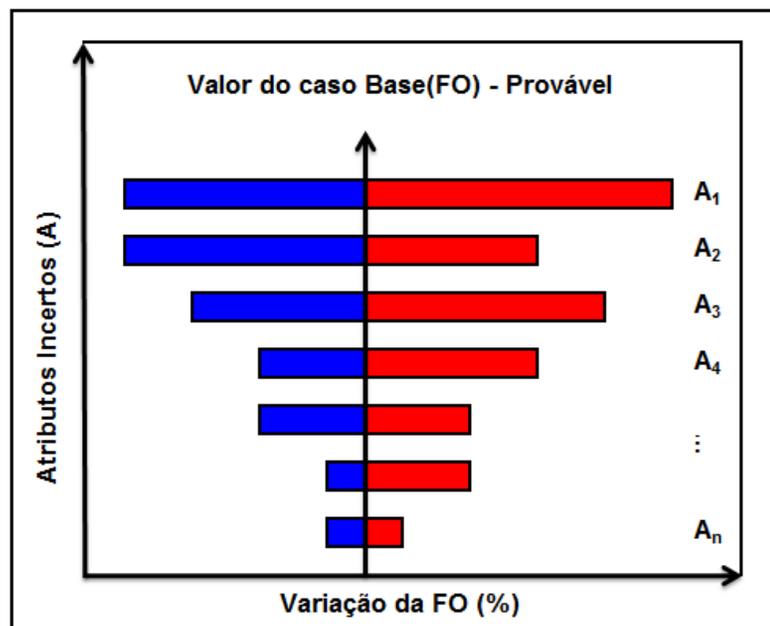


Figura 2.3 – Gráfico tipo tornado (Diagrama de Pareto).

Em um processo de análise de sensibilidade tradicional, realizam-se duas simulações por atributo. Para um estudo mais completo, todos os níveis podem ser simulados gerando o número de simulações segundo a Equação (2.3).

$$NS_{AS} = \left[ \sum_{i=1}^N A_i(n_i - 1) \right] + 1 \quad 2.3$$

onde  $A_i$  é a quantidade de atributos do grupo discretizado em  $n_i$  níveis e  $N$  é o número de grupo de atributos.

Com os resultados da análise de sensibilidade, alguns atributos podem, inclusive, sofrer eliminação de níveis, assim, as probabilidades dos valores remanescentes devem ser redistribuídas (Costa, 2003). Neste caso, é importante avaliar o impacto desses atributos/níveis em diferentes  $FO$ , antes de eliminar.

Esta técnica auxilia a escolha dos atributos críticos que devem ser considerados em uma análise de incertezas estatística, como os métodos de Árvore de Derivação ( $AD$ ) e métodos baseados no uso de técnicas de amostragem, Monte Carlo ( $MC$ ) e Hipercubo Latino ( $HL$ ), a partir de um esforço computacional ainda pequeno.

A variação de cada atributo, para o seu valor máximo e/ou mínimo, pode causar impacto positivo ou negativo na  $FO$ . Entretanto, a variação de dois ou mais atributos diferentes pode anular mutuamente os impactos desses atributos sobre a  $FO$ , caso cada um deles cause um impacto inversamente proporcional ao outro. Apesar do efeito descrito, é possível obter uma curva de produção próxima aos dados de histórico, porém que não representa necessariamente um ajuste real.

### **2.2.2 Métodos estatísticos de avaliação do impacto de incertezas**

A partir da década de 90, previsões de produção sob um enfoque probabilístico tem sido crescente nas áreas de E&P de petróleo, devido ao elevado grau de incertezas inerentes aos projetos neste setor (Steagall, 2001).

Nas últimas décadas muitos trabalhos foram desenvolvidos e publicados sob essa temática. Como resultados desses estudos novos métodos foram apresentados com o objetivo de avaliar e mitigar o impacto das incertezas. Dentre os métodos apresentados neste período pode-se destacar a técnica de Árvore de Derivação (AD, Item 2.2.2.1) e o uso de técnicas de amostragem, como o método de Monte Carlo (MC, Item 2.2.2.2) e recentemente Hipercubo Latino (HL, Item 2.2.2.3), associada a técnicas de análise de incertezas.

### 2.2.2.1 Árvore de Derivação

A técnica de árvore de derivação destaca-se como uma metodologia consolidada e eficiente para um número baixo de atributos incertos e níveis discretos. Essa técnica é representada por um diagrama ramificado que assemelha-se a uma árvore. A técnica de Árvore de Derivação é baseada na técnica de árvore de decisão, porém não possui nó de decisão. Logo, todos os cenários possíveis são realizados.

Cada ramo da árvore define um modelo de simulação completo (cenário), composto por uma combinação diferente de atributos e uma probabilidade associada equivalente ao produto das probabilidades dos atributos que o compõe. O somatório das probabilidades de todos os cenários possíveis resulta na unidade (Figura 2.4).

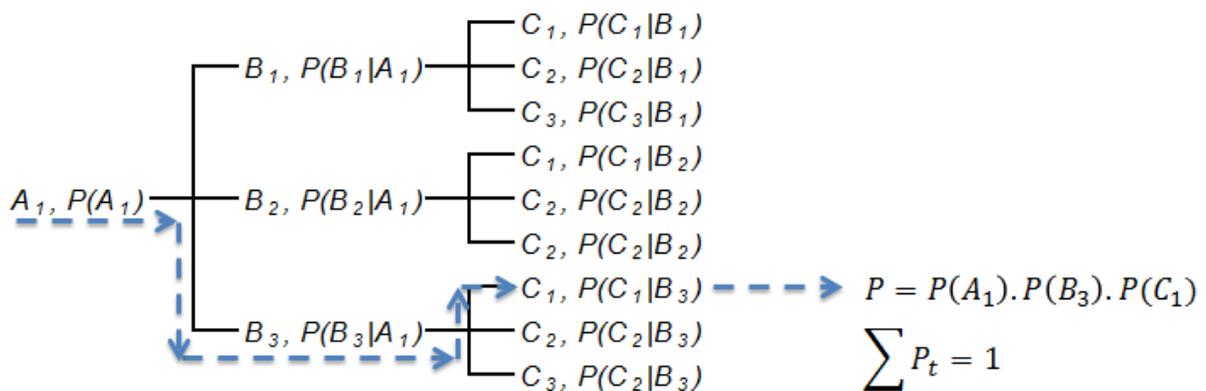


Figura 2.4 – Diagrama esquemático de uma árvore de derivação.

Na técnica de árvore de derivação o número de simulações apresenta um aumento exponencial em relação ao aumento no número de atributos incertos e/ou níveis discretos (Tabela

1), sendo esta a principal limitação desta técnica. Para Loschiavo (1999), apenas os atributos considerados críticos na AS, devem ser considerados na aplicação dessa técnica. Essa limitação pode tornar sua aplicação inviável para um número elevado de atributos incertos e/ou níveis discretos.

O número total de simulações ( $NS$ ) a serem executadas na árvore de derivação pode ser obtido pela Equação 2.4.

$$NS = \prod_{i=1}^N n_i^{A_i} \quad 2.4$$

onde  $N$  é o número de grupos de atributos,  $i$  representa o grupo do atributo,  $n_i$  é a quantidade de níveis incertos e  $A_i$  é a quantidade de atributos do grupo  $i$ . Para um reservatório com dois grupos de atributos incertos, grupo 1 (com 4 atributos e 3 níveis discretos) e grupo 2 (com 3 atributos e 2 níveis discretos) o número total de simulações é  $NS = 3^4 \times 2^3 = 648$ . Para um caso com 8 atributos e 3 níveis o número total de simulações é  $NS = 3^8 = 6561$ .

Tabela 2.1 – Quantidade de modelos em relação à quantidade de atributos e níveis.

Quantidade de Combinações Possíveis		Quantidade de Níveis		
		3	5	7
Quantidade de Atributos	4	81	625	2401
	5	243	3.125	16.807
	6	729	15.625	117.649
	7	2.187	78.125	823.543
	8	6.561	39.0625	5.764.801
	16	43.046.721	152.587.890.625	33.232.930.569.601

### **2.2.2.2 Método de Monte Carlo**

O método de Monte Carlo (*MC*) é bastante utilizado em estudos na área de petróleo, de modo que é fácil encontrar trabalhos e publicações que utilizam esta técnica. Esse método consiste em sorteios aleatórios independentes, a partir de uma distribuição de probabilidades e, portanto, a precisão dos resultados normalmente depende do tamanho da amostra, ou número de sorteios realizados.

Segundo Hammersley e Handscomb (1964), o método de Monte Carlo é a parte da matemática experimental que trata de números aleatórios. Para Mun J. (2006), em sua forma mais simples, o método de Monte Carlo é um gerador de números aleatórios, que é útil para previsão, estimativa e análise de risco.

Em uma aplicação do método de Monte Carlo juntamente com simulação estocástica realiza-se amostragens aleatórias dos atributos incertos considerados, a partir de uma distribuição de probabilidades pré-definida para cada atributo, a fim de compor modelos de simulação (cenários) de forma eficiente. Cada cenário pode ter uma previsão, com uma probabilidade associada. As previsões são eventos (geralmente com fórmulas ou funções) definidos como saídas importantes do modelo.

### **2.2.2.3 Método de Hipercubo Latino**

O uso do método de Hipercubo Latino (*HL*) em trabalhos na área de petróleo tem aumentando recentemente, pois este método é mais preciso para a reprodução das probabilidades de atributos incertos avaliados, quando comparado ao método de Monte Carlo, uma vez que garante que o intervalo de densidade de probabilidades será respeitado com um menor número de sorteios (Vose, 2008).

O conceito de amostragem através da Hipercubo Latino consiste em dividir as distribuições de probabilidades em intervalos e realizar um sorteio aleatório dependente, selecionando valores aleatórios pertencentes a cada um dos intervalos (Maschio *et al.*, 2009). Os valores sorteados dentro de cada intervalo são proporcionais às suas probabilidades, honrando assim a densidade de probabilidade de cada nível. Na Figura 2.5, as barras (vermelha, azul e verde) representam a

quantidade de pontos amostrados, dentro de cada intervalo. Logo, o intervalo com maior probabilidade apresenta também a maior concentração de pontos amostrados.

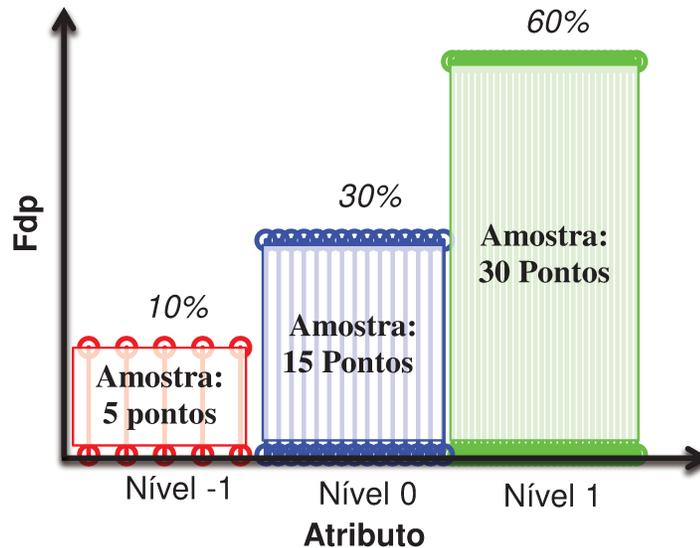


Figura 2.5 – Esquema de sorteio por Hipercubo Latino, dividindo os níveis em intervalos.

A grande vantagem deste método é que são geradas amostras proporcionais à probabilidade de cada intervalo, honrando a distribuição de probabilidades, independente do número de sorteios realizados.

Uma aplicação do método de Hipercubo Latino associado à simulação estocástica permite uma amostragem aleatória dependente dos atributos considerados, resultando em modelos de simulação que melhor representam as probabilidades envolvidas e a composição de cenários com maior representatividade das incertezas que estão sendo tratadas. O método de Hipercubo Latino resulta normalmente em uma convergência mais rápida e precisa ao valor esperado, ou resultado, que o método de Monte Calo, devido à forma com que a amostragem é realizada.

### 2.2.3 Curva de Incertezas

Uma análise de risco trata das possibilidades de perdas, como o custo de perfuração de um poço exploratório seco, ou ganhos, como a descoberta de quantidades comercializáveis de óleo (Harbaugh *et al.*, 1995). Parte destes riscos está associada às incertezas provenientes da fase de caracterização do reservatório e, devem ser minimizados a fim de possibilitar operações e

produções otimizadas, reduzindo perdas ou gastos desnecessários que proporcionem desvantagens financeiras. Os riscos não serão tratados nesse trabalho, apenas as incertezas de reservatórios e o impacto na variabilidade de produção e respectivo afastamento dos dados observados.

Na análise de incertezas, as avaliações e previsões de comportamento não são realizadas a partir da construção de um único modelo; ao invés de um valor determinístico, são utilizados intervalos de valores possíveis para cada atributo (Dijkers, 1985). A partir da combinação dos intervalos de valores possíveis de cada atributo considerado são obtidos diferentes modelos geológicos com uma probabilidade associada, que proporcionam cenários com diferentes resultados. Esses cenários são normalmente avaliados e ordenados segundo a *FO* (definida no problema) de cada modelo de simulação.

Segundo Becerra (2007), o grau de incerteza do sistema e a qualidade do ajuste podem ser medidos a partir da dispersão da *FO* de cada modelo em relação ao valor zero, que representaria o ajuste “perfeito” (quando a curva calculada e observada têm valores iguais). Este tipo de representação é conhecido como curva de incerteza da *FO* (Figura 2.6). O grau de variação é quantificado pela *FO* e respectivas probabilidades de ocorrência dos modelos correspondentes às combinações geradas. A utilização de métodos de redução de incerteza permite obter as novas curvas de incerteza, que podem ser comparadas com as curvas anteriores.

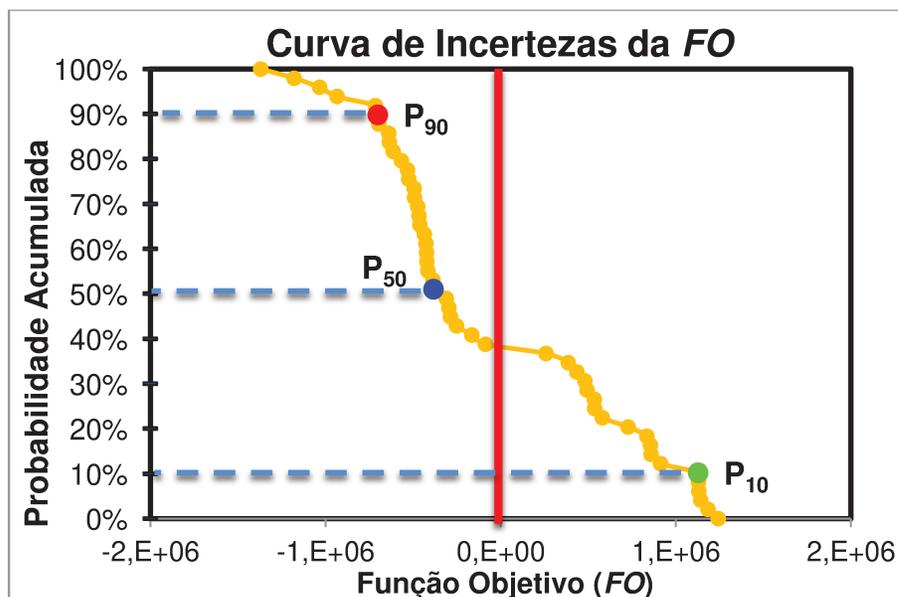


Figura 2.6 – Ilustração de uma curva de incertezas.

A Figura 2.6 ilustra um exemplo de curva de incertezas da *FO* de um caso hipotético, onde a *FO* pode ser qualquer variável de produção do campo com dados observados disponíveis. A curva em vermelho representa o ajuste “perfeito”. Em amarelo está representada a curva de incerteza da *FO* para este caso cada ponto representa um cenário. Através deste tipo de gráfico é possível visualizar a dispersão dos modelos de simulação em relação aos dados observados, para a *FO* adotada. Geralmente, são utilizados três percentis para representar a variabilidade das respostas que podem ser obtidas em um ajuste probabilístico:  $P_{10}$ ,  $P_{50}$  e  $P_{90}$ . A estimativa  $P_n$  significa que existe  $n$  % de probabilidade para que o valor real seja maior ou igual ao valor estimado (Becerra, 2007).



### **3. REVISÃO BIBLIOGRÁFICA**

Neste capítulo, é realizada uma abordagem sobre estudos desenvolvidos para mitigação de incertezas. Destacando-se os estudos que visam a integração das técnicas de ajuste de histórico de produção e análise do grau de incertezas dos reservatórios, de modo a possibilitar a redução dessas incertezas.

Nas últimas décadas, as comunidades científicas têm apresentado interesse crescente nos estudos realizados sob este enfoque. Esse interesse pode ser justificado pela importância de se obter modelos dinâmicos de simulação cada vez mais confiáveis e realistas. Na maioria das vezes, decisões futuras sobre o desenvolvimento do reservatório são apoiadas nesses estudos.

É possível observar que ao longo dos anos muitos trabalhos vêm tentando apresentar métodos viáveis para a redução de incertezas, através da integração entre diferentes técnicas e propondo novos métodos. Nos Itens 3.1, 3.2, 3.3, 3.4 e 3.5 deste capítulo são relacionados os trabalhos utilizados como referência para esse estudo e uma breve análise referente a cada um deles.

#### **3.1 Análise de Incertezas de Reservatórios**

O estudo desenvolvido por Øvreberg *et al.* (1992) é um dos primeiros trabalhos encontrados na literatura baseado no método de análise de incertezas, combinado com outras técnicas de análise probabilística, dos atributos incertos do reservatório nas estimativas de fator de recuperação e previsão de produção utilizando modelos de simulação. O método apresentado inicia com a identificação dos atributos críticos através de uma análise de sensibilidade, que é utilizada para a obtenção do risco de fator de recuperação e potencial de produção através da combinação dos resultados encontrados pela técnica de Monte Carlo. A principal limitação dessa metodologia é a impossibilidade de considerar possíveis não-linearidades dos atributos correlacionados e suas dependências espaciais.

Campozana e Ballin (1998) desenvolveram uma metodologia para estimativa de incerteza na previsão de produção de reservatórios. Neste trabalho, é realizada uma análise de sensibilidades dos atributos incertos com o uso de simulador de fluxo e, posteriormente, a combinação dos resultados utilizando a técnica de árvore de decisão. Esses resultados são normalizados, a fim de se obter as probabilidades do fator de recuperação. O método é finalizado ao gerar uma curva de risco do volume de óleo acumulado, utilizando a técnica de Monte Carlo.

### **3.2 Uso de Métodos Estatísticos para Estimativa de Incertezas e Perfis Probabilísticos**

Loschiavo (1999) apresentou uma metodologia para estimar perfis probabilísticos de desempenho do reservatório. Esse método baseia-se na aplicação da técnica de árvore de decisão, análises probabilísticas e simulação estocástica. Nesse trabalho, é utilizado o conceito de árvore de derivação, onde cada combinação entre os níveis dos diferentes atributos críticos considerados representa um ramo da árvore e resulta em um modelo de simulação completo, com uma probabilidade de ocorrência associada.

Steagall (2001) acrescentou contribuições ao trabalho apresentado por Loschiavo (1999) através de uma metodologia para análise do impacto das incertezas de reservatório nas previsões de produção e análise econômica de um campo de petróleo. Essa metodologia baseia-se na simulação de fluxo de modelos representativos dos cenários possíveis obtidos através do uso da técnica de árvore de decisão. Os modelos de simulação consistem na combinação entre os diferentes níveis dos atributos críticos selecionados na análise de sensibilidade e, para cada atributo crítico, foram definidos os valores representativos das incertezas e suas respectivas probabilidades.

Scheidt e Caers (2008) apresentaram um trabalho para obtenção de modelos representativos das incertezas espaciais, ou perfis probabilísticos ( $P_{10}$ ,  $P_{50}$  e  $P_{90}$ ), a partir de um método que utiliza o conceito de distância (ou semelhança) entre dois cenários geoestatísticos e método de Kernel. Uma vez conhecidas as semelhanças entre os cenários, o espaço de incertezas multidimensional é modelado com técnica de Kernel. A partir do agrupamento de cenários, de acordo com as semelhanças entre suas propriedades, essa ferramenta possibilita a seleção de modelos representativos das incertezas ( $P_{10}$ ,  $P_{50}$  e  $P_{90}$ ). O conceito de distância (ou semelhança)

entre dois modelos geoestatísticos, abordado nesse trabalho, foi introduzido por Arpat (2005) e Suzuki e Caers (2008) e para melhor entendimento deste método a leitura desses trabalhos é recomendada.

De forma semelhante ao trabalho anteriormente citado, Scheidt e Caers (2009) avaliaram a quantificação de incertezas no desempenho de reservatórios, utilizando um método chamado de “Distância e Método de Kernel” (*DKM*, sigla em inglês). Esse método é baseado na distância (ou semelhança) entre os modelos de reservatórios possíveis e classificação em grupos de acordo com essas semelhanças. A partir dessa classificação são selecionados os modelos representativos ( $P_{10}$ ,  $P_{50}$  e  $P_{90}$ ) das incertezas do caso estudado.

### **3.3 Uso de Hipercubo Latino em Estudos na Área de Petróleo**

Xu *et al.* (2005) introduziram o uso do método de Hipercubo Latino (*HL*) em um algoritmo de simulação estocástica. O método de *HL* foi inicialmente comparado com um método de amostragem mais comum, ou métodos mais simples, e posteriormente aplicado na composição dos modelos de simulação. Os resultados mostraram que o método de *HL* realiza uma seleção mais representativa dos atributos em um espaço amostral, do que uma técnica de amostragem simples, principalmente quando o número de simulações é pequeno. Conforme descrito nesse trabalho, o uso de técnicas como método de *MC* é bastante difundida em estudos na área de petróleo, porém essa técnica requer um número elevado de simulações, enquanto o método de *HL* apresenta maior precisão nos resultados para uma amostra menor.

Assim como o trabalho apresentado por Xu *et al.* (2005), Minhas *et al.* (2005) também apresentaram um método baseado no uso de simulações estocásticas e método *HL*. A técnica de *HL* foi aplicada para obter uma quantidade reduzida de modelos de simulação, para realizar previsões de produção e ajudar a identificar os atributos mais influentes na estimativa de *gas-in-situ* (*VGIS*) em campos do Paquistão. Neste trabalho foram identificados o modelo estrutural e o *NTG* (*Net to Gross*) como os parâmetros mais críticos.

Esses dois trabalhos destacam-se também por fazer parte dos primeiros estudos na área de petróleo utilizando o método de Hipercubo Latino.

Queipo *et al.* (2002) e Zerpa *et al.* (2005) usaram o método de Hipercubo Latino para definir um planejamento estatístico, na seleção de variáveis de entrada, combinado com redes neurais.

O trabalho proposto por Risso *et al.* (2009) teve como objetivos principais identificar a melhor maneira de realizar a distribuição dos sorteios, verificar a influência do número de sorteios na curva de risco e a aplicação do método do *HL* na análise de risco de campos de petróleo. Foi realizada também uma comparação entre as técnicas de *HL* e da Árvore de Derivação, a fim de reduzir o número de simulações mantendo a precisão dos resultados. Os resultados mostraram que 200 sorteios foram suficientes para representar o problema, pois não apresentou alteração nos resultados em relação à curva obtida com 9000 sorteios. Finalmente, pode-se concluir que a utilização do método de *HL* é eficaz e eficiente mesmo a partir de um número baixo de sorteios.

O método de Hipercubo Latino foi utilizado por Maschio *et al.* (2010) para selecionar os modelos de simulação que compõem as curvas de incertezas, obtidas ao final da aplicação do método apresentado. O método de Monte Carlo também foi utilizado nesse trabalho para realizar a amostragem e a combinação estatística dos atributos incertos, a fim de compor diferentes modelos de simulação. A metodologia apresentada por Maschio *et al.* é uma das principais referências para o desenvolvimento deste trabalho e será melhor abordada no Item 3.5 deste capítulo.

Nos últimos anos a utilização da técnica de *HL*, em estudos na área de petróleo, apresentou um aumento considerável. Muitos desses estudos vêm apresentando novas linhas de pesquisa, proporcionando métodos mais rápidos e precisos para obtenção de resultados mais confiáveis, como redução no número de simulações e melhor representatividade de perfis probabilísticos, quando comparado a técnicas bastante utilizadas (como a técnica de árvore de derivação e o método de Monte Carlo).

### **3.4 Integração entre técnicas de análise de incertezas e ajuste de histórico**

Almeida Netto (2003) propõe uma metodologia para avaliação e redução de incertezas, a partir da integração entre as técnicas de ajustes de histórico de produção e análise de incertezas,

utilizando a simulação numérica de fluxo. Os cenários de previsão de produção e suas respectivas avaliações econômicas somente são considerados a partir dos casos que apresentam ajustes, ou concordância, com as curvas de vazão e comportamento de pressão observados. O autor recomenda que deve ser observado o ajuste de todos os parâmetros de produção do campo (produção de fluidos e pressão da formação, por exemplo) e de cada poço.

Landa e Guayaguler (2003) apresentaram um método onde coeficientes de sensibilidade são usados para construir uma superfície de resposta, meta-modelo (ou *proxy*), para o simulador, honrando o valor dos dados e dos gradientes, para os parâmetros das combinações simuladas. Esse meta-modelo é usado para guiar as localizações posteriores de amostras para o processo de ajuste de histórico. A precisão da superfície de resposta aumenta com simulações adicionais e com o progresso do algoritmo. O meta-modelo obtido ao final do método de ajuste de histórico é então utilizado para estimar as incertezas associadas com as previsões de desempenho de um modelo de simulação.

Zabalza-Mezghani *et al.* (2004) e Fetel e Caumon (2008) apresentaram várias opções para gerenciamento de incertezas baseadas em técnicas de planejamento estatístico e meta-modelos combinadas com o uso de geoestatística. O método consiste em obter um ajuste de histórico probabilístico equivalente à aproximação estocástica, e então, realizar uma extrapolação para previsão sob incertezas.

No trabalho apresentado por Schiozer *et al.* (2005), é proposto um procedimento de ajuste de histórico que se inicia com análise de sensibilidade dinâmica, seguido de uma avaliação de incertezas dos atributos críticos do reservatório, identificados na AS, onde são gerados vários modelos de simulação. Os modelos que não honram o comportamento do reservatório, no período de histórico, são descartados nesta etapa. São apresentadas como vantagens dessa metodologia uma calibração mais rápida, resultados mais confiáveis e a incorporação das incertezas na predição de produção. Outro fator importante é que o método proposto pode ser útil nos primeiros anos de produção de um campo, onde as incertezas são significativamente maiores e o procedimento tradicional de ajuste de histórico não é suficiente, ou é incapaz de apresentar resultados eficientes. Esse procedimento é justificável pela não garantia de previsões confiáveis a partir de um modelo único.

Manceau *et al.* (2001) apresentaram um método para gerenciamento de incertezas durante o ajuste de histórico, a previsão de produção e a otimização da estratégia de produção. A quantificação de incertezas (dados petrofísicos, atuação de aquíferos, locação de poços) foi realizada a partir da combinação entre as técnicas de planejamento estatístico e a utilização de meta-modelos. Nesse trabalho foi utilizado o método Joint Modeling (*JMM*, em inglês), técnica baseada na quantificação de incertezas geoestatísticas e planejamento estatístico. Ao final desse trabalho foi concluído que a utilização de planejamento de experimento com o *JMM* é uma metodologia apropriada para ser usada em tomada de decisões em ambiente propício ao risco, incluindo todos os tipos de incertezas.

O *JMM* também foi utilizada por Feraille *et al.* (2003) para quantificar o impacto das incertezas na previsão de produção de um campo real. Esse trabalho manipula parâmetros de produção, dentro de uma determinada faixa de valores, com o objetivo de minimizar as incertezas, devido à existência de várias soluções de ajuste de histórico. Esse trabalho foi validado através da 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. Os resultados indicam que as incertezas na previsão são reduzidas em 75% quando são considerados os modelos ajustados, em relação aos modelos não submetidos ao ajuste de histórico.

Nicotra *et al.* (2005) implementaram nesse trabalho um algoritmo da vizinhança (*Neighbourhood Algorithm*). Esse algoritmo foi desenvolvido para solução de problemas de inversão em sismologia de terremoto, em ajuste de histórico e avaliação de incertezas de um reservatório real. Neste trabalho, foram gerados múltiplos cenários para ajuste de histórico para um campo marítimo, com três anos de dados de histórico de produção, a partir de uma aplicação prática dessa metodologia. Destaca-se como resultado dessa metodologia a redução do tempo e esforço humano para se obter um ajuste de histórico de alta qualidade.

Litvak *et al.* (2005) também utilizam o algoritmo de vizinhança (*Neighbourhood Algorithm*). A metodologia apresentada neste trabalho consiste na estimativa de incertezas nos perfis de produção através dos dados de produção e de sísmica. O algoritmo da vizinhança foi utilizado para selecionar valores de parâmetros de ajuste de histórico em cada simulação. Essa

metodologia tem sido aplicada com bastante sucesso em vários reservatórios do Golfo do México.

Williams *et al.* (2004) apresentaram uma nova abordagem, que incorpora incertezas do reservatório na construção do modelo e na previsão de desempenho de produção. Essa metodologia é denominada *Top-Down Reservoir Modelling (TDRM)*. O método *TDRM* usa um algoritmo genético para ajuste de histórico assistido por ser considerado o otimizador mais robusto para encontrar soluções alternativas. Essa metodologia tem sido aplicada com sucesso em diferentes reservatórios em estudo (tanto de óleo, quanto de gás) e em diferentes fases da “vida” de um reservatório, desde a fase de avaliação até a fase de declínio.

Gu e Oliver (2004) aplicaram com sucesso o método de filtro de Kalman estendido para o ajuste de histórico automático permitindo, ao mesmo tempo, a determinação e a redução da incerteza no desempenho futuro de reservatório. O filtro de Kalman apresenta-se como uma solução prática para o problema do tempo relacionado ao esforço computacional e à frequência de amostragem de dados de reservatório cada vez maior. Esse 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. A inédita técnica é aplicada sobre o caso de estudo PUNQ.

Ma *et al.* (2006) aplicaram, pela primeira vez, uma quantificação da incerteza num ajuste de histórico usando um método de duas etapas. Esse método foi baseado na aproximação mediante linearização rápida dos dados dinâmicos e no uso do algoritmo de Markov Chain Monte Carlo (*MCMC*). Na primeira fase (ou estágio) são utilizadas as sensibilidades, obtidas através de simulações por linhas de fluxo, para obter a aproximação analítica de vizinhança dos dados dinâmicos previamente computados. Essa aproximação é usada para modificar uma nova proposta de distribuição de parâmetros durante a aplicação do *MCMC*. Na segunda fase, a partir das propostas sugeridas na primeira fase, as simulações de fluxo são realizadas para garantir o rigor de cálculo na amostragem posterior. Este método de duas etapas aumenta a taxa de aceitação e reduz o custo computacional, comparado com o método de amostragem *MCMC* convencional, sem perda de precisão.

No trabalho apresentado por Hegstad e Omre (2001), a metodologia proposta avalia as contribuições de observações de poços, dados de amplitude sísmica e dados de histórico de

produção na redução de incertezas na previsão de comportamento de reservatório. O condicionamento para o histórico de produção constitui um desafio maior, devido a não-linearidade do modelo de fluxo.

Alvarado (2003) propõe um método para quantificar incertezas, que utiliza um conjunto de simulações de ajuste de histórico e determina a função de densidade de probabilidade da produção futura de óleo, enquanto o ajuste de histórico está sendo desenvolvido. Para esse estudo foi utilizado apenas o comportamento dinâmico do reservatório.

A metodologia proposta por Alvarado *et al.* (2005) desenvolve-se com o foco na geração de previsões de produção preliminares no início do estudo do reservatório e o cálculo da incerteza associada a partir das previsões obtidas. O processo é completado quando se utiliza o grau de ajuste, obtido para cada cenário, ou cada execução do método de ajuste de histórico, para os cálculos dos pesos correspondentes a cada previsão. Essa metodologia foi aplicada com sucesso no estudo de um reservatório complexo no Golfo do México. É possível observar que à medida que a precisão do modelo aumenta, durante o ajuste de histórico, as incertezas nas previsões diminuem.

Os trabalhos relatados neste Item 3.4 apresentam como característica comum a combinação entre diferentes técnicas de integração entre a análise de incertezas e a técnica de ajuste de histórico de produção. Esses métodos atingiram o objetivo do estudo, contudo, alguns deles têm uma aplicação bastante complexa, demandam muito tempo na modelagem do problema, requerem um elevado esforço computacional e análise de grande volume de dados e tempo de análise.

A linha de pesquisa escolhida como referência para esse estudo apresenta como grande vantagem uma metodologia de obtenção de um ajuste probabilístico com boa representatividade das incertezas envolvidas no caso em estudo. Pode-se destacar ainda que os avanços recentes indicam a possibilidade de trabalhar com uma quantidade elevada de atributos incertos e níveis discretos, sem que haja um aumento expressivo no número de simulações.

### 3.5 Linha de Pesquisa de Referência

Maschio *et al.* (2005) e Moura Filho (2006) apresentaram uma metodologia que possibilita a integração entre a técnica de ajuste de histórico e análise de incertezas, baseada na técnica da árvore de derivação. Esta metodologia consiste na combinação entre todos os níveis incertos de cada atributo, de modo a reproduzir todas as combinações possíveis entre esses níveis, e cada combinação resulta em um modelo de simulação com uma probabilidade associada. A partir de um procedimento baseado na *FO* de cada modelo, novas probabilidades são estimadas para cada cenário. Essas metodologias foram aplicadas a casos teóricos simples.

Becerra (2007) e Maschio *et al.* (2009) apresentaram contribuições à metodologia apresentada por Maschio *et al.* (2005) e Moura Filho (2006), a partir da aplicação em casos mais complexos. Becerra (2007) apresentou uma aplicação desta técnica também para atributos com influências global e regional/local, contudo de maneira bastante complexa.

Os métodos apresentados por Maschio *et al.* (2005), Moura Filho (2006), Becerra (2007) e Maschio *et al.* (2009) tornam-se inviáveis para quantidades elevadas de atributos incertos e/ou níveis discretos, uma vez que se baseiam no uso da técnica de árvore de derivação, que apresenta um aumento exponencial no número de simulações em relação ao aumento dos atributos incertos e/ou níveis avaliados, conforme apresentado Tabela 2.1 do Capítulo 2.

Maschio *et al.* (2010) apresentaram uma nova metodologia no processo de mitigação de incertezas, uma alternativa à técnica de árvore de derivação, a partir do uso de técnicas de amostragem e um processo de redistribuição de probabilidades por nível. O método de Monte Carlo é utilizado para realizar amostragens, dos níveis dos atributos considerados e combiná-los aleatoriamente (Figura 3.1 e Figura 3.2), cada combinação entre os níveis dos diferentes atributos resulta em modelos de simulação. Em seguida, os modelos são simulados e, através de procedimentos baseados na *FO* de cada modelo, novas probabilidades são estimadas.

O método de Hipercubo Latino (*HL*) foi utilizado nesse trabalho apenas para compor as curvas de incertezas. Esta metodologia tem como grande vantagem a redução do número de simulações, pois não é necessário realizar todas as combinações possíveis entre os níveis dos atributos considerados para a estimativa de novas probabilidades e consequentemente a redução das incertezas.

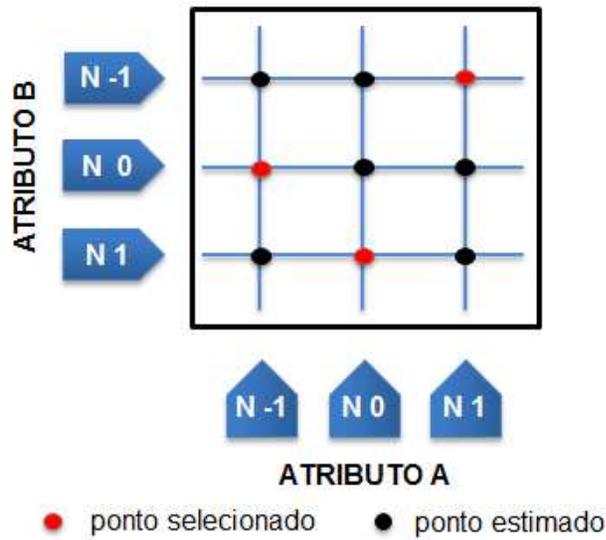


Figura 3.1 – Ilustração da composição de modelos de simulação com 2 atributos incertos discretizados em 3 níveis cada.

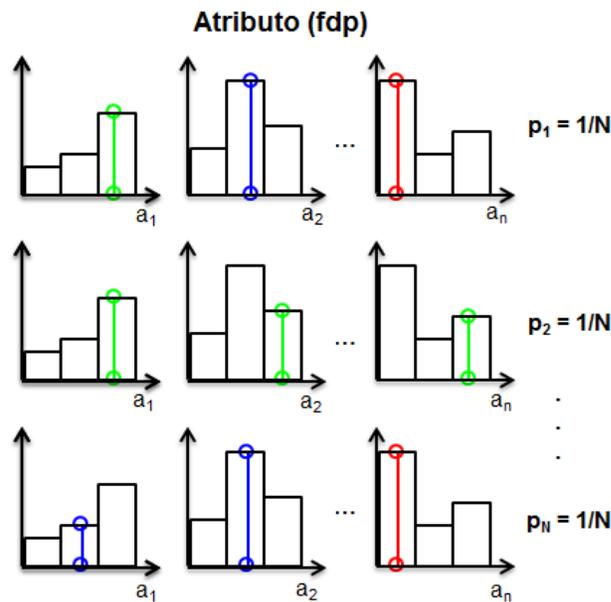


Figura 3.2 – Esquemático da seleção dos atributos por nível.

Na Figura 3.1 é possível observar a amostragem e combinação aleatória dos níveis de dois atributos. No exemplo da Figura 3.2 também são considerados 3 níveis discretos, o Nível -1 (vermelho), Nível 0 (azul) e Nível 1 (verde), indicados na figura pelas suas respectivas cores cada vez que o nível foi amostrado.

A partir desta metodologia apresentada por Maschio *et al.* (2010), a quantidade de combinações possíveis deixa de ser um fator limitante da técnica de mitigação de incertezas. A possibilidade de trabalhar com uma quantidade maior de atributos e níveis discretos torna-se possível, uma vez que não é necessário avaliar todos os cenários para se obter bons resultados.

### 3.5.1 Função Objetivo de Referência

A função objetivo é definida de acordo com as características de cada problema, no trabalho apresentado por Maschio *et al.* (2010), a definição da *FO* segue a ordem indicada a seguir e, consiste basicamente na diferença entre os dados observados e simulados (Equação 3.1).

$$D = \sum_{i=1}^N (d_i^{obs} - d_i^{sim}) \quad 3.1$$

onde  $i$  indica o dado analisado,  $N$  a quantidade total de dados,  $d_i^{obs}$  representam os dados observados da propriedade ajustada e  $d_i^{sim}$  os dados simulados da mesma propriedade ajustada. Esses termos também são utilizados na Equação 3.2, a qual representa o afastamento quadrático entre os dados observados e os dados simulados.

$$E = \sum_{i=1}^N (d_i^{obs} - d_i^{sim})^2 \quad 3.2$$

Na Equação 3.3 o termo  $D/|D|$  define o sinal do afastamento, de modo a representar se os dados simulados são maiores ou menores que os dados observados. Valores negativos significam que a curva que representa os dados simulados está acima (ou predominantemente acima) do histórico, e vice versa (Figura 3.3).

$$E_s = \frac{D}{|D|} \cdot E \quad 3.3$$

O erro médio absoluto é obtido pela Equação 3.4, onde  $j$  representa o dado analisado,  $p$  a quantidade total de dados, o termo  $S$  dessa equação representa a quantidade de fonte de dados (ex.: quantidade de poços produtores).

$$\bar{E} = \frac{1}{S} \sum_{j=1}^p (|E_s|)_j \quad 3.4$$

Finalmente, a função objetivo utilizada por Maschio *et al.* (2010) é representada pela Equação 3.5, basicamente a soma do afastamento quadrático dos poços com sinal.

$$FO = \frac{\bar{E}_s}{|\bar{E}_s|} \cdot |\bar{E}| \quad 3.5$$

onde,

$$\bar{E}_s = \frac{1}{S} \sum_{j=1}^p (E_s)_j \quad 3.6$$

O termo  $\bar{E}_s/|\bar{E}_s|$  da Equação 3.5 também é usado para definir o sinal do afastamento médio, assim os dados simulados são identificados como maiores ou menores que os dados observados.

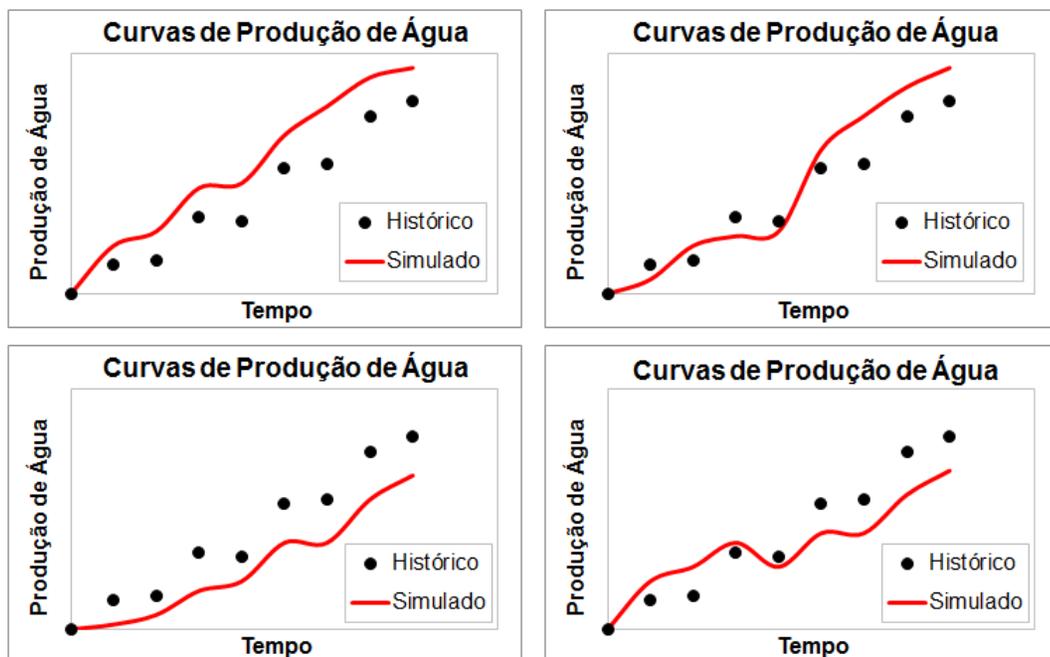


Figura 3.3 – Posição das Curvas de Produção em Relação aos Dados Observados.

### 3.5.2 Estimativa de novas probabilidades

Para a estimativa das novas probabilidades é necessário obter o erro médio de cada nível discreto de cada atributo considerado. Esse erro é calculado a partir da Equação 3.7,

$$R_n^e = \frac{M_n}{p} \sum_{j=1}^p (E^{-F})_j \quad 3.7$$

onde  $R_n^e$  é a estimativa do erro médio de cada nível,  $M_n$  é o número de modelos correspondente ao nível  $n$  (Equação 3.8),  $p$  é o número de modelos selecionados para cada nível  $n$  e  $F$  é um fator que representa o peso atribuído a cada nível (de modo a dar maior importância aos modelos mais próximos do histórico) e,

$$Mn = n^{A-1} \quad 3.8$$

Na Equação 3.8,  $n$  representada a quantidade de níveis e  $A$  a quantidade de atributos considerados para a quantidade de níveis  $n$ .

No estudo apresentado por Maschio *et al.* (2010), foi realizada uma análise cuidadosa para definir o valor do fator  $F$ , para o caso mais simples foi utilizado o valor de 2.5 e para o caso mais complexo 3, para melhor entendimento desse estudo é indicada a leitura da literatura citada.

Por fim, as probabilidades de cada nível são estimadas pela Equação 3.9. A probabilidade de cada nível é totalmente modificada a partir da primeira amostra selecionada, independente do tamanho da amostra.

$$P_n = R_n^e / \sum_{n=1}^k R_n^e \quad 3.9$$

onde  $P_n$  representa a probabilidade calculada para cada nível em relação aos modelos selecionados.

De modo geral, os níveis cujos afastamentos apresentam menor dispersão em relação aos dados observados (ponto zero na Figura 3.4), após a aplicação da Equação 3.7 onde são estimados o inverso do erro médio de cada nível, a partir dos erros de cada modelo, têm seus

valores aumentados possibilitando a estimativa de novas probabilidades para cada nível (Figura 3.5).

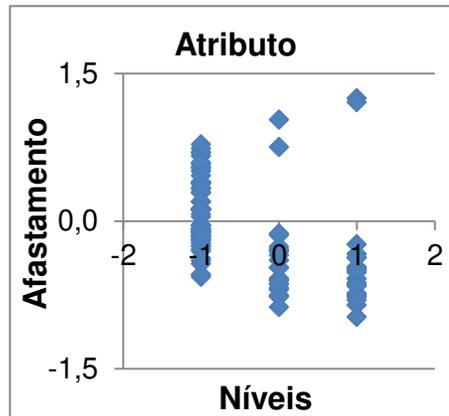


Figura 3.4 – Mapa de dispersão do erro médio (afastamento quadrático) por nível.

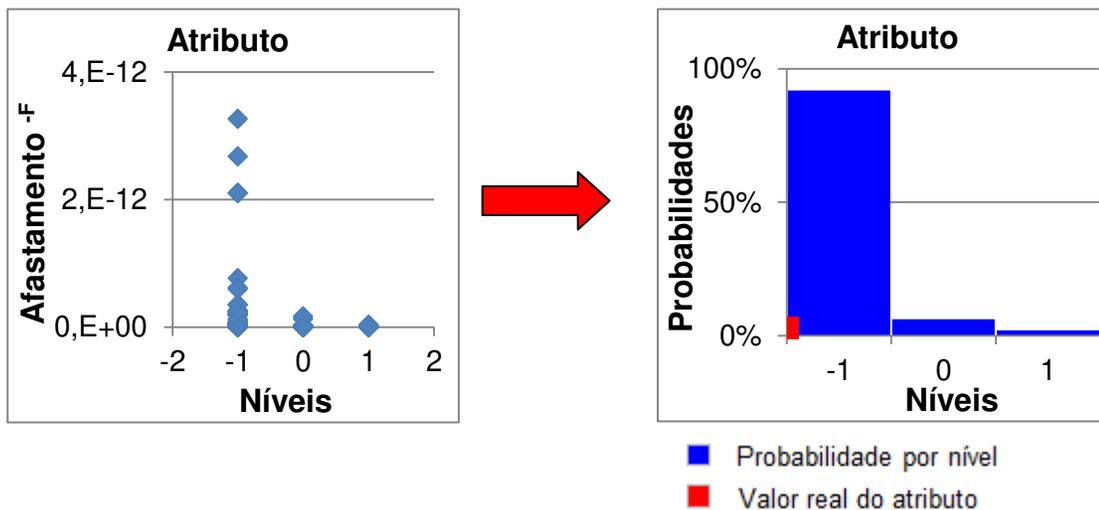


Figura 3.5 – Ilustração de dispersão do inverso do erro médio por nível (elevado ao fator peso) e as probabilidades finais do atributo.

Na metodologia apresentada por Maschio *et al.* (2010), a qualidade do resultado obtido pode ser avaliada através de uma análise da curva de incertezas, do ajuste das curvas de produção e, para os casos teóricos de resposta conhecida, do aumento das probabilidades dos níveis que mais se aproximam dos valores reais do atributo.

Com os trabalhos citados neste capítulo, é possível destacar o crescente volume de estudos recentes que buscam por processos de redução de incertezas cada vez mais precisos e confiáveis.

Esses trabalhos apresentaram importantes avanços em relação à confiabilidade dos resultados e desenvolvimento de métodos alternativos (ou diferentes) para redução de incertezas. Contudo, esses avanços muitas vezes vêm acompanhados de métodos complexos e que necessitam de elevado esforço (computacional e humano).

Nos trabalhos, de referência, apresentados por Maschio *et al.* (2005), Moura Filho (2006), Becerra (2007) e Maschio *et al.* (2010) os avanços apresentados são evidentes. A quantidade de cenários possíveis deixa de ser um fator limitante desse método e a possibilidade de estimar novas probabilidades a partir de um número reduzido de simulações (quando comparado ao uso da árvore de derivação) é um desses avanços. Entretanto, a possibilidade de melhoria deve ser considerada; segundo os próprios autores, há a necessidade de se estabelecer um critério para definir a quantidade de cenários amostrados, avaliar outras técnicas de amostragem, criar indicadores de qualidade e confiabilidade dos resultados, e revisar o procedimento de estimativa de novas probabilidades.



## 4. METODOLOGIA

Este capítulo consiste na apresentação da proposta do trabalho, com detalhes do seu funcionamento, justificativa das modificações propostas em relação à principal metodologia de referência, implementação de novas fórmulas e critérios para a análise e quantificação da qualidade dos resultados. O Item 4.1 apresenta a metodologia geral do trabalho, o Item 4.2 características comum com o método de referência e no Item 4.3 a metodologia proposta.

### 4.1 Metodologia Geral

A proposta deste trabalho é apresentar contribuições à metodologia de mitigação de incertezas desenvolvida inicialmente por Moura Filho (2006), aprimorada por Becerra (2007) e mais recentemente por Maschio *et al.* (2010), sendo esse último a principal referência para o desenvolvimento desse estudo.

Através de algumas modificações no método apresentado por Maschio *et al.* (2010), esta metodologia visa proporcionar maior consistência nos resultados obtidos a partir da técnica de redução de incertezas, utilizando técnicas de amostragem, de modo a avaliar novas possibilidades para obter redução na faixa de incertezas a partir de um melhor ajuste global (da *FO*) e local.

As principais contribuições apresentadas pela metodologia descrita neste trabalho são:

- Utilização do método de Hipercubo Latino para realizar as amostragens;
- Criação de um indicador para definir a quantidade de modelos amostrados, a partir da variabilidade das probabilidades estimadas, que servem também como critério de parada deste método;
- Criação de um indicador que representa a qualidade e confiabilidade dos resultados, através do ajuste (ou afastamento) de cada poço; e
- Avaliação do método proposto para casos com diferentes níveis de discretização (3, 5 e 7).

## 4.2 Características comuns com o método de referência

As características comuns entre a metodologia deste trabalho e a metodologia apresentada por Maschio *et al.* (2010) podem ser observadas na Figura 4.1 que ilustra, passo a passo, a metodologia geral de mitigação de incertezas utilizando técnicas de amostragem. O processo tem início após o recebimento os dados de parametrização (atributos, discretização e modelo base) fornecidos pela equipe responsável pela caracterização do reservatório.

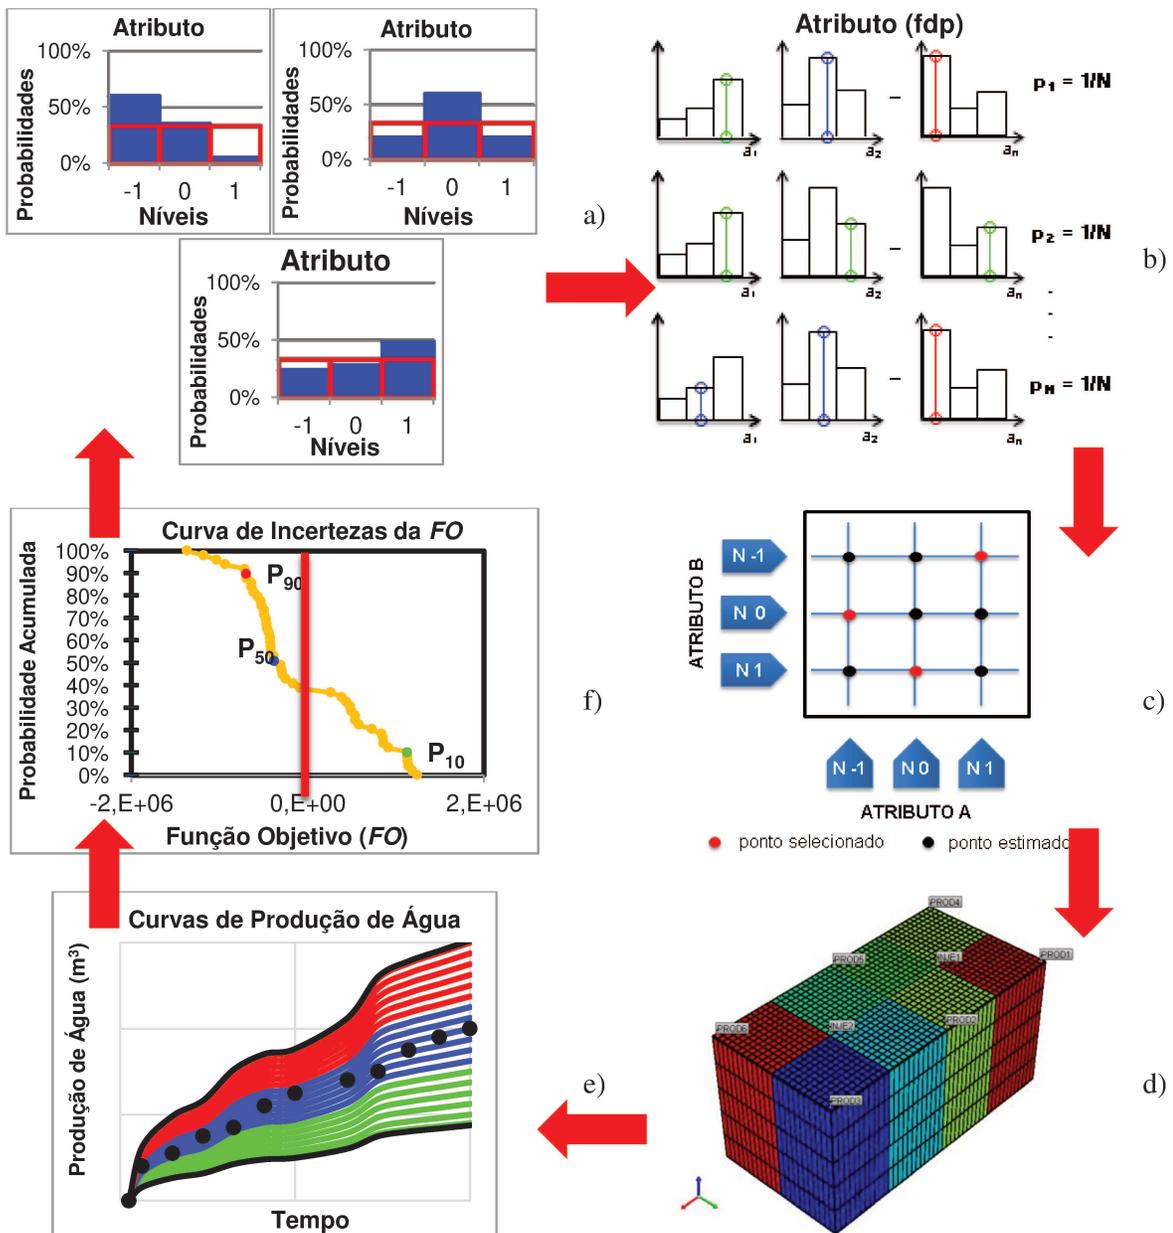


Figura 4.1 – Ilustração do fluxograma simplificado das características comuns.

Os passos apresentados na Figura 4.1 são:

- a) O método inicia com os atributos e suas respectivas probabilidades iniciais;
- b) Em seguida cada nível discreto, dos atributos incertos considerados, é selecionado através de um método de amostragem;
- c) Os níveis selecionados são combinados aleatoriamente;
- d) A combinação entre os diferentes níveis de cada atributo resulta em diferentes modelos de simulação dos diferentes cenários;
- e) Os modelos são submetidos ao simulador e posteriormente a *FO* é calculada;
- f) A partir de um procedimento baseado na *FO* de cada cenário, novas probabilidades são estimadas para cada nível.

O processo é iterativo e termina quando o critério de parada tenha sido atingido.

### 4.3 Metodologia Proposta

A metodologia proposta nesse trabalho consiste na redistribuição de probabilidades por níveis discretos, dos atributos incertos, considerados para cada caso, onde cada nova probabilidade é estimada a partir de um processo baseado na *FO* (obtida pela Equação 3.5) de cada modelo de simulação. Uma das principais contribuições deste trabalho é a utilização do método de Hipercubo Latino (*HL*) como técnica de amostragem, para composição dos modelos de simulação, através da seleção e combinação aleatória dos níveis discretos dos atributos, baseados em suas respectivas probabilidades. Esse método de amostragem foi implementado com a finalidade de substituir o método de Monte Carlo (*MC*), utilizado por Maschio *et al.* (2010), para executar a mesma tarefa.

No processo de mitigação de incertezas apresentado nesta metodologia, as novas probabilidades são estimadas utilizando as equações e métodos apresentados por Maschio *et al.* (2010), seguido da aplicação da Equações 4.1 (índice de proporcionalidade) e Equação 4.2 (nova probabilidade), criadas e implementadas como contribuição deste trabalho, e serão apresentadas mais adiante. Na nova abordagem, é estabelecida uma quantidade mínima de modelos que devem ser amostrados. Essa quantidade mínima é usada como referência na estimativa das novas probabilidades, onde as probabilidades iniciais são modificadas de forma gradativa e

proporcional à quantidade mínima de modelos definida no início do processo. Ao atingir a quantidade mínima de modelos estabelecida, as novas probabilidades são estimadas modificando totalmente as probabilidades anteriores.

O processo recomeça até que o critério de parada, estabelecido para a aplicação da metodologia, tenha sido atingido. Para este trabalho, foram considerados os seguintes itens no critério de parada: estabilidade das probabilidades (baixa variação nas probabilidades estimadas, em relação às anteriores); análise da distribuição de probabilidade (verificação da existência de curvas com formas estranhas e não estabilizadas); e redução na faixa de incertezas (na dispersão da *FO* dos modelos representativos das probabilidades finais, em relação à dispersão inicial).

A Figura 4.2 apresenta o fluxograma geral da metodologia proposta, onde é possível observar as principais características desta metodologia.

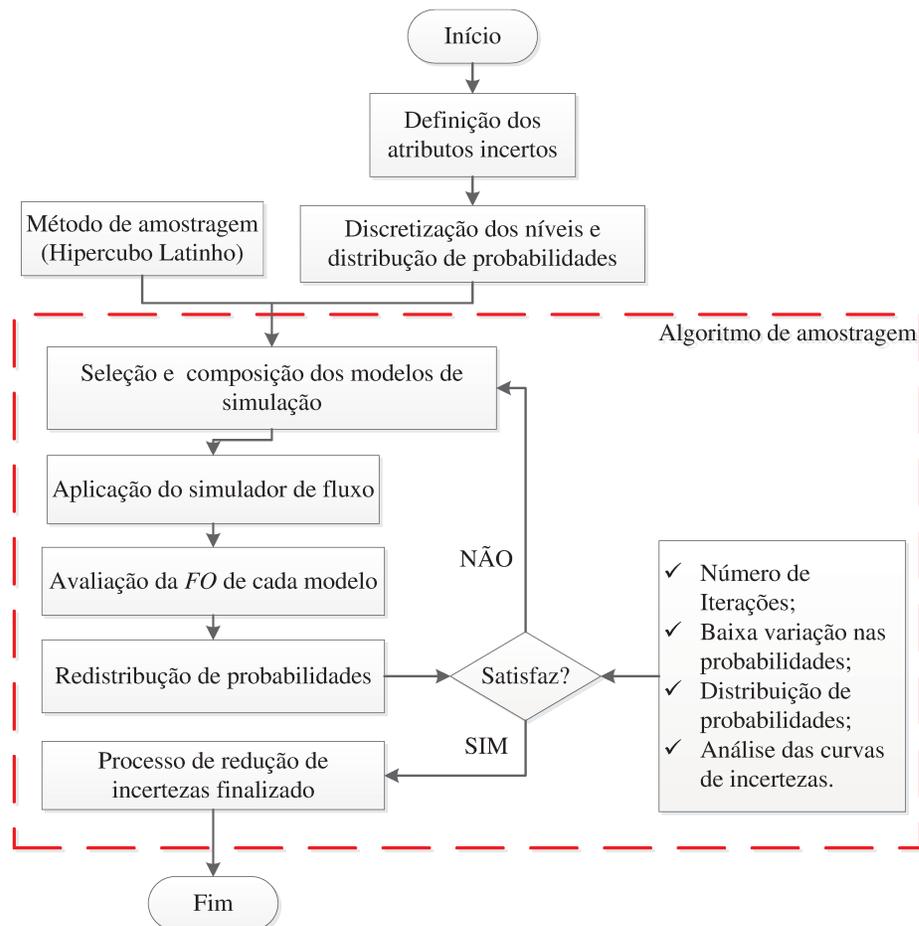


Figura 4.2 – Fluxograma da metodologia proposta.

No fluxograma apresentado a definição dos atributos incertos e discretização (fora do retângulo em linhas pontilhada) devem ser realizadas pela equipe responsável pela caracterização do reservatório; os demais itens são realizados a partir desta metodologia. As principais diferenças deste fluxograma para o esquema apresentado por Maschio *et al.* (2010) é a modificação do método de amostragem, de *MC* para *HL*; e os critérios de parada do processo.

Para tornar essa metodologia viável, seus procedimentos e funcionalidades foram modelados em um algoritmo, denominado algoritmo de amostragem (Item 4.3.1). Nesse algoritmo além das amostragens dos atributos, são realizadas as composições dos modelos de simulação, cálculo da *FO* de cada modelo avaliado, estimativa do erro médio por nível, estimativa das novas probabilidades, medição da variabilidade das probabilidades e composição das curvas de incertezas.

#### **4.3.1 Algoritmo de Amostragem**

O algoritmo de amostragem, desenvolvido para o processo de redistribuição de probabilidade, tem por objetivo realizar os cálculos deste processo de forma confiável. Baseado nas formulações matemáticas apresentadas e aplicação do método de amostragem definido, o algoritmo permite uma redução na faixa de incertezas de forma automatizada, fornecendo os melhores ajustes locais e, conseqüentemente, um melhor ajuste global sem utilizar todas as combinações necessárias à técnica de árvore de derivação. A *FO* definida para esse trabalho consiste basicamente na soma dos afastamentos quadráticos de todos os poços.

Este algoritmo consiste na estimativa de novas probabilidades (Item 4.3.1.1) para os níveis dos atributos incertos em estudo, a partir da realização da amostragem e combinação aleatória dos níveis discretos dos atributos incertos, com o método de Hipercubo Latino (*HL*), e um procedimento para a estimativa das novas probabilidades utilizando a *FO* de cada modelo e a quantidade de modelos amostrados.

A Figura 4.3 ilustra o fluxograma do algoritmo. Esses critérios foram avaliados e testados ao longo da estruturação e aplicação dessa metodologia.

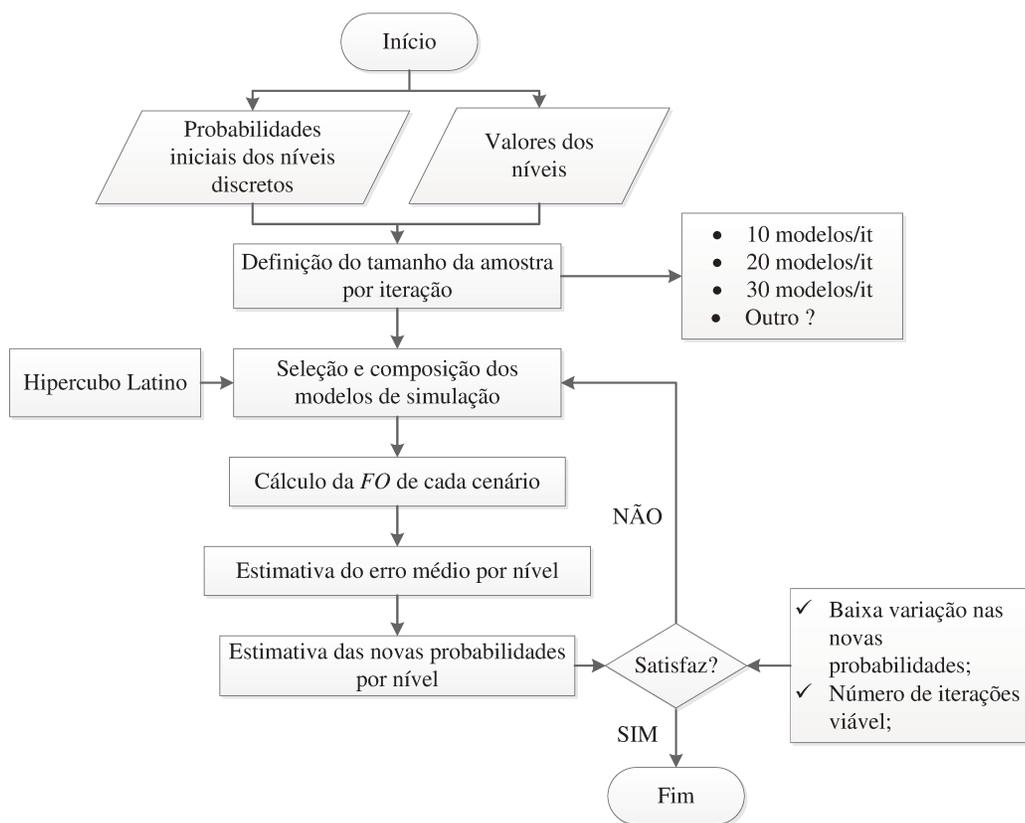


Figura 4.3 – Fluxograma do algoritmo de amostragem.

No fluxograma apresentado na Figura 4.3 é possível observar que as probabilidades iniciais e os valores dos níveis discretos, de cada atributo, são dados de entrada do algoritmo e devem ser declarados antes de iniciar a aplicação; é necessário definir também a quantidade de modelos que devem ser amostrados por iteração. O termo iteração é utilizado neste trabalho para representar a repetitividade do procedimento de amostragem, a cada iteração podem ser selecionados um ou mais modelos de simulação, conforme for estabelecido para aplicação da metodologia.

#### 4.3.1.1 Estimativa de Novas Probabilidades

Nesta metodologia a estimativa das novas probabilidades consiste na aplicação das formulações e métodos apresentados por Maschio *et al.* (2010) acrescidas de duas novas equações, que proporcionam uma redistribuição gradativa de probabilidades para cada nível discreto (Equação 4.1 e Equação 4.2).

A estimativa de novas probabilidades, para cada nível, em relação à quantidade de modelos amostrados ( $P_n$ ) segue o procedimento descrito na metodologia de Maschio *et al.* (2010) até a aplicação da Equação 3.9. Após esse procedimento, foram inseridas duas etapas: a estimativa do índice de proporcionalidade da probabilidade (Equação 4.1) e o cálculo das novas probabilidades proporcional à quantidade de modelos sorteados (Equação 4.2), modificando as probabilidades iniciais, em relação à quantidade mínima definida.

$$I_p = \left[ \left( 1 - \frac{Ma}{Ma_{min}} \right) \cdot (1 - P_n/P_{nini}) \right] + P_n/P_{nini} \quad 4.1$$

O índice de proporcionalidade da probabilidade limita a modificação das probabilidades iniciais, a partir da relação entre a quantidade acumulada de modelos amostrados ( $Ma$ ) e a quantidade mínima de modelos ( $Ma_{min}$ ) que devem ser amostrados, para permitir uma modificação total nas probabilidades de cada nível. Conforme descrito anteriormente, ao atingir a quantidade mínima de modelos estabelecida a relação entre ( $Ma/Ma_{min}$ ) assume o valor equivalente à unidade (1), permitindo que as probabilidades iniciais sejam totalmente modificadas.

Finalmente, as novas probabilidades, proporcionais às quantidades de modelos amostrados, são obtidas pela Equação 4.2.

$$P_{nMa} = P_{nini} \cdot I_p \quad 4.2$$

Neste caso,  $P_{nini}$  representa a probabilidade inicial de cada nível e  $P_{nMa}$  a nova probabilidade estimada para cada nível, em relação à quantidade de modelos amostrados.

A ideia de inserir novas equações tem como principal motivação evitar a eliminação precoce de níveis discretos a partir de uma amostra muito pequena. Na metodologia de Maschio *et al.* (2010) foi observado que as probabilidades iniciais podem, em alguns casos, ser totalmente modificadas a partir da primeira amostragem, não sendo mais consideradas para os sorteios seguintes. Tal efeito pode levar a uma redução brusca nas probabilidades de alguns níveis, ou até mesmo a eliminação desses níveis, a partir de uma amostra muito pequena de modelos, conforme ilustrado na Figura 4.4.

O efeito descrito se agrava ainda mais com a implementação do método de *HL*, uma vez que esse método honra a densidade de probabilidade de cada nível. Em uma amostra muito pequena a combinação entre os diferentes níveis, de diferentes atributos, pode resultar em uma *FO* muito grande (quanto maior a *FO*, menor as probabilidades estimadas) e conseqüentemente uma redução brusca na probabilidade dos níveis que participam desse modelo, podendo chegar à zero já no(s) primeiro(s) sorteio(s), e esses níveis não serem mais amostrados.

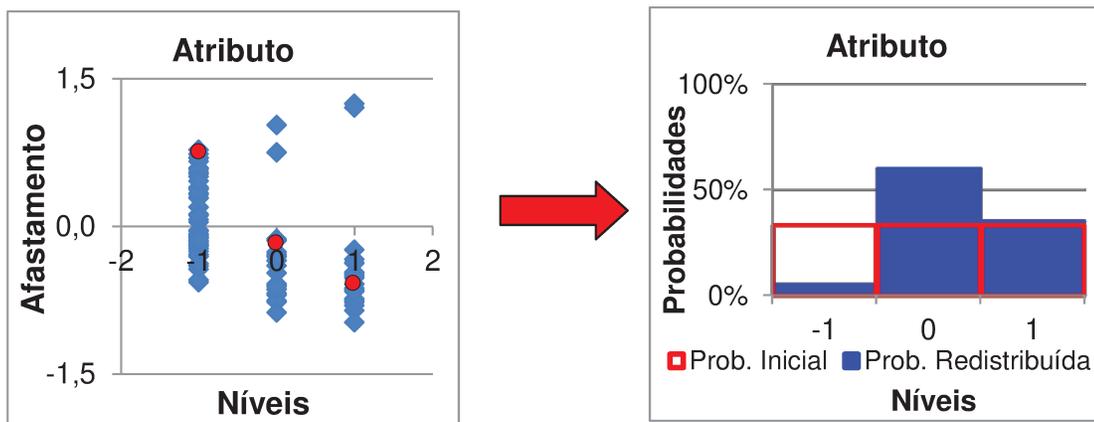


Figura 4.4 – Ilustração da eliminação precoce de um nível, a partir de uma amostra muito pequena, sem as equações de redistribuição gradativa.

Na Figura 4.4, é possível observar a ilustração de um caso hipotético, onde as probabilidades dos níveis do atributo são totalmente modificadas, a partir da amostragem de uma quantidade muito pequena de pontos (círculos vermelhos). Para o exemplo dado, a amostragem de poucos pontos, resultaria na eliminação/redução do Nível -1, porém para uma amostragem de uma quantidade maior de pontos o Nível -1 é o que apresenta menor afastamento e, portanto, deveria ter sua probabilidade aumentada. Em uma aplicação do método com redistribuição gradativa de probabilidades, dependendo da quantidade mínima de modelos ( $Ma_{min}$ ), haveria pouca mudança nas probabilidades.

### 4.3.2 Indicadores de Qualidade do Resultado e Critérios de Parada

Para avaliação dos resultados obtidos foram utilizadas as curvas de incertezas, tradicionais na avaliação de ajustes probabilísticos; e foram criados e testados nesta metodologia dois

indicadores de qualidade dos resultados: indicador de variabilidade das novas probabilidades estimadas e indicador do grau de ajuste obtido por poço.

A variabilidade das probabilidades é avaliada de modo a identificar quando o processo de redistribuição de probabilidades estabiliza, ou seja, quando as novas probabilidades apresentam pouca/baixa variação em relação às probabilidades anteriores.

A Figura 4.5 apresenta um gráfico de variabilidade das probabilidades para um atributo qualquer, nesta figura é possível verificar baixa variação próximo a 200 simulações (com uma variação de +/- 5% para o Nível 0 e Nível 1).

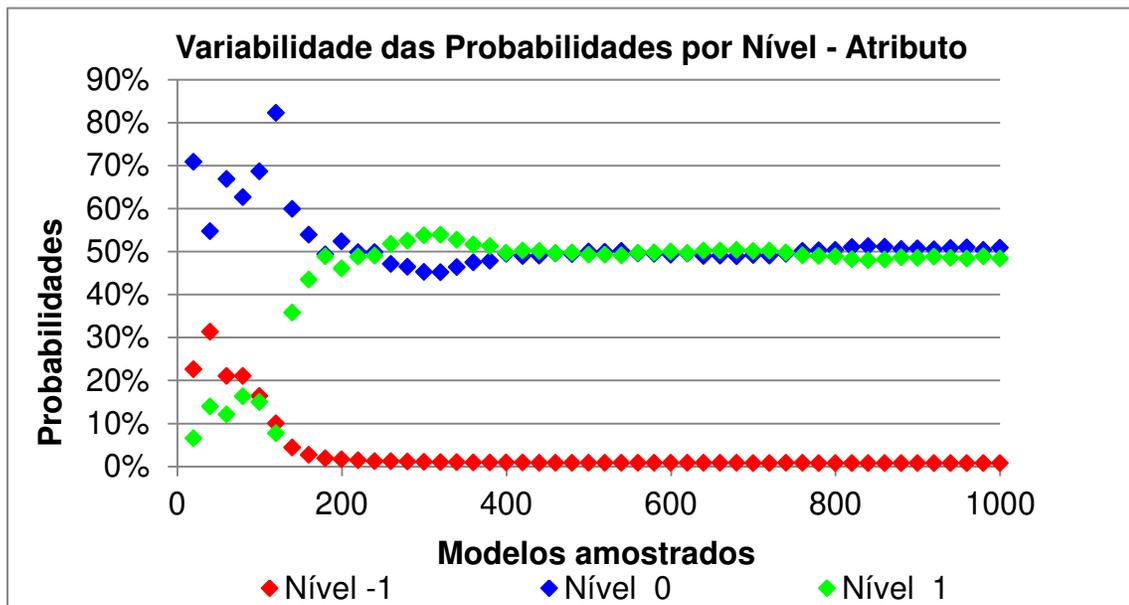


Figura 4.5 – Ilustração da representação da variabilidade das probabilidades por nível.

Após obter as probabilidades finais, as curvas de incertezas são geradas, e a partir dessas curvas, são selecionados modelos representativos das incertezas do caso em estudo ( $P_1$ ,  $P_{10}$ ,  $P_{90}$  e  $P_{99}$ ), conforme indicado na Figura 4.6.

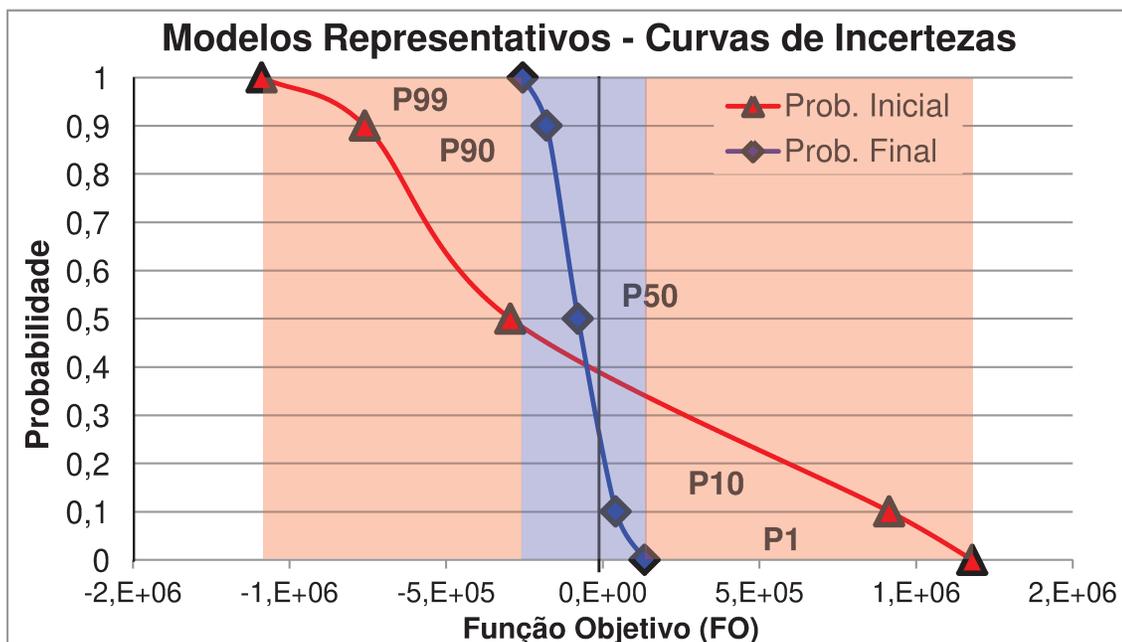


Figura 4.6 – Ilustração da seleção dos modelos representativos das incertezas inicial e final.

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 4.7). Esse tipo de gráfico foi introduzido principalmente para expressar o ajuste (ou afastamento) por poço (Figura 4.8), obtido com essa metodologia.

É importante citar que neste trabalho as curvas de incertezas são traçadas de uma maneira diferente da usual, onde todos os modelos têm que ser avaliados, a chamada curva de incertezas completa. Para este estudo cada curva de incerteza é composta por 50 modelos e, portanto, cada modelo possui probabilidade de 2%, selecionados e combinados aleatoriamente também com o método de Hipercubo Latino a partir das probabilidades iniciais e finais de cada atributo.

Nesse trabalho, o termo ajuste global é relacionado à *FO* utilizada (basicamente a soma dos afastamentos de todos os poços), enquanto o termo ajuste local representa o afastamento (ou erro) de cada um dos poços.

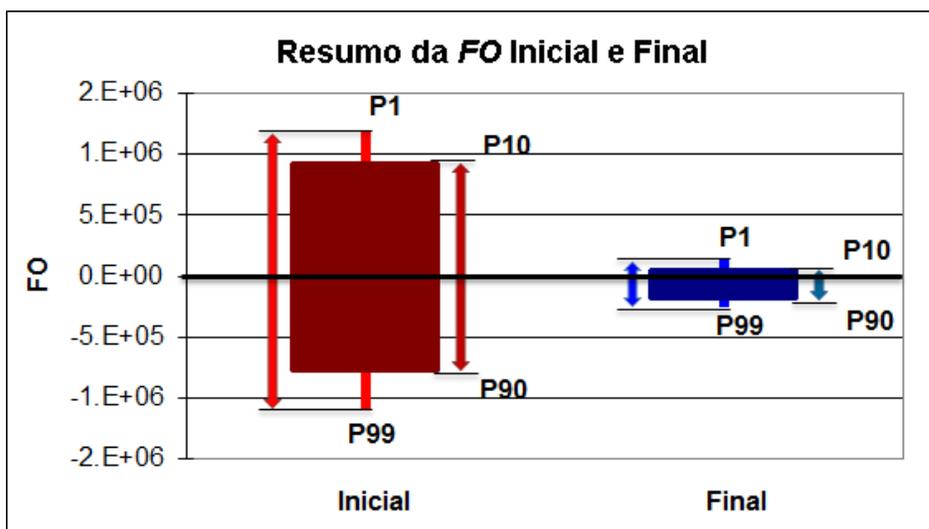


Figura 4.7 – Ilustração FO do campo antes e após a aplicação da metodologia.

Os afastamentos apresentados na Figura 4.8 são obtidos a partir da Equação 3.3, esses afastamentos também servem para representar a proporção, ou dispersão, em relação ao indicador de ajuste.

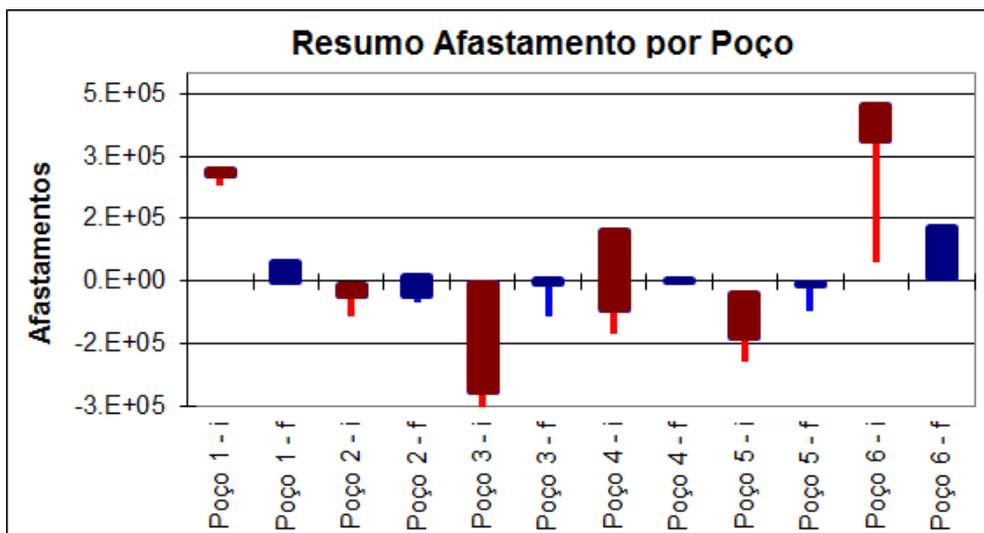


Figura 4.8 – Ilustração dos afastamentos dos poços.

Os ajustes obtidos por poço é um dos principais indicadores de qualidade dos resultados obtidos pelo método de redução de incertezas proposto neste trabalho. Esse indicador pode ser utilizado para qualquer caso, sintético ou com características reais, expressando a redução de incertezas e/ou grau de ajuste local, a partir da influência dos atributos considerados e suas respectivas probabilidades.



## **5. APLICAÇÃO**

Este capítulo consiste em uma descrição dos casos utilizados na validação e aplicação da metodologia proposta. São apresentadas as características dos modelos de simulação, tais como características espaciais, quantidade de poços, atributos incertos avaliados para cada caso, função objetivo escolhida. O Item 5.1 consiste na descrição dos casos utilizados nesse trabalho, Caso A e Caso B.

### **5.1 Descrição dos Casos**

A abordagem é realizada em dois casos de complexidades distintas. O primeiro caso (Caso A, Item 5.1.1) trata de um modelo de simulação simples, com atributos incertos da mesma natureza e, foi utilizado para validar essa metodologia. No segundo caso (Caso B, Item 5.1.2), a metodologia é aplicada em um modelo de simulação mais complexo, com elevada quantidade de atributos incertos de naturezas diferentes. Ambos os casos tratam-se de modelos de simulação sintéticos com resposta conhecida.

Todos os modelos aqui tratados possuíam como situação inicial uma distribuição uniforme de probabilidades para os atributos incertos, entretanto o tipo de distribuição de probabilidade não é uma limitação para o método proposto. A partir dessa condição, a metodologia pode então gerar novos perfis probabilísticos, resultando no processo de mitigação de incertezas.

É importante destacar mais uma vez, que o foco desta metodologia é obter um ajuste probabilístico, para os casos em estudo, a partir de uma redução das incertezas proveniente da fase de caracterização do reservatório. Portanto, não contempla os procedimentos de modelagem e parametrização do reservatório (definição dos atributos, discretização em níveis de incerteza e tipo de distribuição de probabilidades). Todos esses dados foram fornecidos pela equipe responsável pela fase de caracterização e obtidos de trabalhos anteriores.

Assume-se ainda que os atributos incertos avaliados são independentes, não sendo consideradas as influências que podem existir entre eles. A função objetivo escolhida para ser

ajustada neste trabalho é a vazão de água dos poços produtores, para ambos os casos e alcançando-se o ajuste da vazão de água, obtém-se também o ajuste da vazão de óleo, garantindo o balanço de materiais.

Conforme descrito no Capítulo 3, no trabalho apresentado por Maschio *et al.* (2010) foi realizada uma análise cuidadosa e detalhada para definir o valor do fator  $F$ , para o caso mais simples foi utilizado o valor de  $F = 2.5$ . Neste trabalho foi adotado o mesmo valor para o fator  $F$ , tendo em vista que foram utilizados os mesmos modelos de simulação. Para melhor entendimento desse estudo é indicada a leitura da literatura citada.

### **5.1.1 Caso A: Modelo de Simulação Simples**

O caso utilizado para a primeira aplicação da metodologia apresentada, denominado “Caso A”, trata-se de um modelo de simulação teórico simples, de resposta conhecida (Figura 5.1) e foi utilizado para validação desta metodologia. O Item 5.1.1.1 consiste na descrição das características do modelo de simulação do Caso A e o Item 5.1.1.2 a descrição dos atributos considerados para esse caso.

#### **5.1.1.1 Características do Modelo de Simulação – Caso A**

O modelo de simulação é descrito em uma malha cartesiana regular de 46 x 23 x 5 (sendo 46 blocos na direção “x”, 23 blocos na direção “y” e 5 camadas na direção “z”), dividido em 8 regiões e, cada uma dessas regiões possui um valor de permeabilidade absoluta diferente na direção horizontal. Possui ainda 8 poços, sendo 6 produtores e 2 injetores, arranjados em uma configuração do tipo “*five-spot*” (Figura 5.1).

Esse modelo foi utilizado para gerar um histórico sintético para um período de 10 anos. O caso base é gerado considerando os valores de  $K_x$  iguais para todas as regiões.

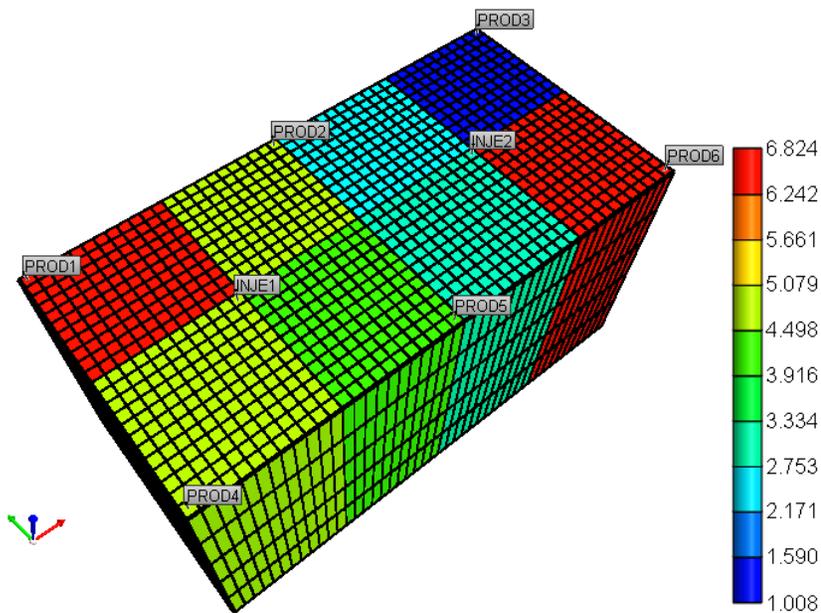


Figura 5.1 – Perspectiva do modelo de simulação do Caso A.

### 5.1.1.2 Atributos incertos considerados no Caso A

Os atributos incertos considerados neste caso são os valores de permeabilidade absoluta de cada região, resultando em um problema com oito atributos (Figura 5.2). Cada atributo incerto pode assumir valores que variam entre 1000 mD e 7000 mD.

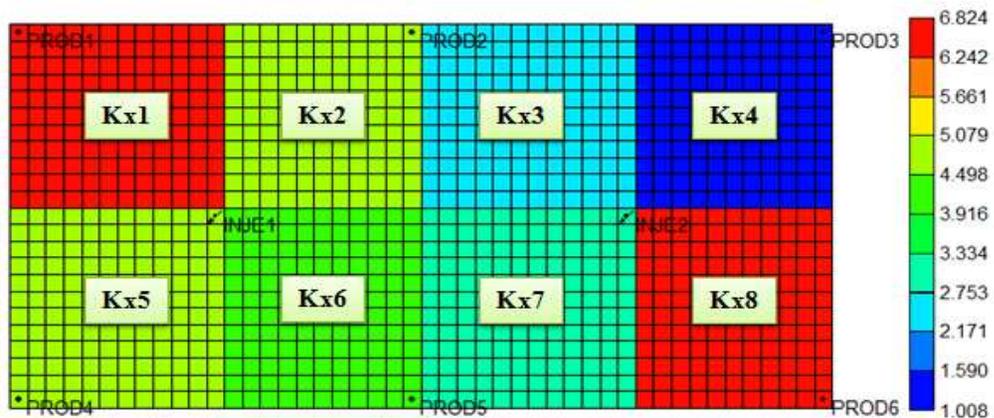


Figura 5.2 – Destaque das 8 regiões de diferentes permeabilidades (Caso A).

Esses atributos foram avaliados a partir de 3 “subcasos”, cada um com discretização em diferentes quantidades de níveis (Caso A1: 3 níveis, Caso A2: 5 níveis e Caso A3: 7 níveis discretos), onde cada nível é representado por um valor médio dentro da sua faixa de distribuição, conforme disposto na Tabela 5.1.

Tabela 5.1 – Resumo dos 3 cenários com diferentes níveis de discretização (Caso A)

Descrição dos Atributos	Cenários	Níveis discretos						
		1	2	3	4	5	6	7
Permeabilidade (mD)	A1	1000	4500	7000	X	X	X	X
	A2	1000	2750	4500	5750	7000	X	X
	A3	1000	2000	3000	4000	5000	6000	7000

Para este caso a metodologia foi executada com o fator  $F$  igual a 2.5, valor definido nos estudos apresentados por Maschio *et al.* (2010). As curvas de incertezas são compostas por 100 modelos de simulação, sendo 50 modelos provenientes das probabilidades iniciais e 50 modelos provenientes das probabilidades finais, selecionados a partir do método de Hipercubo Latino.

Para todos os cenários foi realizado um total de 1000 iterações, porém as probabilidades consideradas para a composição das curvas de incertezas foram retiradas a partir do momento em que as novas probabilidades apresentaram baixa variabilidade com o aumento no número de simulações (conforme indicado pelo critério de parada estabelecido), utilizando como referência a quantidade de simulações indicadas pelo critério de parada estabelecido (baixa variabilidade).

### 5.1.2 Caso B: Modelo de Simulação Complexo

A metodologia descrita foi aplicada também no “Caso B”, que se trata de um modelo de simulação com características muito mais parecidas com as de um campo real e, portanto, mais complexo (Figura 5.3). A descrição das características do modelo de simulação utilizado no Caso B é realizada no Item 5.1.2.1, enquanto a descrição dos atributos incertos considerados é realizada no Item 5.1.2.2.

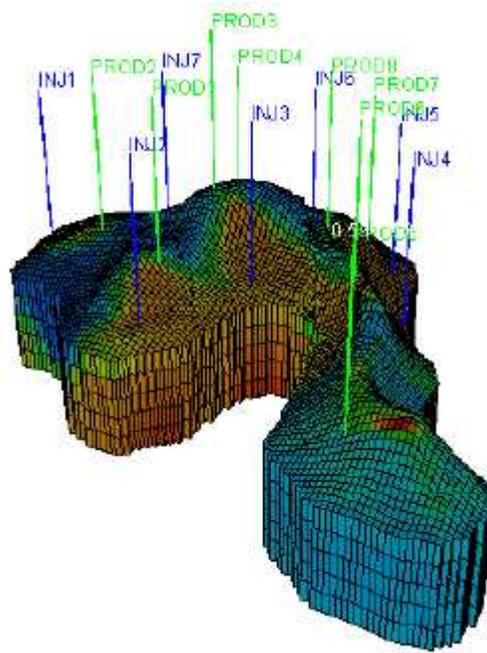


Figura 5.3 – Perspectiva do modelo de simulação do Caso B.

#### 5.1.2.1 Características do Modelo de Simulação – Caso B

Trata-se de um modelo de alta heterogeneidade e complexidade, a Figura 5.3 apresenta um mapa com uma perspectiva geral do modelo, com a representação dos poços. O Caso B também é um modelo sintético, descrito em uma malha do tipo *corner-point* com dimensões de 90 x 110 x 5, totalizando 49.500 blocos, gerado através de técnicas de geoestatística. Neste campo estão presentes 4 falhas, a drenagem é realizada por 8 poços produtores, e possui ainda 7 poços injetores de água que auxiliam na manutenção da pressão, totalizando 15 poços distribuídos ao longo da formação.

#### 5.1.2.2 Atributos incertos considerados no Caso B

Para este caso foram considerados 16 atributos incertos, entre eles a porosidade, permeabilidade absoluta e permeabilidade relativa, que estão associados às fácies do reservatório, localizadas conforme indica a Figura 5.4. Além dos atributos incertos já citados, a

transmissibilidade de cada uma das falhas também é considerada como um atributo incerto a ser considerado.

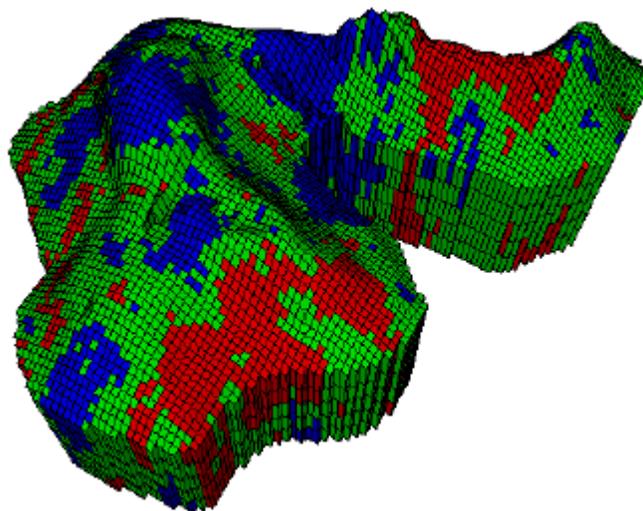


Figura 5.4 – Fácies do reservatório.

Assim como no Caso A, os atributos considerados no Caso B foram avaliados a partir de 3 “subcasos” com discretização em diferentes quantidades de níveis (Caso B1: 3 níveis, Caso B2: 5 níveis e Caso B3: 7 níveis de incerteza). A Tabela 5.2 apresenta um resumo geral relativo aos atributos considerados. Um modelo escolhido a partir de uma combinação dos atributos mostrados nessa tabela foi utilizado para geração de um histórico sintético para um período de 10 anos.

Tabela 5.2 – Resumo geral dos atributos incertos considerados.

Número do atributo	Descrição	Tipo	Mín.	Máx.
1 a 3	Porosidade	Multiplicador	0.85	1.15
4 a 6	Permeabilidade horizontal (Kx)	Multiplicador Log	0.75	1.1
7 a 9	Permeabilidade vertical (Kz)	% de Kx	4	25
10 a 12	Transmissibilidade da falha	Multiplicador	0	1
13 a 16	Permeabilidade relativa	Expoente da fase água (Modelo de Corey)	1	5

Assim como acontece também no caso anterior, cada nível discreto é representado por um valor médio dentro da sua faixa de distribuição, conforme indicado na Tabela 5.3. A distribuição inicial de probabilidades para cada um desses níveis discretos nos diferentes cenários avaliados é do tipo uniforme.

Tabela 5.3 – Resumo dos 3 cenários com diferentes níveis de discretização (Caso B).

Descrição dos Atributos	Cenários	Níveis discretos						
		1	2	3	4	5	6	7
Porosidade	<b>B1</b>	0.850	1.000	1.15	X	X	X	X
	<b>B2</b>	0.850	0.925	1	1.075	1.150	X	X
	<b>B3</b>	0.850	0.900	0.950	1	1.05	1.100	1.150
Permeabilidade horizontal (Kx)	<b>B1</b>	0.75	0.925	1.1	X	X	X	X
	<b>B2</b>	0.75	0.8375	0.925	1.0125	1.1	X	X
	<b>B3</b>	0.75	0.81	0.87	0.93	0.98	1.04	1.1
Permeabilidade vertical (Kz)	<b>B1</b>	4	14.5	25	X	X	X	X
	<b>B2</b>	4	9.25	14.5	19.75	25	X	X
	<b>B3</b>	4	7.5	11.0	14.5	18.0	21.5	25
Transmissibilidade da falha	<b>B1</b>	0	0.5	1	X	X	X	X
	<b>B2</b>	0	0.25	0.5	0.75	1	X	X
	<b>B3</b>	0	0.17	0.33	0.5	0.67	0.83	1
Permeabilidade relativa	<b>B1</b>	1	3	5	X	X	X	X
	<b>B2</b>	1	2	3	4	5	X	X
	<b>B3</b>	1	1.67	2.33	3	3.67	4.33	5

Novamente considerando os estudos apresentados por Maschio *et al.* (2010) para Caso B a metodologia foi executada com o fator  $F$  de 2.5. Mais uma vez, as curvas de incertezas foram compostas de por 100 modelos de simulação, sendo 50 modelos provenientes das probabilidades iniciais e 50 modelos provenientes das probabilidades finais, selecionados a partir do método de Hipercubo Latino.

Para todos os cenários foram realizados um total de 1000 iterações, porém as probabilidades consideradas para a composição das curvas de incertezas foram retiradas a partir do momento em que as novas probabilidades apresentaram baixa variabilidade com o aumento no número de simulações.

## **6. RESULTADOS E DISCUSSÕES**

Este capítulo apresenta os resultados e discussões correspondentes à aplicação da metodologia deste trabalho, nos casos descritos no Capítulo 5. O presente capítulo está dividido em duas seções, as primeiras análises são destinadas aos resultados oriundos do Caso A (Item 6.1) e a segunda seção destinada às análises relacionadas ao Caso B (Item 6.2).

### **6.1 Caso A – Modelo de Simulação Simples**

O método de mitigação de incertezas foi inicialmente aplicado a um modelo de simulação simples, o Caso A deste trabalho, descrito no Capítulo 5. Este caso foi utilizado para validação da metodologia e avaliado a partir de 3 (três) subcasos, onde cada subcaso difere do outro pela quantidade de níveis discretos (Caso A1: 3 níveis; Caso A2: 5 níveis; e Caso A3: 7 níveis), os resultados obtidos são apresentados nos Itens 6.1.1, 6.1.2 e 6.1.3, respectivamente. Uma análise comparativa entre os resultados obtidos para o Caso A é realizada e apresentada no Item 6.1.4.

#### **6.1.1 Caso A1 – 3 níveis discretos**

Os resultados obtidos a partir do Caso A1 são apresentados a partir da Figura 6.1. Essa figura expressa as probabilidades finais obtidas para cada um dos níveis dos atributos incertos, considerados nesse caso. Ao lado da identificação dos atributos pode ser observada a quantidade de modelos amostrados para obter o resultado. É possível identificar que há um aumento das probabilidades dos níveis mais próximos às marcas em vermelho, que representam os valores conhecidos de cada atributo.

## PROBABILIDADES DE CADA NÍVEL POR ATRIBUTO

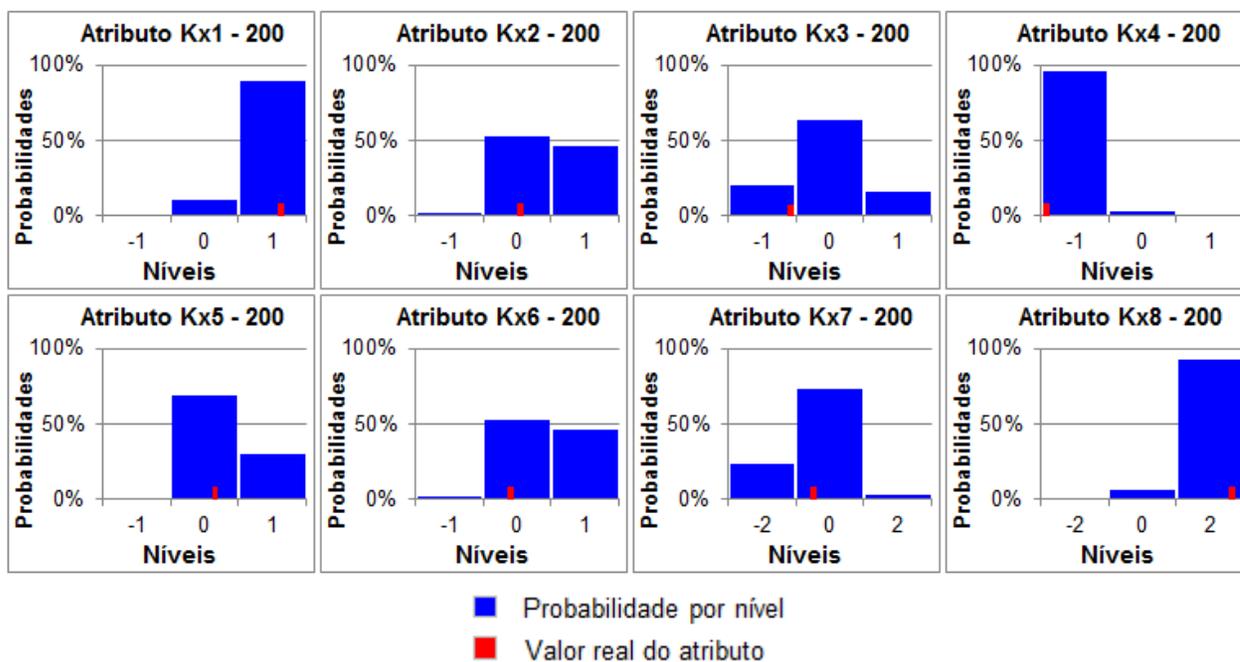


Figura 6.1 – Probabilidades Caso A1: 200 Simulações.

Esse resultado indica que a metodologia apresentou um resultado coerente com o esperado, uma vez que os níveis que possuem valores mais próximos dos reais tiveram suas probabilidades ampliadas, exceto o atributo Kx3.

A variabilidade das probabilidades de cada nível discreto, de cada atributo, é um importante indicador de estabilidade do processo e foi utilizado como critério de parada na metodologia proposta neste trabalho. Através desse indicador, é possível identificar de forma direta a quantidade de modelos amostrados e simulados até que o método seja finalizado. Com uma análise visual da Figura 6.2 é evidente a baixa variação das probabilidades próximo a 200 simulações.

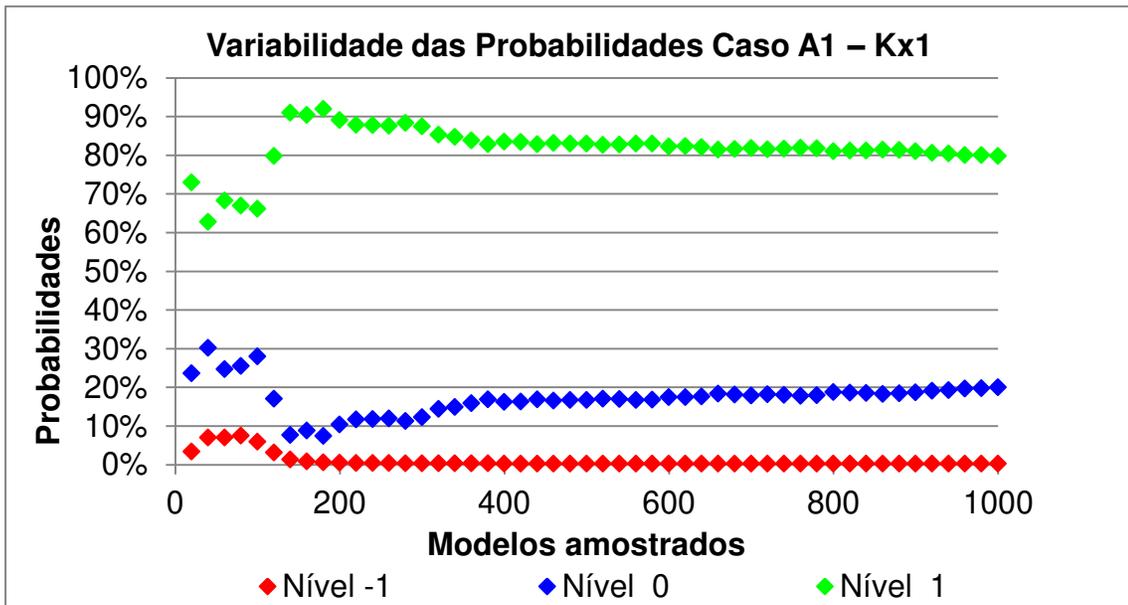


Figura 6.2 – Variabilidade das Probabilidades de Kx1 (Caso A1).

As mesmas observações utilizadas para avaliar a variabilidade do atributo “Kx1” (Figura 6.2) podem ser consideradas na avaliação do atributo “Kx2” (Figura 6.3), apesar de algumas pequenas alterações nas probabilidades, não há mudança significativa com o aumento das simulações.

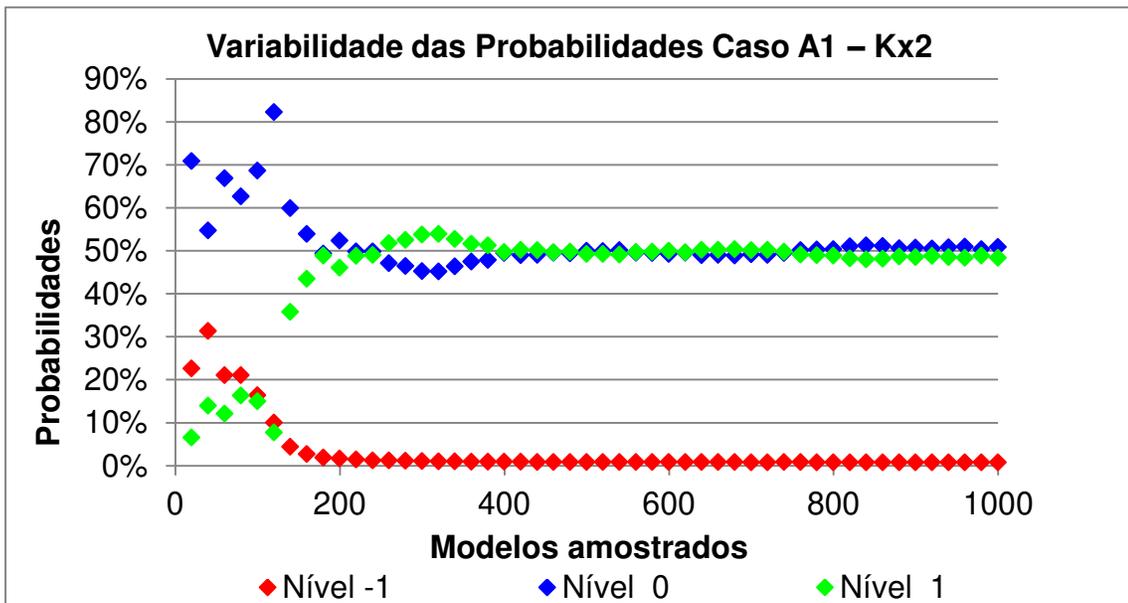


Figura 6.3 – Variabilidade das Probabilidades de Kx2 (Caso A1).

Na avaliação da variabilidade do atributo “Kx3” (Figura 6.4) há uma modificação maior nas probabilidades do Nível 0 e Nível 1, mesmo após a seleção de 200 modelos. Entretanto, as alterações nas probabilidades, obtidas para 200 modelos e o dobro de simulações (400) é de aproximadamente 10% entre os dois níveis citados. Como apenas esse atributo apresentou esse tipo de variação, os resultados considerados para as análises seguintes foram obtidos com 200 simulações.

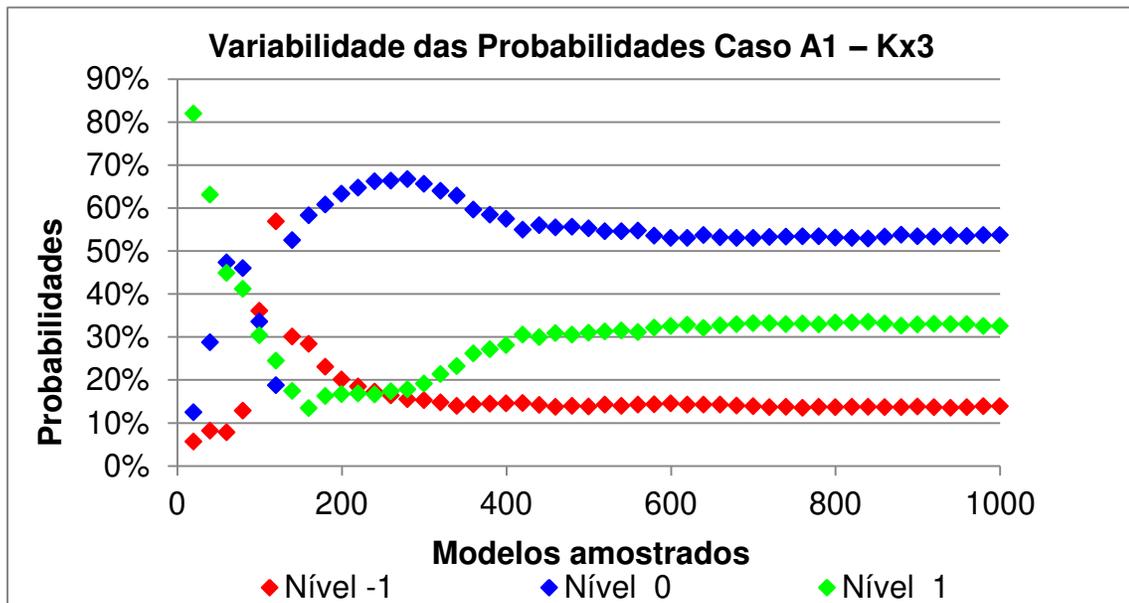


Figura 6.4 – Variabilidade das Probabilidades de Kx3 (Caso A1).

Outro indicador de qualidade dos resultados, obtidos a partir do método de redução de incertezas, consiste na análise das curvas de incertezas. Para compor essas curvas foram selecionados 50 modelos representativos das incertezas provenientes das probabilidades finais e 50 modelos representativos das incertezas provenientes das probabilidades iniciais. Os resultados do Caso A1 indicam uma redução, de aproximadamente 80%, na dispersão dos modelos representativos das incertezas do caso em estudo (Figura 6.5).

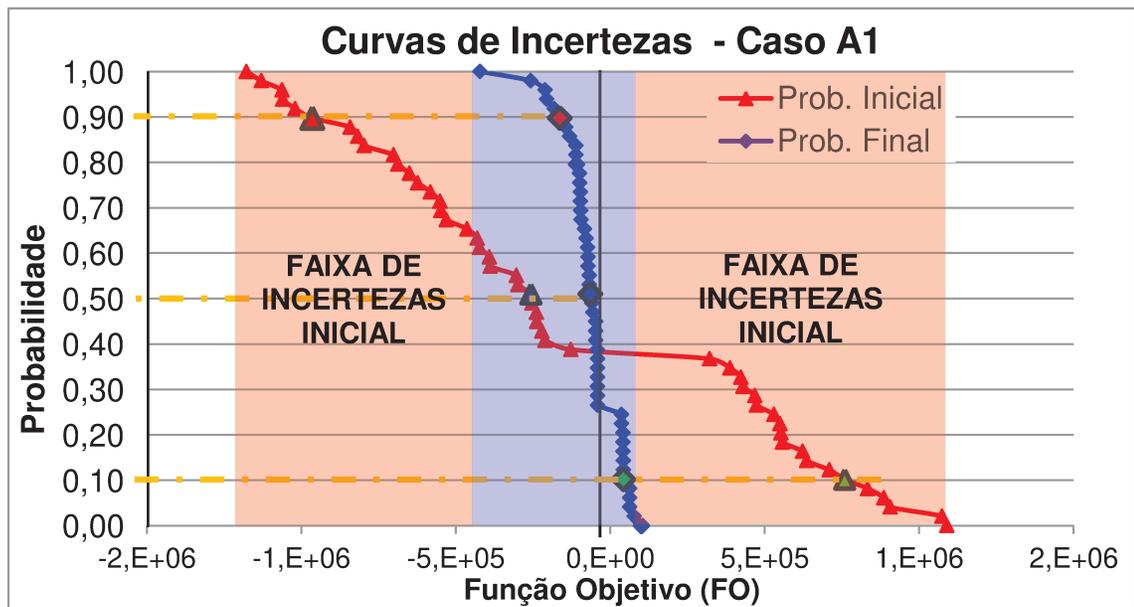


Figura 6.5 – Curva de Incertezas do Caso A1.

A redução na dispersão dos modelos representativos das incertezas pode ser observada na Figura 6.5, a partir da curva de incertezas iniciais (vermelho) e finais (azul). Essa dispersão pode também ser avaliada em um gráfico tipo “bastão”. A Figura 6.6 representa um comparativo resumido da discrepância da *FO* dos modelos de simulação, em relação ao ajuste perfeito, antes e após a aplicação do método de redução de incertezas. Nesta figura são apresentados os modelos representativos das incertezas, extremos  $P_{99}$  e  $P_1$ ; e os modelos  $P_{90}$  e  $P_{10}$  (pessimista e otimista) provenientes das curvas de incertezas inicial (vermelho) e final (azul).

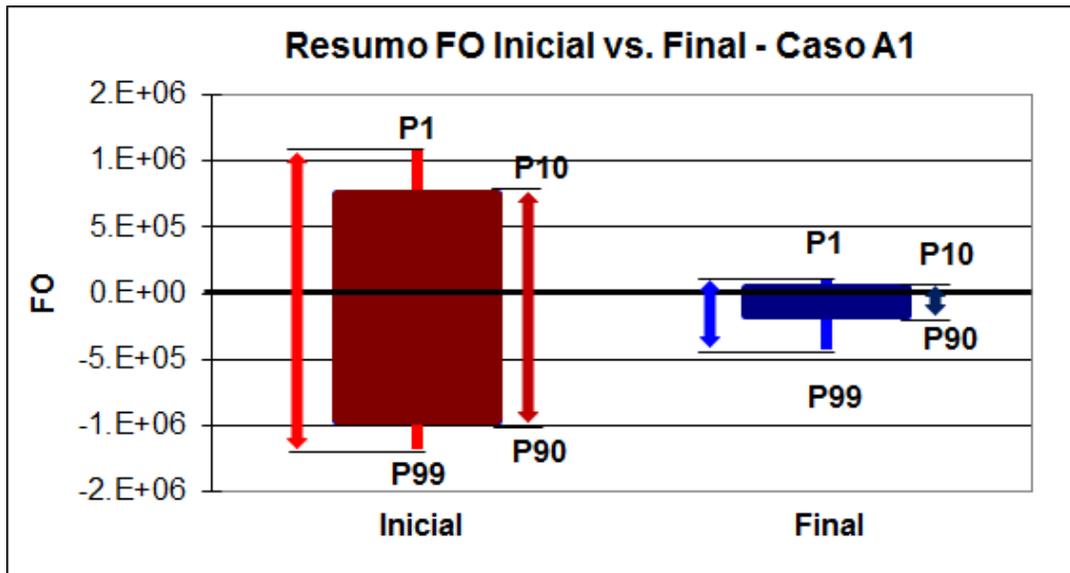


Figura 6.6 – Comparativo da *FO* antes e após a redução de incertezas (Caso A1).

A representação da *FO*, antes e após a redução de incertezas, em gráfico tipo “bastão” é válida por possibilitar uma ideia geral da redução obtida com o método proposto (Figura 6.6), semelhante à curva de incertezas, pois indica também a proporção de modelos com valores acima e abaixo do que seria o ajuste “perfeito”. Entretanto, esse tipo de representação foi introduzido neste trabalho para servir de indicador de qualidade do grau de ajuste (ou afastamento) obtido por poço para facilitar a interpretação dos resultados. Esse tipo de gráfico é útil para representar de forma comparativa os afastamentos inicial e final de cada poço. Os resultados obtidos para o Caso A1 podem ser observados na Figura 6.7.

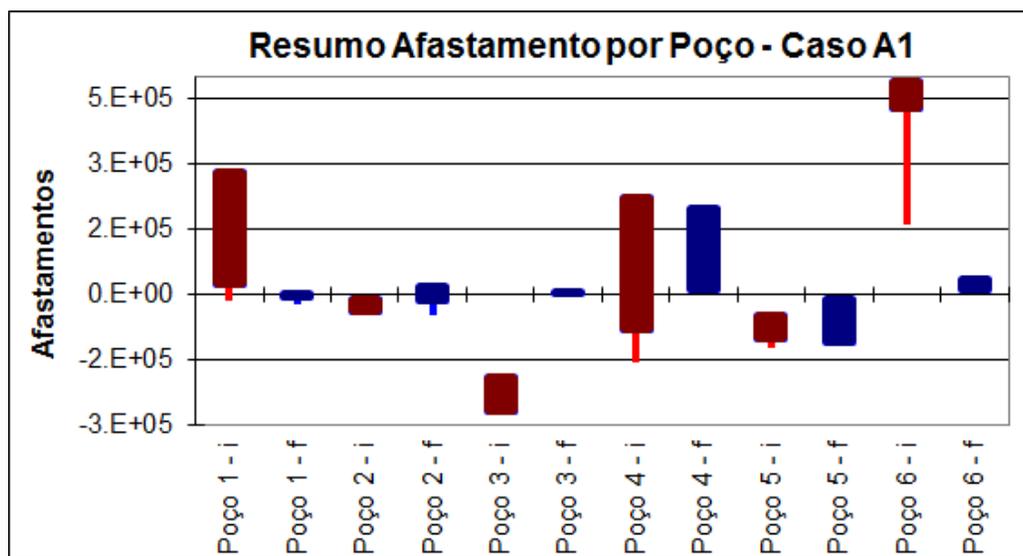


Figura 6.7 – Afastamento por poço (Caso A1).

Os resultados expressos na Figura 6.7 indicam uma redução nos afastamentos finais, para todos os poços, quando comparado aos afastamentos iniciais. Outro fator relevante nesse resultado, que deve ser considerado na avaliação é a proporção, ou centralização, do “bastão”, em relação ao eixo horizontal com valor 0 (zero); essa característica indica que houve uma dispersão mais proporcional dos afastamentos em relação ao que seria o indicador de inexistência de afastamento. Dessa forma entende-se que as incertezas consideradas para este caso estão bem representadas.

### 6.1.2 Caso A2 – 5 níveis discretos

Para o Caso A2, onde cada atributo possui 5 níveis discretos, foram utilizados os mesmos critérios de avaliação dos resultados do Caso A1. Contudo, no Caso A2 foi possível identificar que as novas probabilidades apresentaram baixa variabilidade a partir de um número maior de simulações (Figura 6.8), ou seja, para esse caso ao aumentar o número de níveis é necessário aumentar o número de simulações para obter melhores resultados.

## PROBABILIDADES DE CADA NÍVEL POR ATRIBUTO - CASO A2

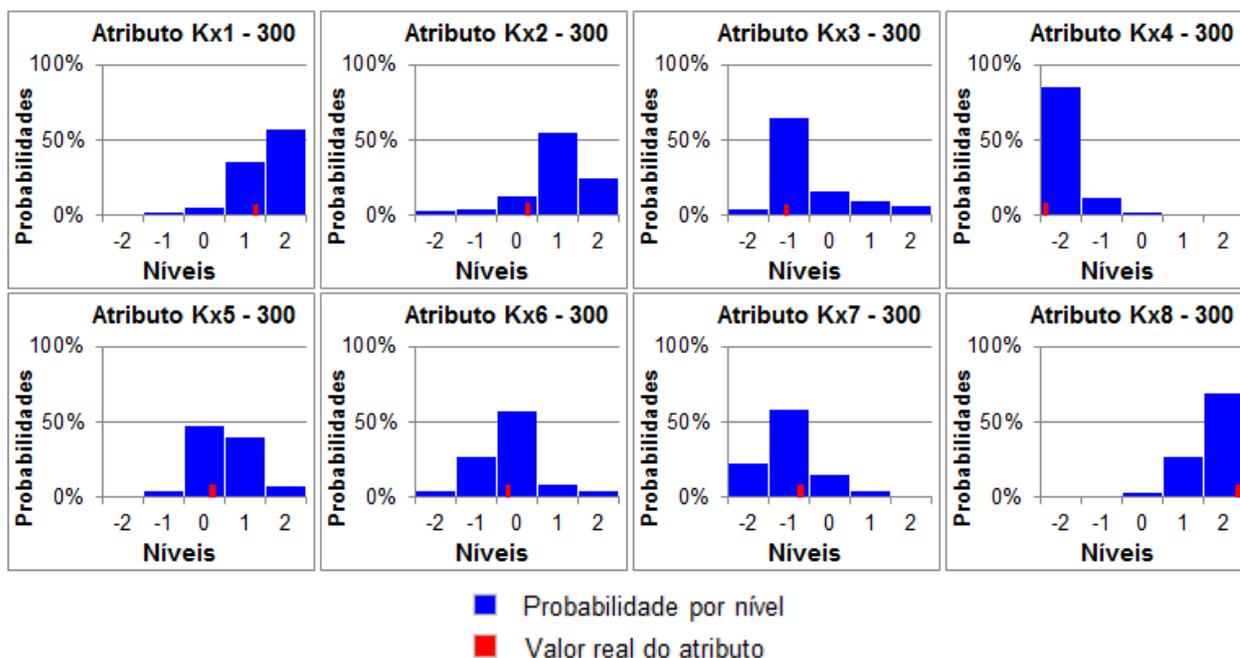


Figura 6.8 – Probabilidades Caso A2: 300 Simulações.

Com a aplicação da metodologia no Caso A2, os resultados obtidos também representam valores e comportamentos satisfatórios, pois as probabilidades de todos dos atributos apresentaram um aumento nos níveis que representam os valores mais próximos dos reais (marcação em vermelho), ou imediatamente ao próximo a eles. No entanto, para obter uma baixa variabilidade, ou estabilidade, nas novas probabilidades, foi necessário um incremento de 50% no número de simulações (totalizando 300 simulações), em relação ao número de simulações necessárias para o Caso A1.

Apesar do incremento de 100 simulações no Caso A2, em relação ao Caso A1, a quantidade de simulações realizadas ainda é muito baixa, quando comparada à técnica de árvore de derivação por exemplo. Com a técnica de árvore de derivação, para esse mesmo caso, seria necessário um incremento de aproximadamente 59 vezes o número total de simulações da primeira aplicação para a segunda (Caso A1 apresenta 6561 modelos simulações possíveis e Caso A2 apresenta 390.625).

O atributo Kx1, no Caso A2, apresentou baixa variabilidade nas probabilidades, dos diferentes níveis, entre 300 e 400 simulações, conforme pode ser observado na Figura 6.9.

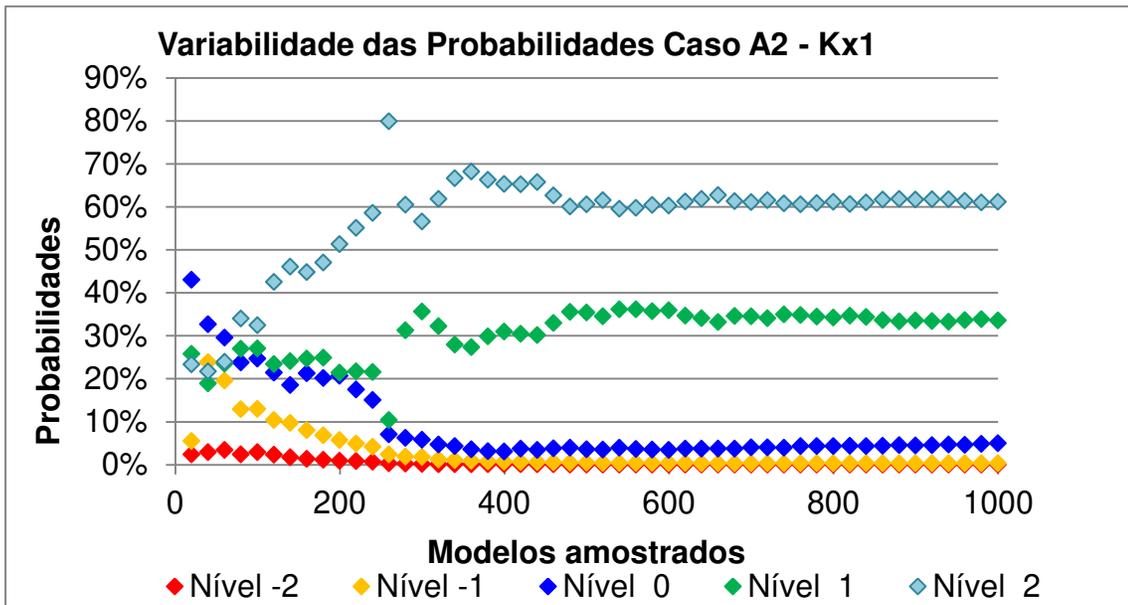


Figura 6.9 – Variabilidade das Probabilidades de Kx1 (Caso A2).

Apesar de apresentar um comportamento com algumas variações, a exemplo do que ocorreu no caso anterior, o atributo Kx3 também apresentou baixa variabilidade próximo a 300 simulações (Figura 6.10).

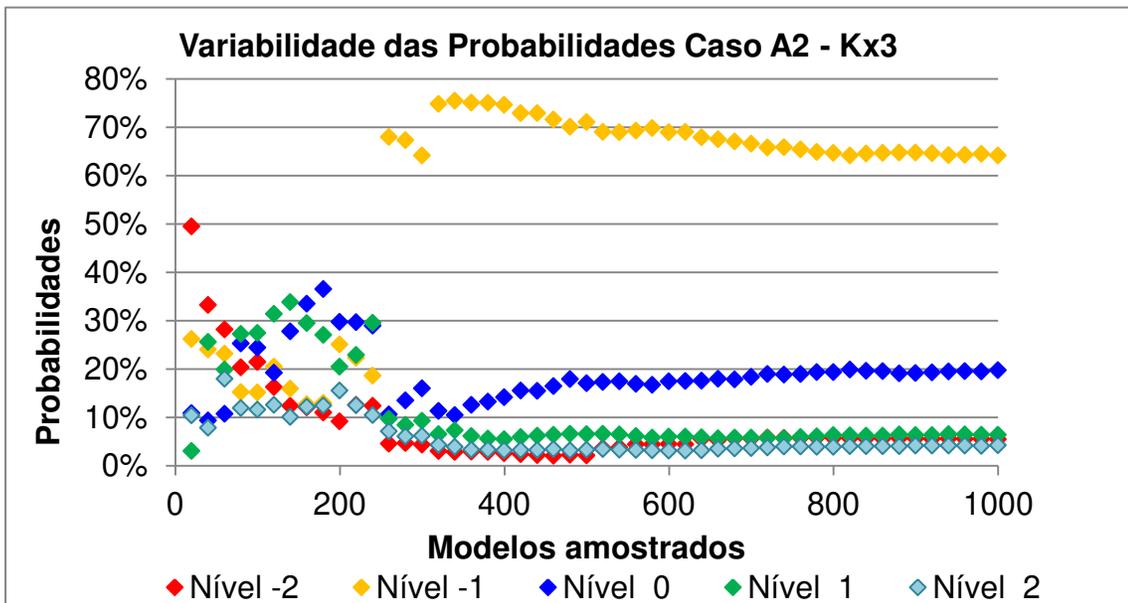


Figura 6.10 – Variabilidade das Probabilidades de Kx3 (Caso A2).

Novamente é realizada uma comparação entre a *FO* dos modelos representativos, antes e após a aplicação da metodologia, para as 300 simulações realizadas nesse caso (Figura 6.11). Os resultados indicam uma redução ainda maior na dispersão dos afastamentos finais, em relação aos iniciais, aproximadamente 85%.

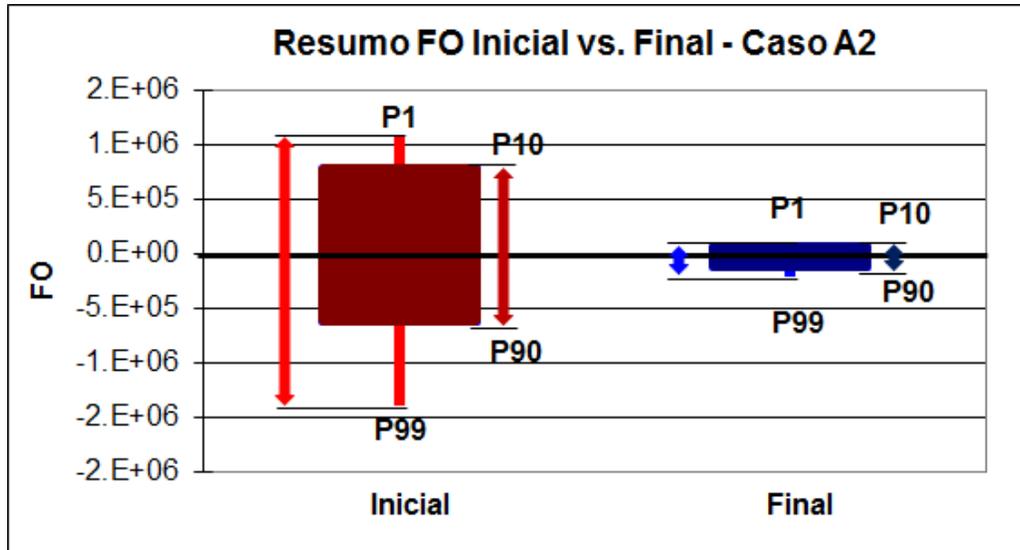


Figura 6.11 – Comparativo da *FO* antes e após a redução de incertezas (Caso A2): 300 simulações.

O reflexo dessa redução e a qualidade do ajuste obtido para esse caso, também podem ser observados na Figura 6.12. Conforme descrito no caso anterior, além da redução do afastamento, a centralização do “bastão” em relação ao eixo horizontal fixado no ponto 0 (zero), também é um indicador de qualidade do método, e serve, principalmente, para avaliar a qualidade do ajuste para casos onde não há resposta conhecida. Na Figura 6.12 é possível observar que o poço 4 apresentou um pequeno aumento no afastamento final, em relação ao inicial, para o lado positivo. Pouco representativo, quando comparado aos ajustes obtidos para os demais poços.

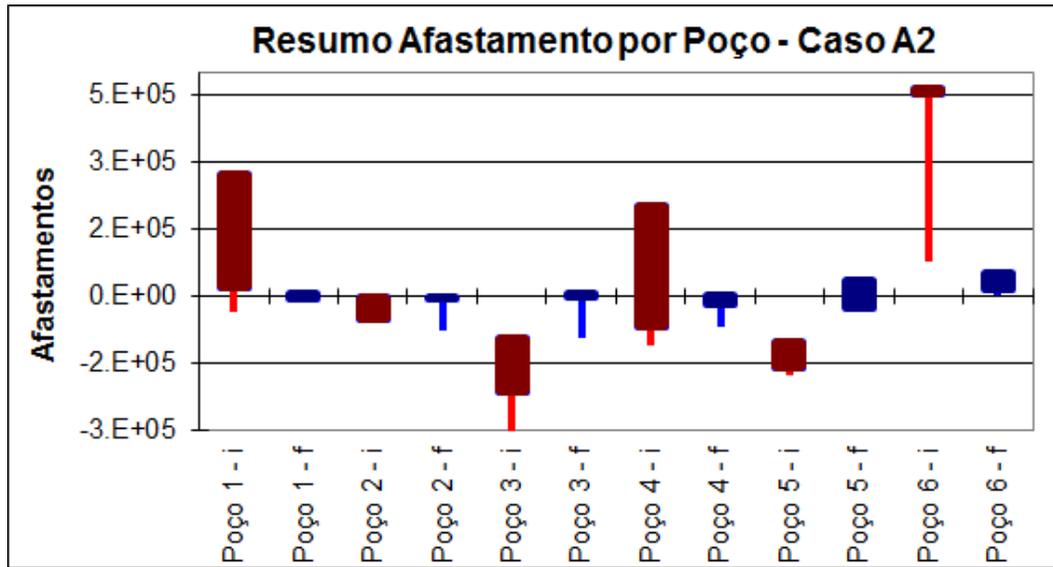


Figura 6.12 – Afastamento por poço (Caso A2).

### 6.1.3 Caso A3 – 7 níveis discretos

Os resultados obtidos para o Caso A3 também apresentaram valores satisfatórios, com as probabilidades dos atributos tendo sido modificadas conforme esperado, convergindo para a marcação em vermelho (que representa o valor real do atributo), exceto o atributo Kx3 (Figura 6.13). O comportamento deste atributo evidencia um problema/limitação do método de distribuição de probabilidades utilizando o *HL*, proposto neste trabalho, para um número elevado de níveis discretos. Quando um dos níveis de qualquer atributo apresenta valores muito baixos, sua probabilidade pode se tornar nula a partir de um número pequeno de simulações, por isso deve sempre ser observado o dimensionamento da quantidade mínima de simulações ( $Ma_{min}$ ) para evitar esse tipo de problema.

### PROBABILIDADES DE CADA NÍVEL POR ATRIBUTO - CASO A3

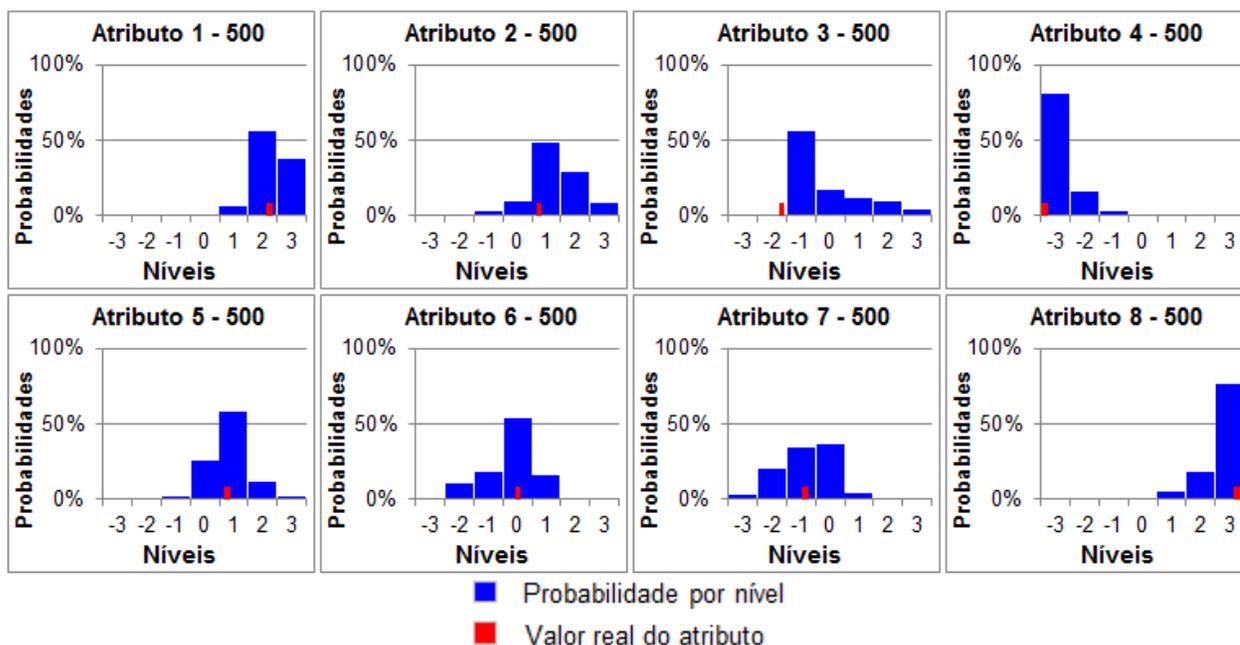


Figura 6.13 – Probabilidades Finais 8 Atributos 7 níveis (1000 Iterações).

Como o objetivo da aplicação da metodologia descrita, nos Casos A1, A2 e A3, é validar o método, foram mantidas as mesmas características de aplicação para as diferentes situações (3, 5 e 7 níveis discreto), quantidade mínima de simulações ( $Ma_{mín}$ ) 200 modelos, com amostragem de 20 modelos por iteração. Desta forma, o resultado obtido para o Caso A3 indica que pode ter ocorrido dimensionamento inadequado da quantidade mínima de simulações ( $Ma_{mín}$ ), de modo a permitir que um dos níveis fosse anulado logo no início do processo. É importante destacar que com o aumento do número de níveis discretos há um aumento considerável no número de modelos possíveis.

Na Figura 6.14 é possível observar que o nível -2, que representa o valor mais próximo do real, tem sua probabilidade reduzida gradativamente já nas primeiras simulações. Esse efeito pode ocorrer, quando um nível (próximo do real), de um determinado atributo, é combinado com outros níveis (longe dos valores reais), dos demais atributos, proporcionando resultados muito distantes dos dados observados. Normalmente é mais fácil de ocorrer em casos com grandes quantidades de níveis discretos, esse efeito pode ser minimizado com o dimensionamento de uma

quantidade mínima de simulações ( $Ma_{min}$ ) adequada para o caso. Apesar disso o nível imediatamente próximo, ao que representa o valor real, teve sua probabilidade bastante ampliada.

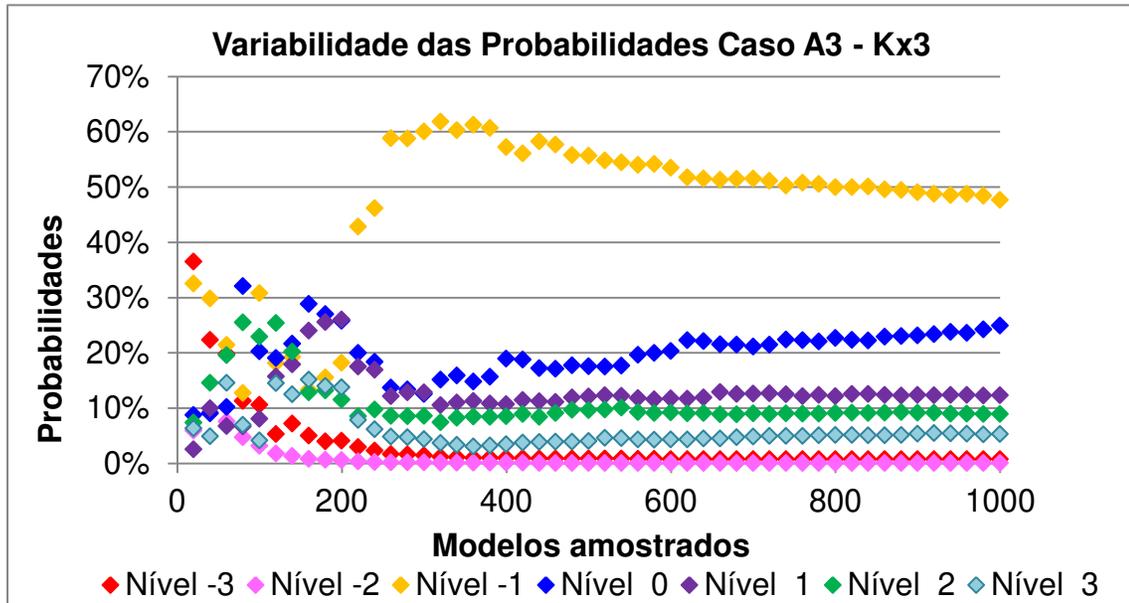


Figura 6.14 – Variabilidade das Probabilidades de Kx3 (Caso A3).

Os demais atributos do Caso A3 apresentaram baixa variabilidade próxima às 400 simulações (Figura 6.14). O aumento no número de simulações representa um incremento de 50% na quantidade de modelos simulados em relação ao Caso A2, e de 100% em relação ao Caso A1. Mais uma vez ao comparar o método proposto com o método de árvore de derivação, a quantidade de simulações utilizadas representa uma quantidade muito pequena. A redução na dispersão da  $FO$  final, em relação a inicial, é de aproximadamente 90% (Figura 6.15).

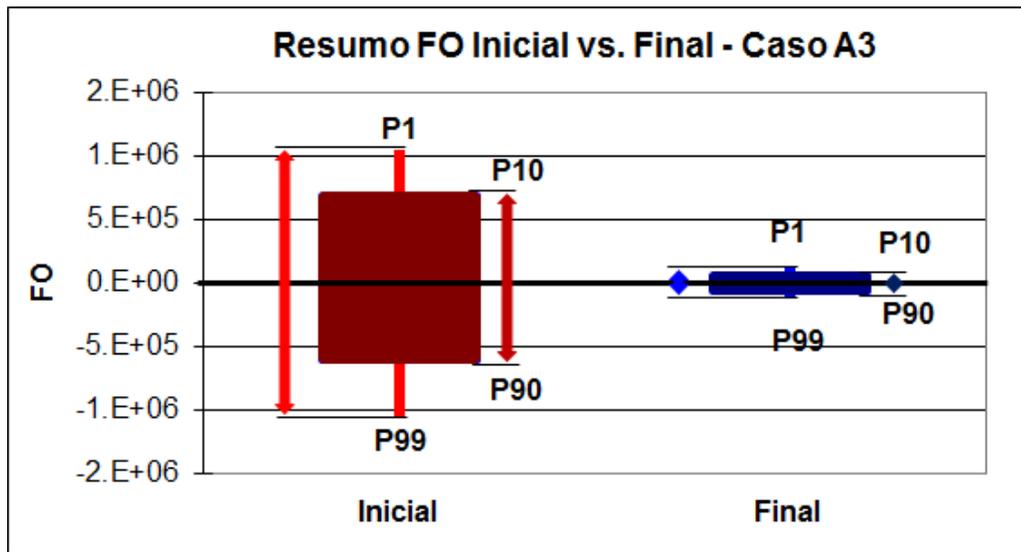


Figura 6.15 – Comparativo da *FO* antes e após a redução de incertezas (Caso A3).

Utilizando o indicador de afastamento por poço (Figura 6.16) a redução das incertezas, observadas nas figuras anteriores, torna-se ainda mais evidente através de um melhor ajuste para os poços.

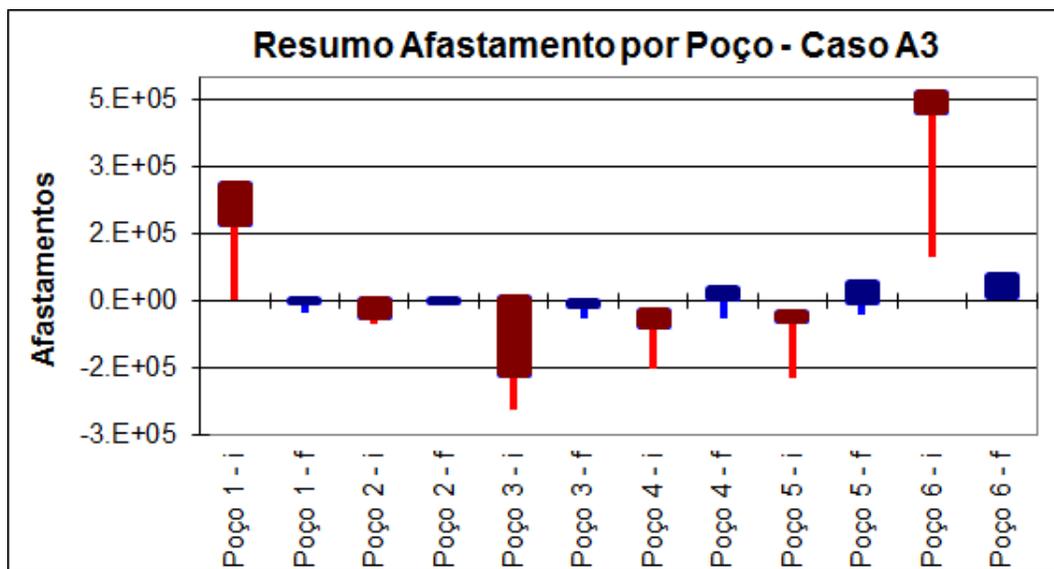


Figura 6.16 – Afastamento por poço (Caso A3).

### 6.1.4 Análise Comparativa dos Resultados do Caso A

Neste Item 6.1.4 é realizado uma análise comparativa entre os resultados finais obtidos para os três subcasos. A Figura 6.17 apresenta um resumo geral das *FO* dos modelos representativos da faixa de incertezas ( $P_{99}$ ,  $P_{90}$ ,  $P_{10}$  e  $P_1$ ), proveniente das curvas de incertezas inicial e final, de cada subcaso do Caso A (Caso A1, Caso A2 e Caso A3), todos para 400 simulações.

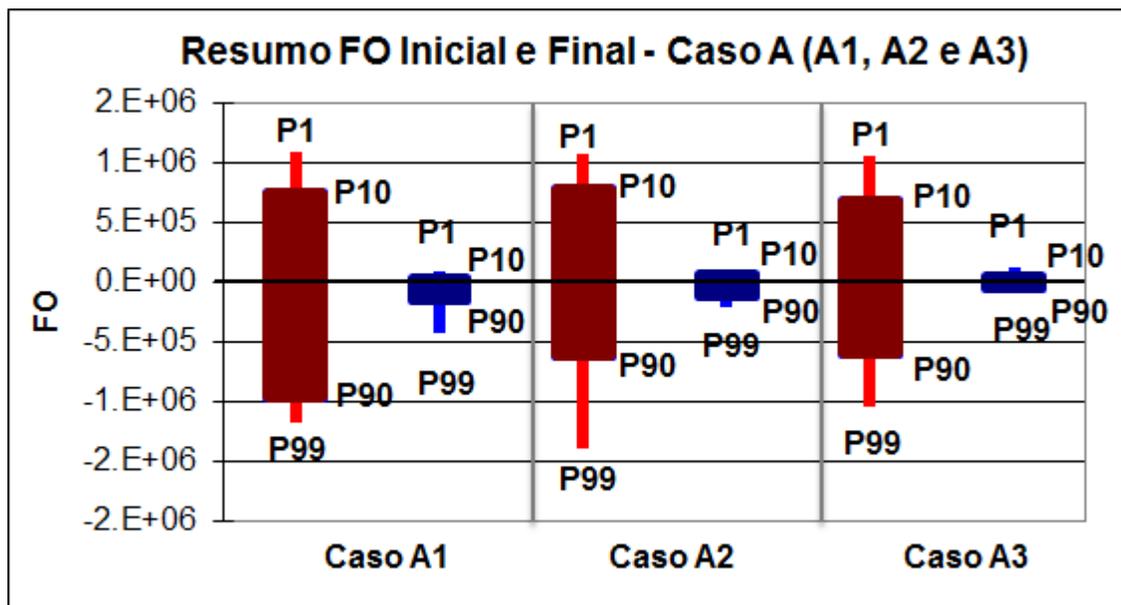


Figura 6.17 – Resumo *FO* inicial e final dos modelos representativos das incertezas dos Caso A1, Caso A2 e Caso A3 para 400 simulações.

É possível observar (na Figura 6.17) uma redução entre 80% e 90% na dispersão da *FO* final dos modelos representativos das incertezas dos casos avaliados, em relação aos modelos iniciais. Além da redução nos afastamentos obtidos para cada poço. Essa constatação indica que a metodologia apresentou desempenho aceitável, dentro do que foi proposto com esse método.

As curvas de produção dos poços dos Casos A1, A2 e A3 também podem representar uma redução na dispersão em relação aos dados de produção observados. As curvas de produção de água inicial (vermelho) e final (azul) dos poços 2 e 4 dos modelos compreendidos entre  $P_{90}$  e  $P_{10}$  estão apresentadas na Figura 6.18, Figura 6.19 e Figura 6.20 (representando os Casos A1, A2 e A3, respectivamente). O poço 2 apresentou pouca redução nas incertezas, enquanto o poço 4 apresenta-se “bem” ajustado.

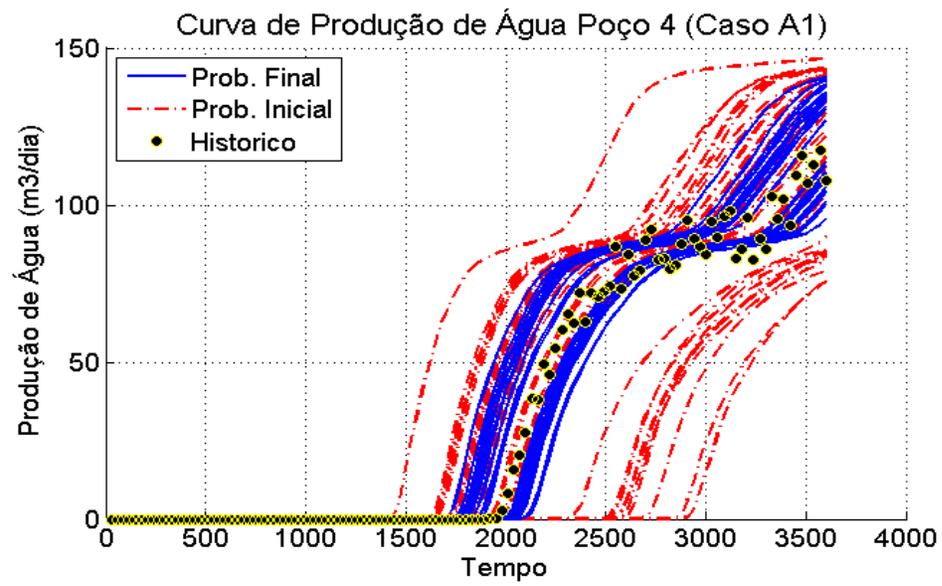
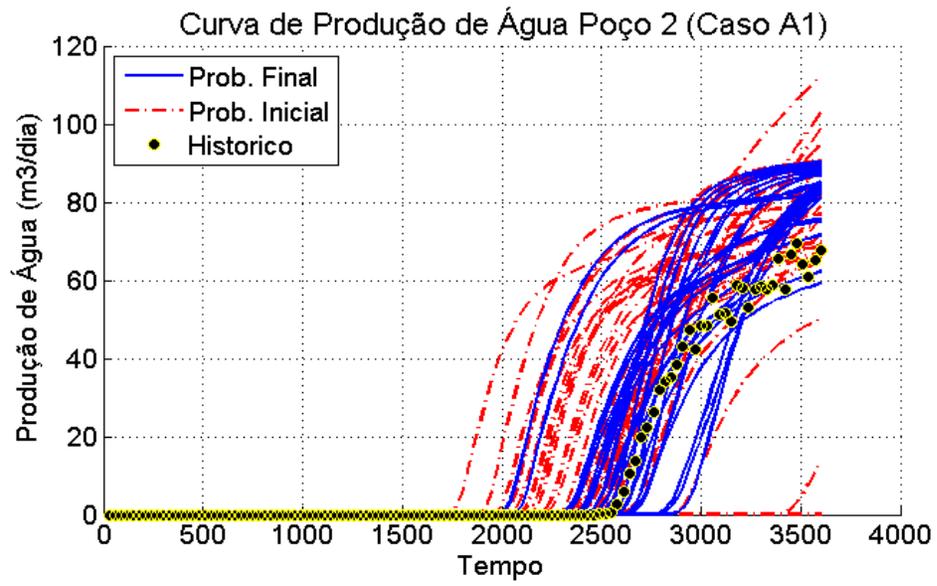


Figura 6.18 – Curvas de Produção dos Poços 2 e 4 (Caso A1).

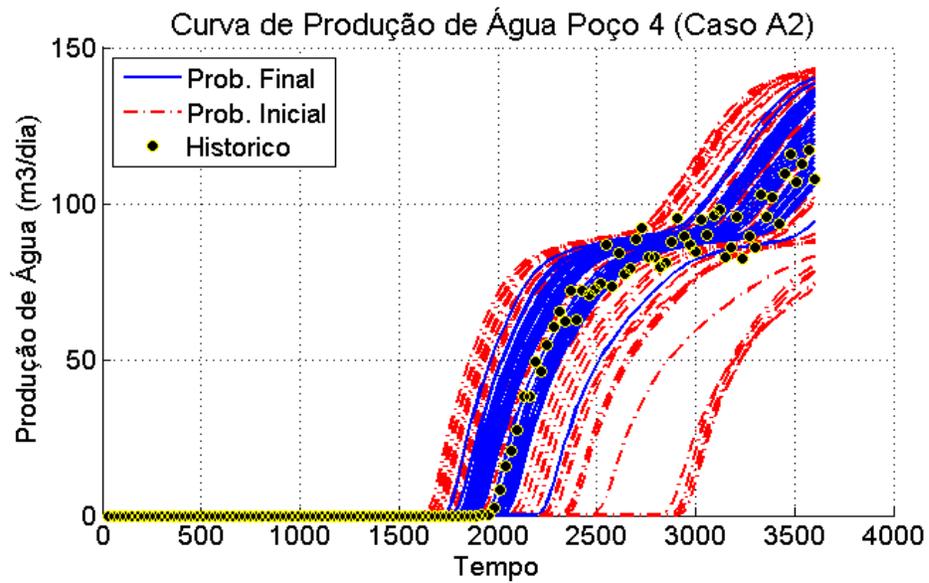
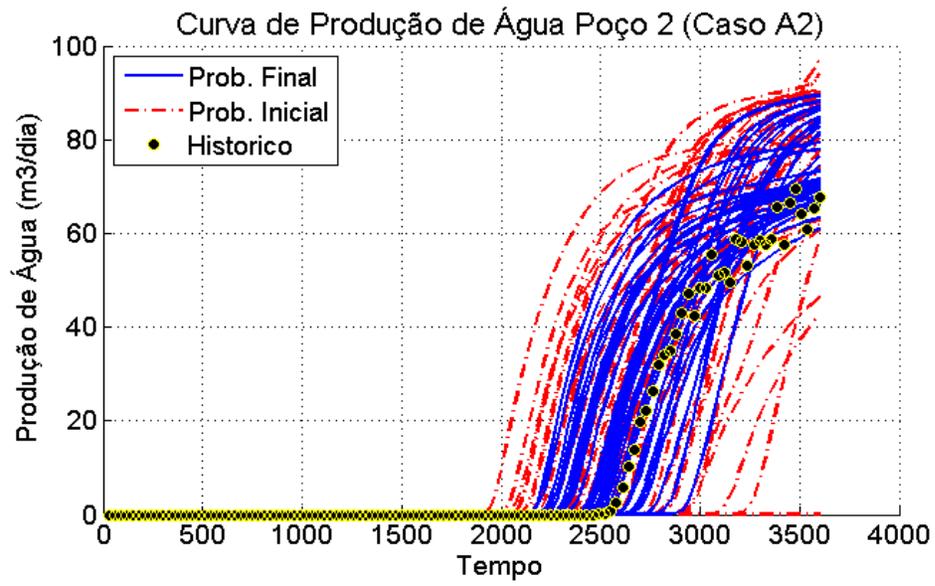


Figura 6.19 – Curvas de Produção dos Poços 2 e 4 (Caso A2).

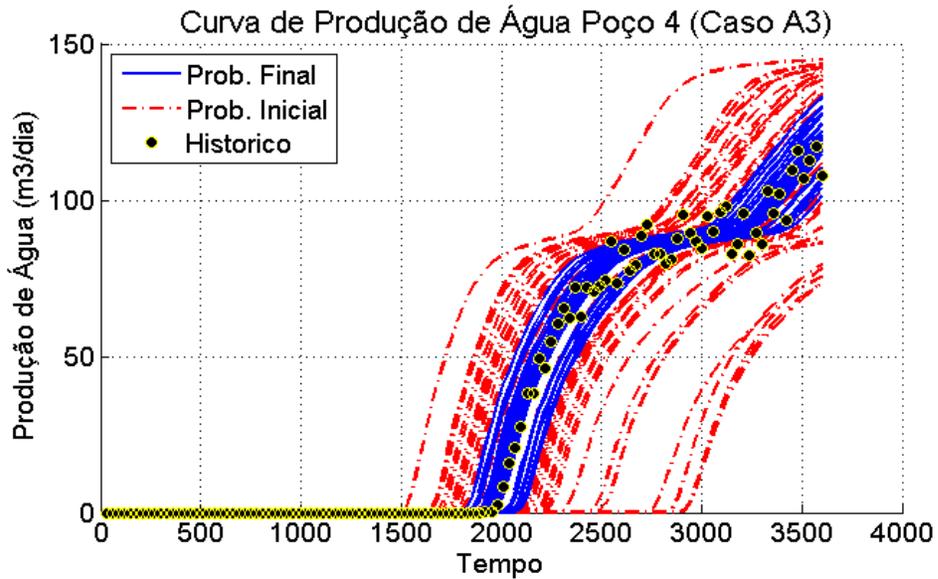
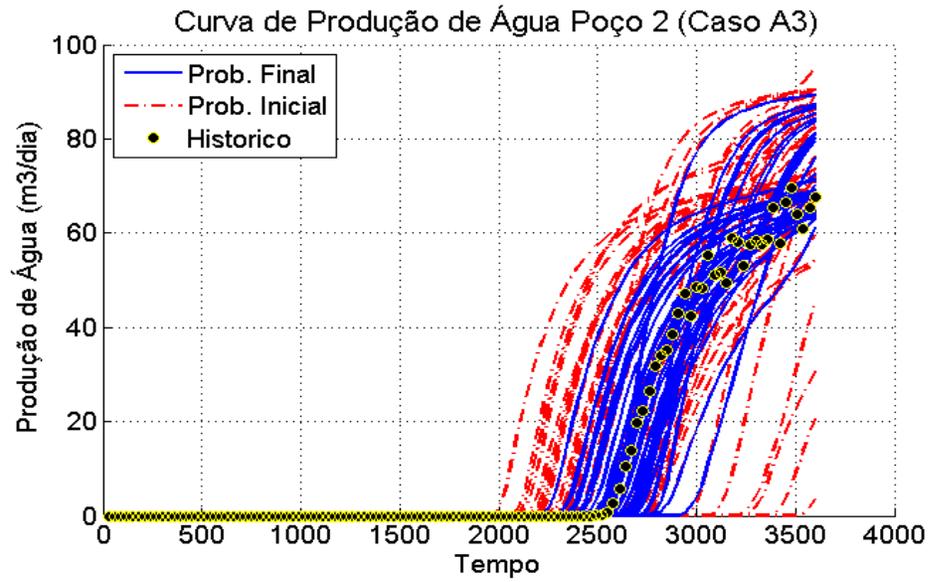


Figura 6.20 – Curvas de Produção dos Poços 2 e 4 (Caso A3).

## 6.2 Caso B – Modelo de Simulação Complexo

Na segunda secção deste capítulo o método de mitigação foi aplicado ao modelo de simulação complexo, Caso B, também descrito no Capítulo 5. Este caso foi utilizado para avaliar a aplicação desse método em um caso mais complexo. Foram avaliados 3 (três) subcasos (Caso

B1: 3 níveis; Caso B2: 5 níveis; e Caso B3: 7 níveis) e os resultados apresentados nos Itens 6.2.1, 6.2.2 e 6.2.3, respectivamente. Após apresentar o resultado para cada um dos subcasos citados, uma análise comparativa entre os resultados obtidos para o Caso B é realizada e apresentada no Item 6.2.4

### 6.2.1 Caso B1 – 3 níveis discretos

Os resultados obtidos para o Caso B1 podem ser observados a partir da Figura 6.21. Esses resultados são expressos em figuras de variabilidade das probabilidades, onde pode ser observada a quantidade de simulações que o processo de redistribuição de probabilidades utiliza até estabilizar.

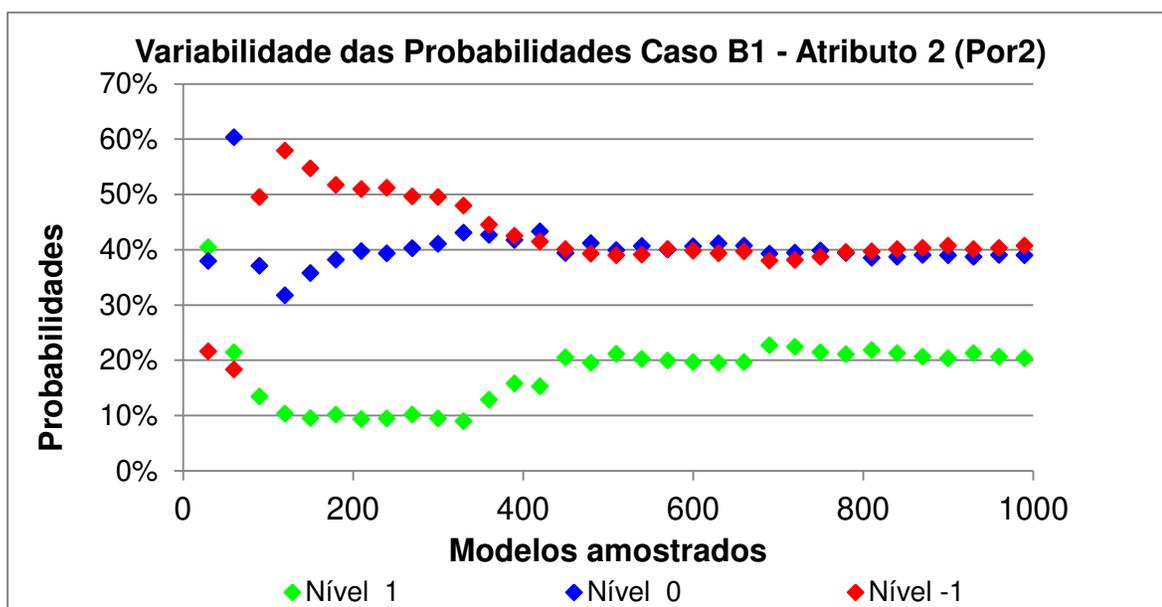


Figura 6.21 – Variabilidade das Probabilidades (Por2), Caso B1.

De acordo com a Figura 6.21 é possível verificar estabilidade nas probabilidades próximo a 500 simulações. Essa quantidade de simulações proporcionou variação muito pequena nas probabilidades da maioria dos atributos avaliados neste caso.

O atributo relativo à transmissibilidade da falha 4 (TF4) apresentou baixa variabilidade com um número bem reduzido de simulações, quando comparado aos demais, esse resultado pode ser

avaliado na Figura 6.22. Esta figura indica que o processo se estabiliza com aproximadamente 150 simulações, para esse atributo.

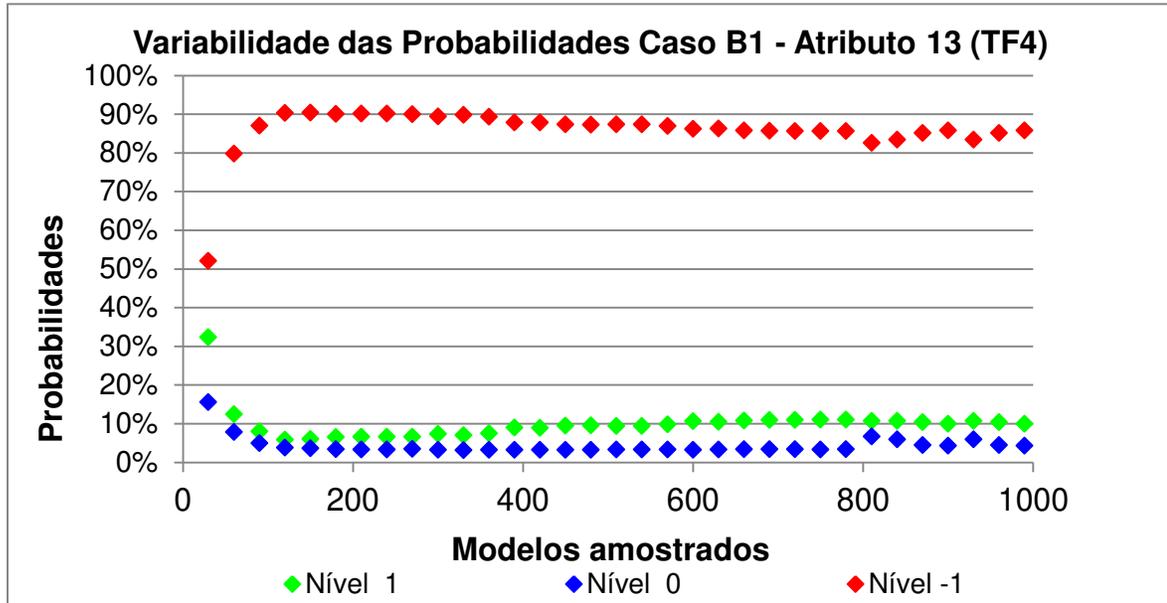


Figura 6.22 – Variabilidade das Probabilidades do atributo TF4, Caso B1.

A aplicação dessa metodologia apresentou um comportamento coerente com o esperado, uma vez que o valor desse atributo é muito próximo ao Nível -1 (inexistência de transmissibilidade). Entretanto, as simulações foram realizadas até que todos os atributos apresentassem resultados estáveis e as probabilidades finais obtidas.

Ao finalizar o processo de redistribuição de probabilidades foram gerados os gráficos de dispersão da *FO*, curva de incertezas (Figura 6.23) e resumo dos modelos representativos contidos nas curvas de incertezas, indicando a redução obtida com a aplicação do método proposto (Figura 6.24).

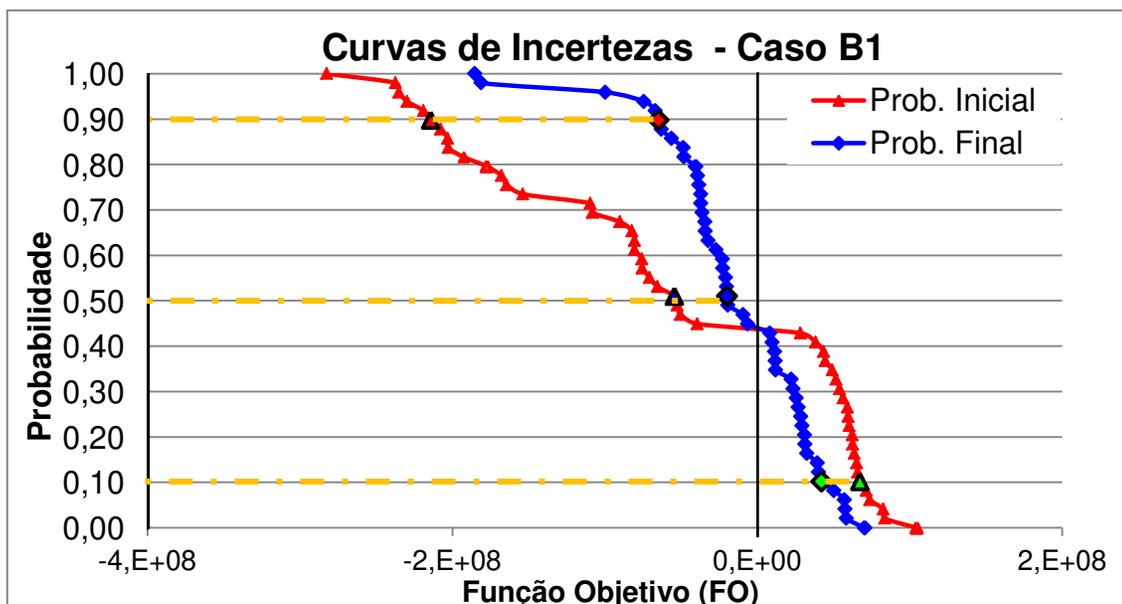


Figura 6.23 – Curva de Incertezas para o para 3 níveis.

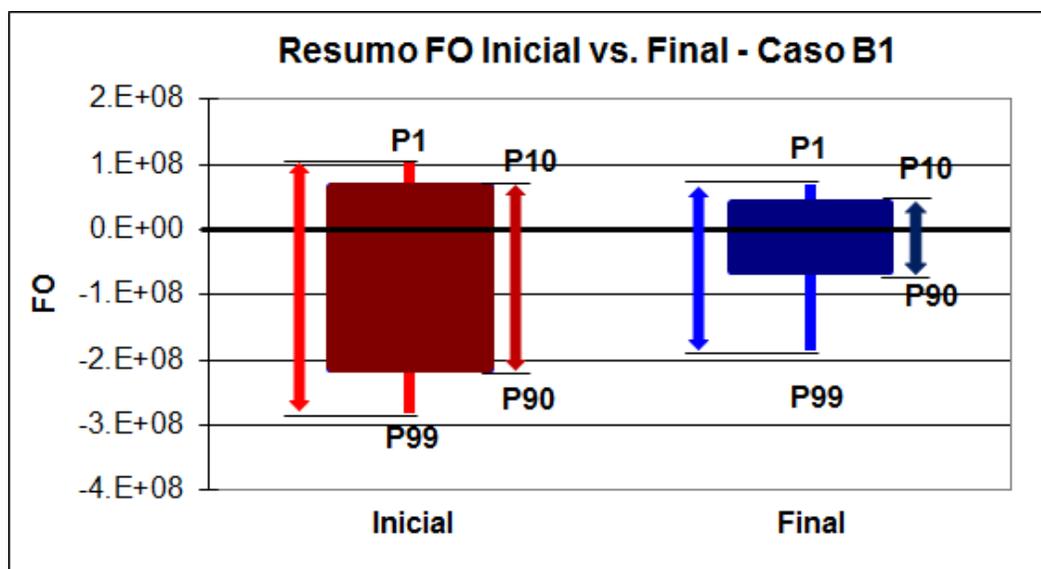


Figura 6.24 – Comparativo da FO antes e após a redução de incertezas (Caso B1).

Nos resultados apresentados nas Figura 6.23 e Figura 6.24 é possível verificar uma redução considerável na dispersão da FO dos modelos representativos das incertezas, para esse caso. Com a aplicação do método de redução de incertezas foi possível alcançar uma redução de aproximadamente 60% na FO final, em relação a inicial. A qualidade do ajuste final obtido, para

esse caso, pode ser avaliada também na Figura 6.25, que apresenta os afastamentos iniciais e finais para cada poço.

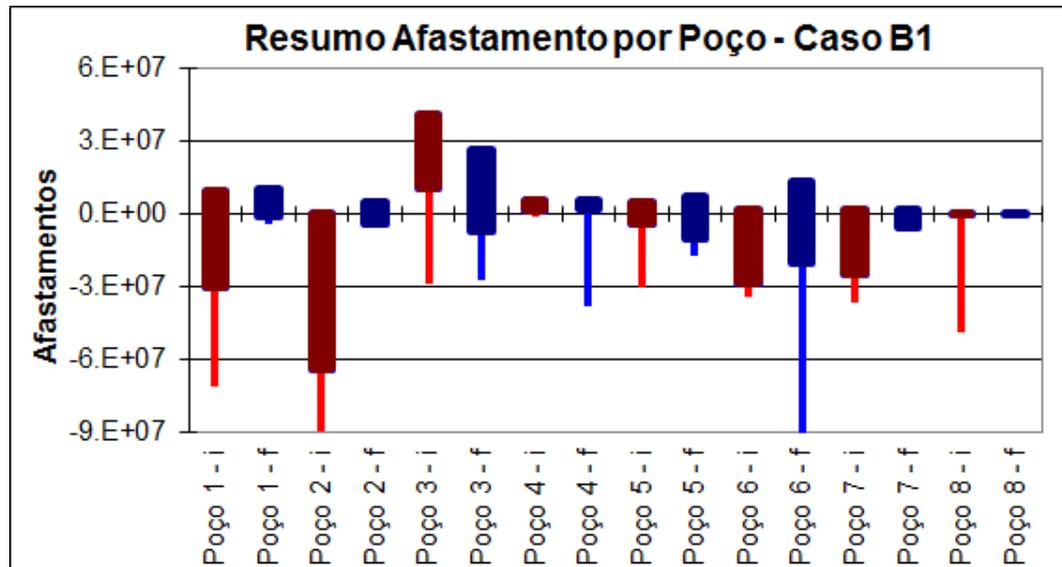


Figura 6.25 – Afastamento por poço (Caso B1).

Para esse caso mais complexo, é possível observar, na Figura 6.25, que os Poços 3 e 6 não apresenta redução significativa nos afastamentos finais, em relação aos afastamentos iniciais, porém há uma maior centralização em relação a indicação de ajuste “perfeito” (quando não há afastamento). Na mesma figura é possível verificar que há redução significativa nos afastamentos dos demais poços, levando a redução apresentada pela *FO* do campo.

### 6.2.2 Caso B2 – 5 níveis discretos

Foi possível observar, no Caso B2, que o método de mitigação de incertezas também apresentou resultados dentro do esperado. As probabilidades da maioria dos atributos considerados apresentaram estabilidade próxima a 600 simulações (Figura 6.26), quantidade de simulações semelhantes às utilizadas no subcaso anterior.

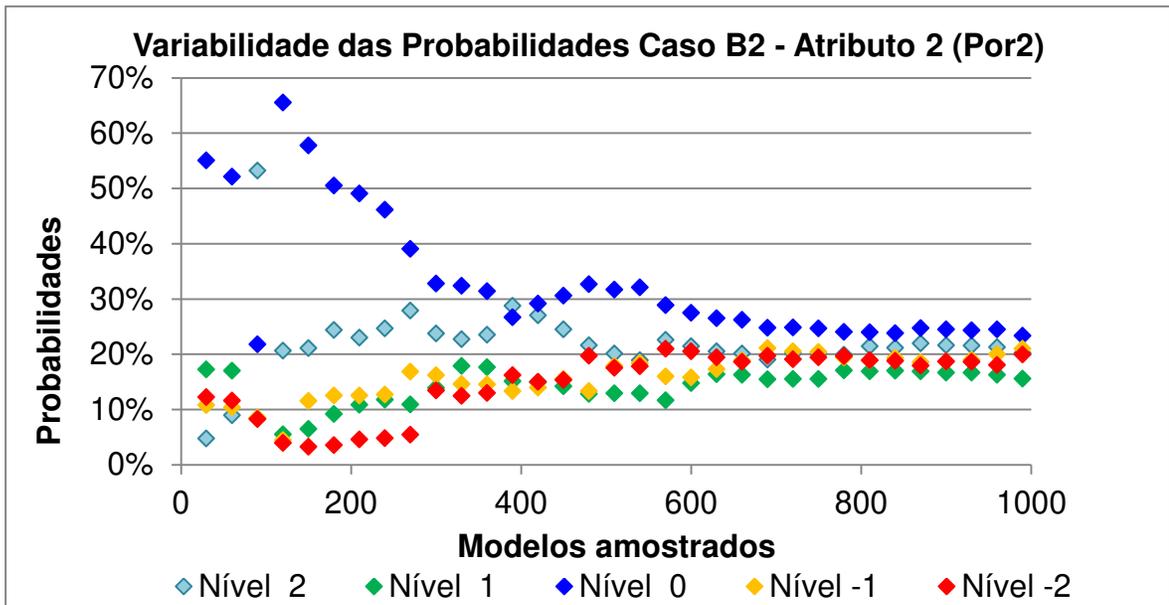


Figura 6.26 – Variabilidade das Probabilidades (Por2), Caso B2.

Na maioria dos atributos houve um aumento nas probabilidades dos níveis mais próximos aos valores reais, porém, em alguns casos destacaram-se os níveis imediatamente próximos aos níveis cujos valores mais se aproximam dos reais. Na Figura 6.27 os resultados indicam maior probabilidade para o Nível 1, entretanto o nível com o valor mais próximo do real é o Nível 0.

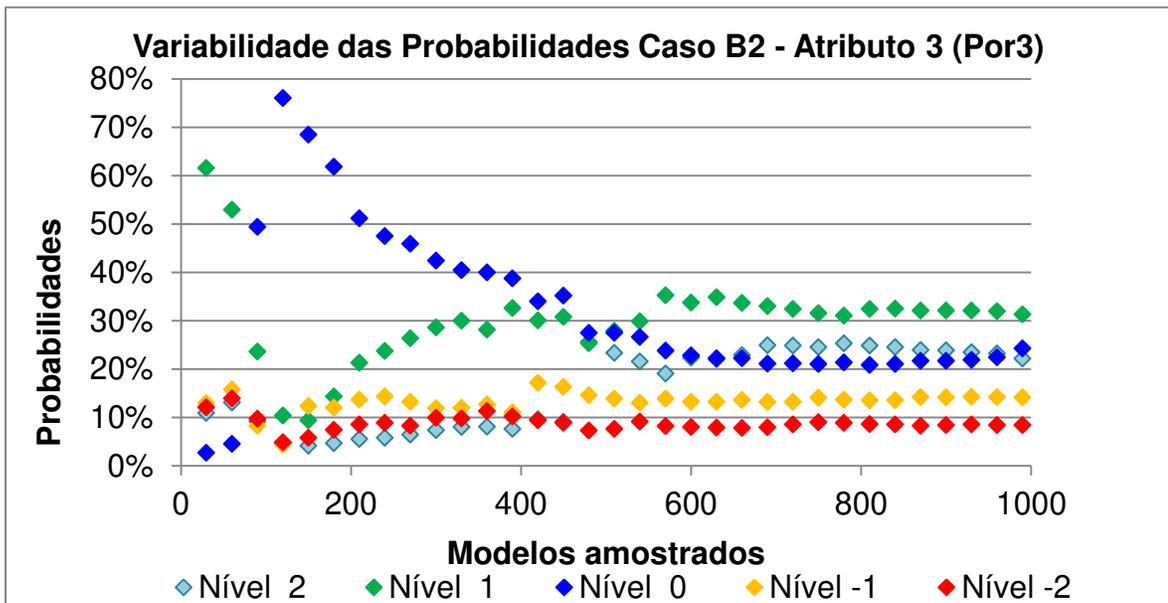


Figura 6.27 – Variabilidade das Probabilidades (Por3), Caso B2.

A exemplo do que ocorreu no Caso B1, o atributo TF4 (transmissibilidade da falha) apresentou estabilidade no processo de redistribuição de probabilidades com uma quantidade muito pequena de simulações, quando comparado aos demais atributos (Figura 6.28).

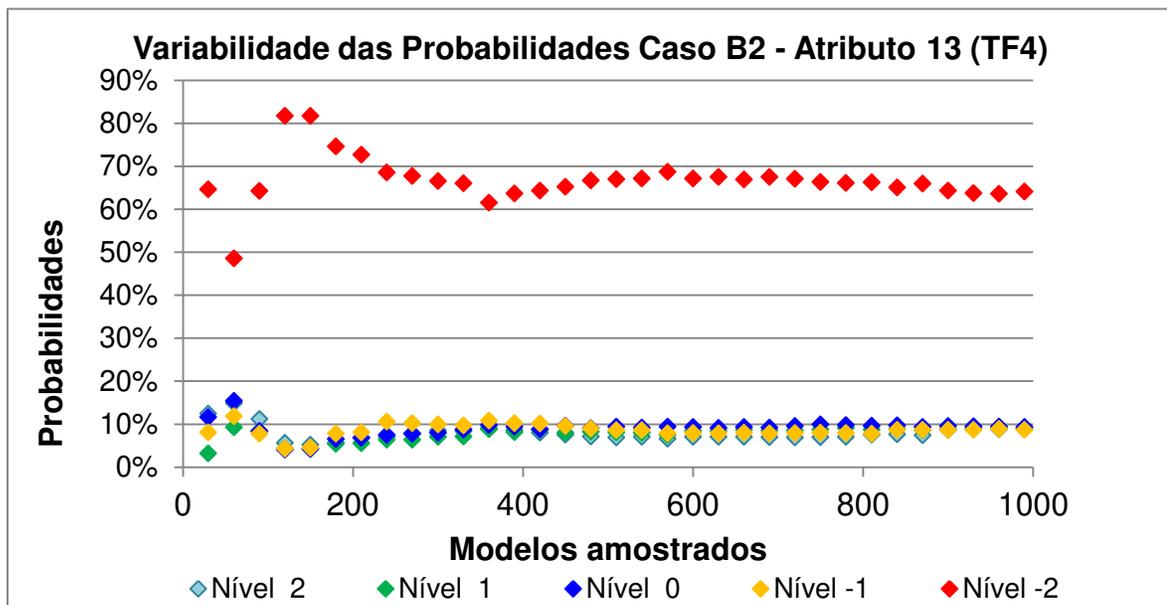


Figura 6.28 – Variabilidade das Probabilidades de Kx1 (Caso A2).

Na Figura 6.28, é possível verificar que o Nível -2 tem sua probabilidade ampliada logo nas primeiras simulações e com pouco mais de 200 simulações o processo se estabiliza para esse atributo. Neste caso os demais níveis são praticamente anulados, abrindo a possibilidade de fixar esse atributo para análises futuras.

A partir das probabilidades finais obtidas para cada atributo, são geradas as curvas de incertezas (inicial e final), de onde são selecionados os modelos representativos da dispersão da FO para compor o gráfico com o resumo da FO (tipo “bastão”), apresentado na Figura 6.29.

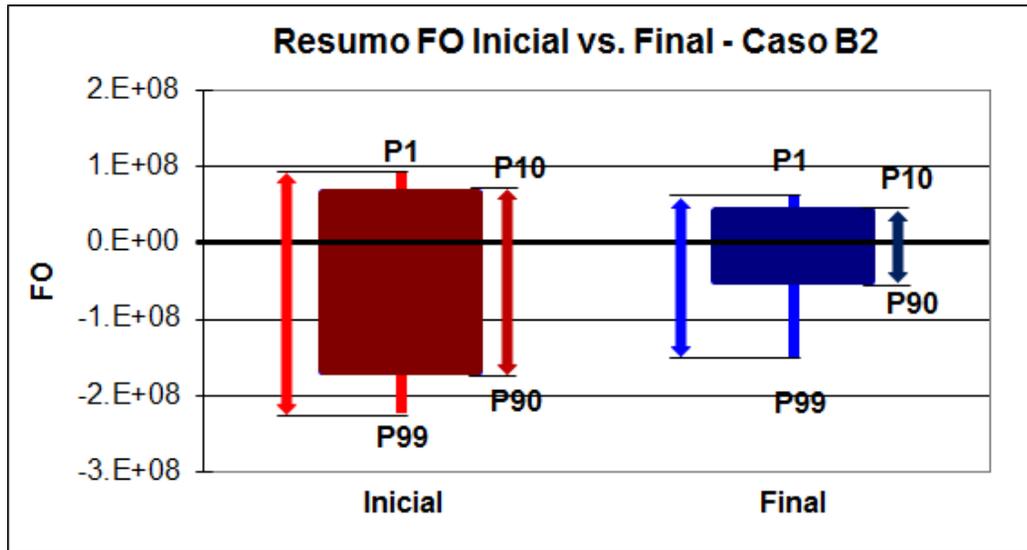


Figura 6.29 – Comparativo da *FO* antes e após a redução de incertezas (Caso B2).

Neste caso é possível verificar uma redução também de aproximadamente 60%, na dispersão final da *FO*, em relação à dispersão inicial. Esse resultado indica que o método de redução de incertezas apresentou um bom desempenho, também para esse caso. A qualidade do desempenho desse método pode também ser avaliada na Figura 6.30, onde são apresentados os afastamentos de cada poço (antes e após a aplicação da metodologia).

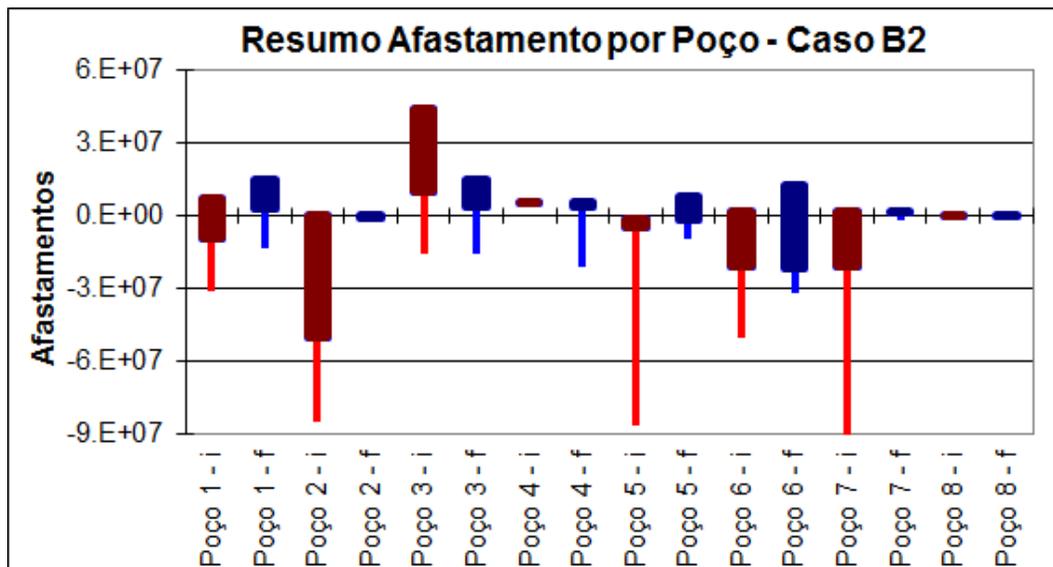


Figura 6.30 – Afastamento por poço (Caso B2).

Os afastamentos dos poços obtidos no Caso B2 (Figura 6.30) apresentam uma redução para quase todos os poços, exceto Poço 4 e Poço 6 os quais apresentaram um aumento no afastamento, porém uma dispersão mais proporcional em relação ao eixo horizontal. É possível observar também uma redução nos afastamentos dos demais poços.

### 6.2.3 Caso B3 – 7 níveis discretos

O Caso B3 representa a situação mais complexa ao qual o método proposto foi submetido, cada atributo possui 7 níveis discretos. Os resultados obtidos também apresentaram comportamento dentro do esperado. Para esse caso foram necessárias aproximadamente 800 simulações para que as probabilidades dos atributos apresentassem valores estáveis. A Figura 6.31 apresenta a variabilidade das probabilidades obtidas para o atributo Por2.

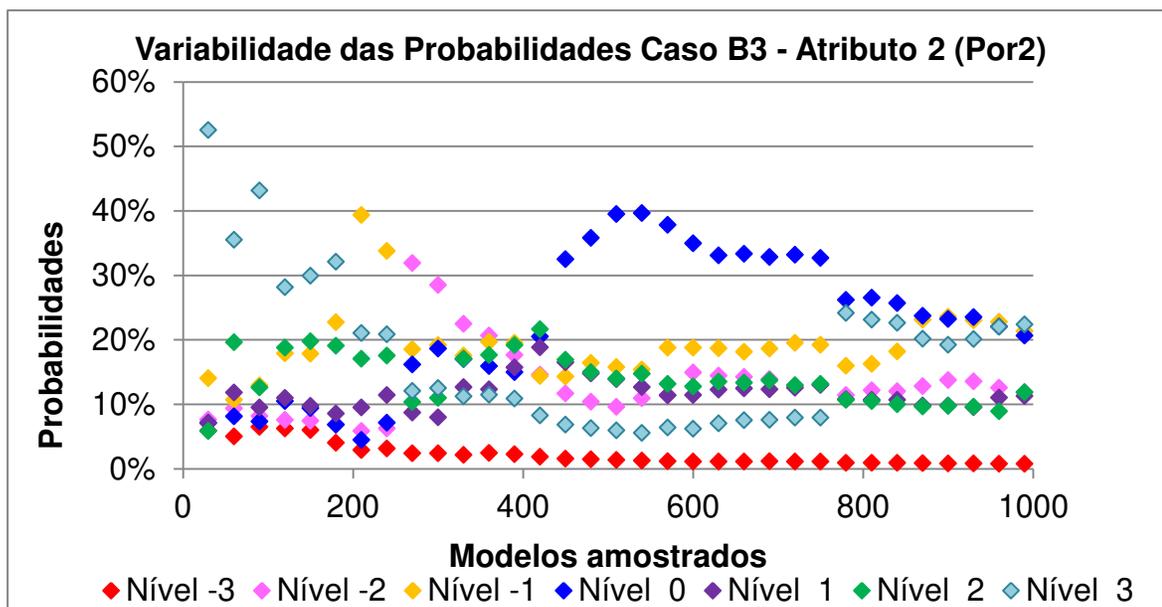


Figura 6.31 – Variabilidade das Probabilidades (Por2), Caso B3.

Alguns níveis dos atributos considerados apresentaram comportamento instável ao longo de quase todo processo, estabilizando próximo a 800 simulações. A Figura 6.32 apresenta a variabilidade das probabilidades do atributo “Kx1” que também apresenta um comportamento estável a partir de 800 simulações

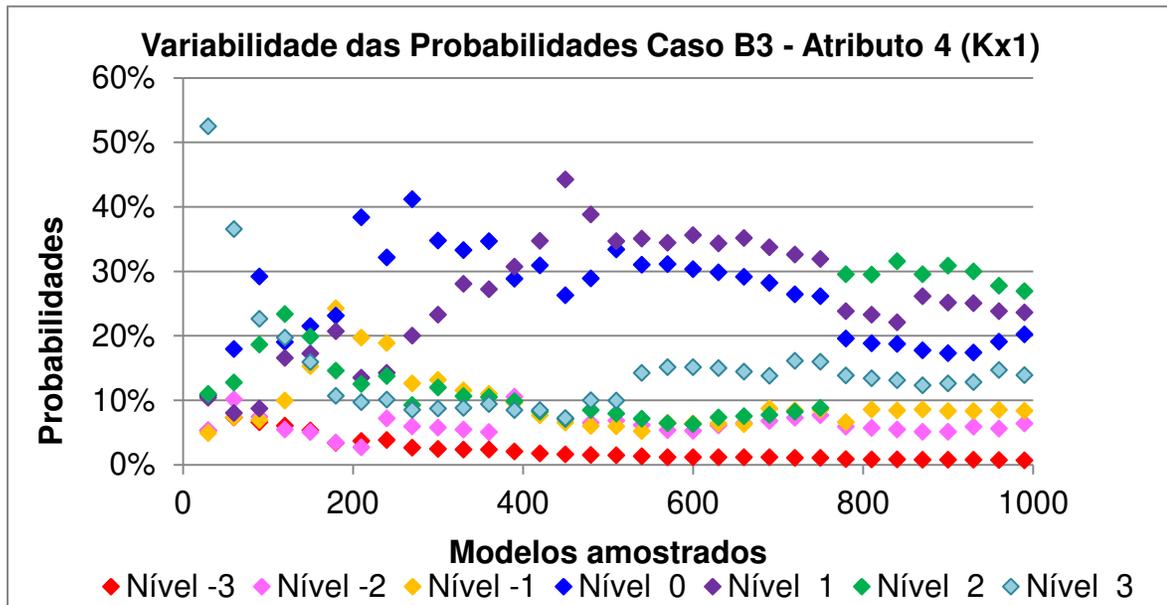


Figura 6.32 – Variabilidade das Probabilidades (Kx1), Caso B3.

Ao contrário do que ocorreu com a maioria dos atributos considerados, mais uma vez o atributo TF4 (transmissibilidade da falha) apresentou estabilidade no processo de redistribuição de probabilidades com uma quantidade de simulações bastante inferior aos demais atributos. A variabilidade da probabilidade desse atributo pode ser observada na Figura 6.33.

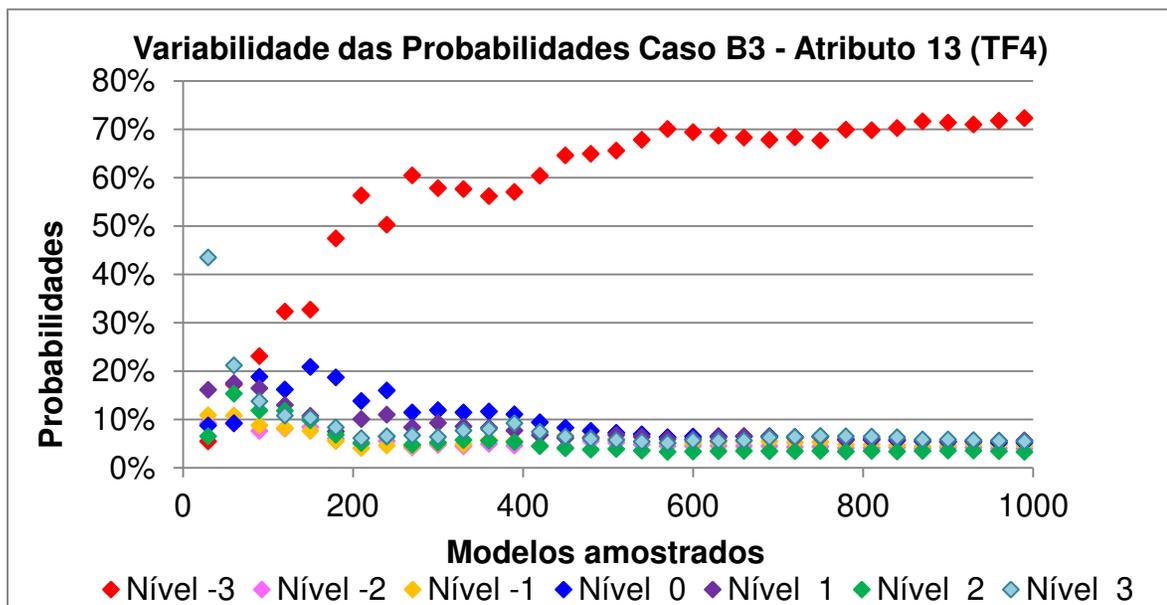


Figura 6.33 – Variabilidade das Probabilidades de TF4 (Caso B3).

As probabilidades estimadas para o atributo TF4 destacaram Nível -3 ao longo de todo o processo, aumentando cada vez mais com o aumento no número de simulações, enquanto os demais níveis assumiram valores muito baixos, quase nulos.

Novamente após a obtenção das probabilidades finais para os atributos avaliados, foram geradas as curvas de incertezas e, em seguida, os gráficos que representam a dispersão resumida da *FO* dos modelos representativos e redução de incertezas (P<sub>99</sub>, P<sub>90</sub>, P<sub>10</sub> E P<sub>1</sub>), para o Caso B3 (Figura 6.34).

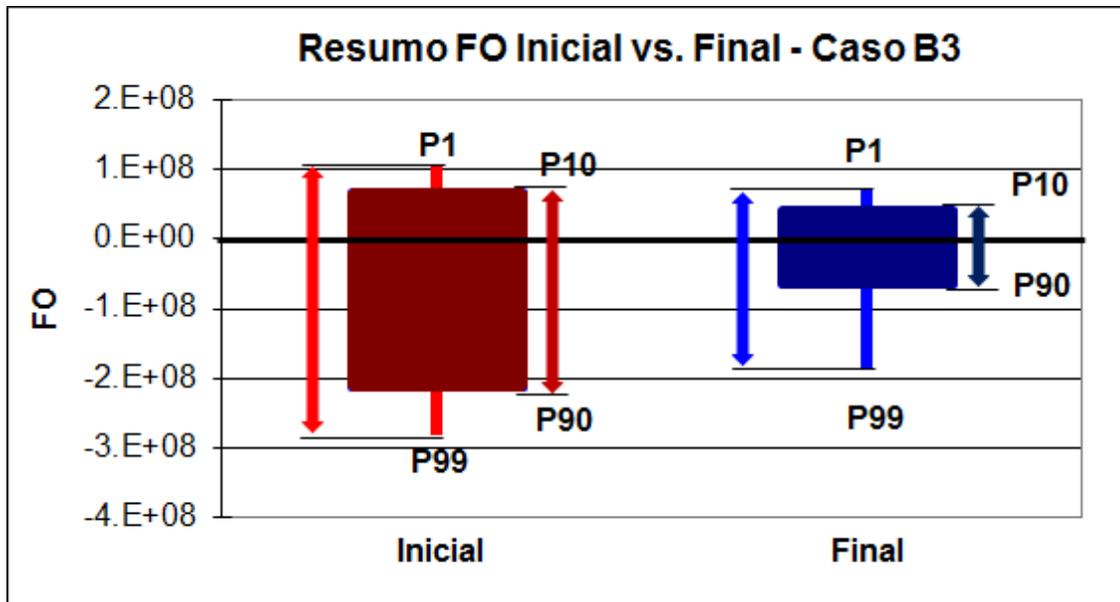


Figura 6.34 – Comparativo da *FO* antes e após a redução de incertezas (Caso B3).

Na Figura 6.34 é possível observar que há uma redução significativa na dispersão da *FO* dos modelos representativos das incertezas (aproximadamente 65%), bem como maior centralização na dispersão da *FO* em relação ao ajuste “perfeito”, ou, uma distribuição mais proporcional dos valores superior e inferior a “0” (zero). Finalmente, a qualidade final dos resultados obtidos para o Caso B3 pode ser avaliada a partir da Figura 6.35, que apresenta os afastamentos para cada um dos poços, antes e após a aplicação da metodologia de mitigação de incertezas proposta.

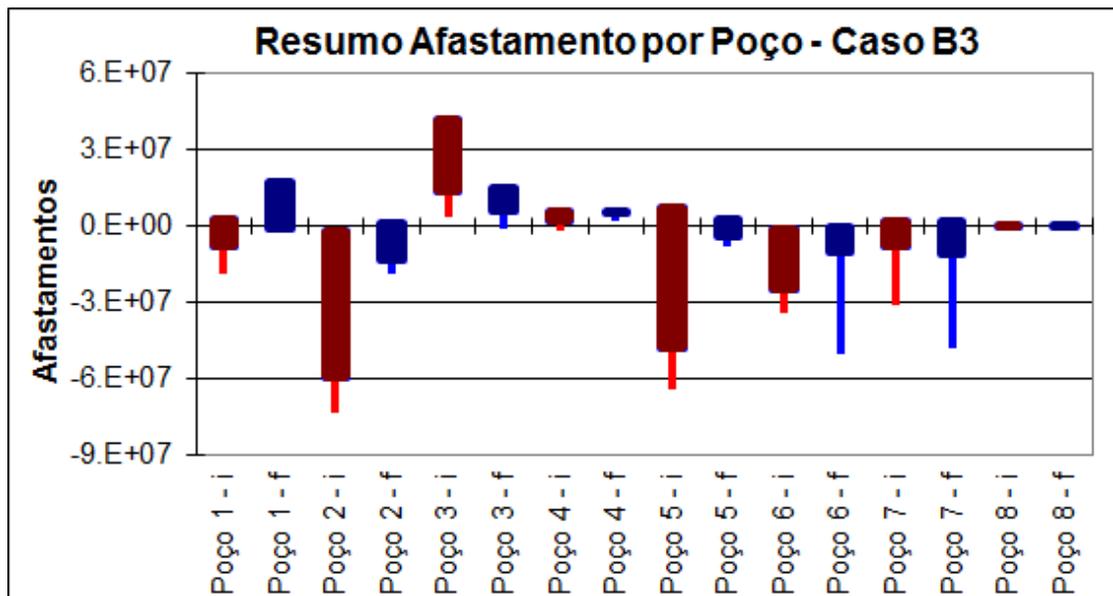


Figura 6.35 – Afastamento por poço (Caso B3).

O que pode ser observado Figura 6.35 é que os resultados obtidos com a metodologia de redução de incertezas, para o Caso B3, com 7 níveis discretos, proporcionaram também uma redução nos afastamentos de praticamente todos os poços. Com uma análise desses afastamentos é possível verificar que o método proporciona um melhor ajuste global, a partir de um melhor ajuste local de cada poço.

#### 6.2.4 Análise Comparativa dos Resultados do Caso B

Com os resultados de todos os “subcasos” (Casos B1, B2 e B3), analisados no Caso B, realizada é possível realizar uma análise comparativa entre os resultados obtidos. Um resumo geral da *FO* dos modelos representativos das incertezas ( $P_{99}$ ,  $P_{90}$ ,  $P_{10}$  e  $P_1$ ), proveniente das curvas de incertezas inicial e final, de cada um dos “subcasos” é apresentado na Figura 6.36, todos para 800 simulações.

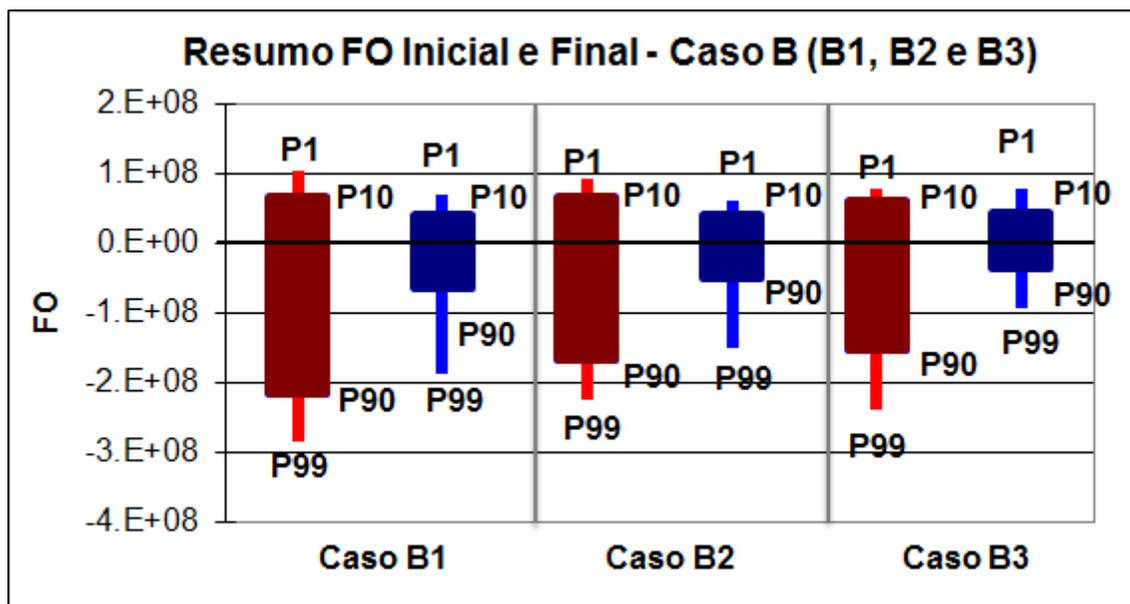


Figura 6.36 – Resumo *FO* inicial e final dos modelos representativos das incertezas dos Caso B1, B2 e B3 para 800 simulações.

Ao analisar cada “subcaso” separadamente, cada um deles apresenta uma redução de aproximadamente 60% na *FO* final, em relação a inicial. Uma comparação entre a *FO* do Caso B1, Caso B2 e Caso B3 não apresenta ganho significativo, na redução final, entretanto, ao analisar os gráficos de afastamento por poço é possível verificar que há uma redução maior nos subcasos que apresentam maior quantidade de níveis discretos.

As curvas de produção por poços também representam a dispersão dos modelos de simulação em relação aos dados de produção observados. Foram plotadas as curvas de produção de água inicial (vermelho) e final (azul) dos Poços 4 e 7, dos modelos compreendidos entre  $P_{90}$  e  $P_{10}$ , nas Figura 6.37 e Figura 6.38 (para os casos Caso B1 e Caso B2, respectivamente) e todas as curvas do Caso B3, na Figura 6.39, Figura 6.40 e Figura 6.41. É possível observar na Figura 6.37 que não uma redução significativa no afastamento das curvas de produção do Poço 4, em relação ao histórico, porém nessa mesma figura é possível notar uma grande redução nas curvas de produção do Poço 7.

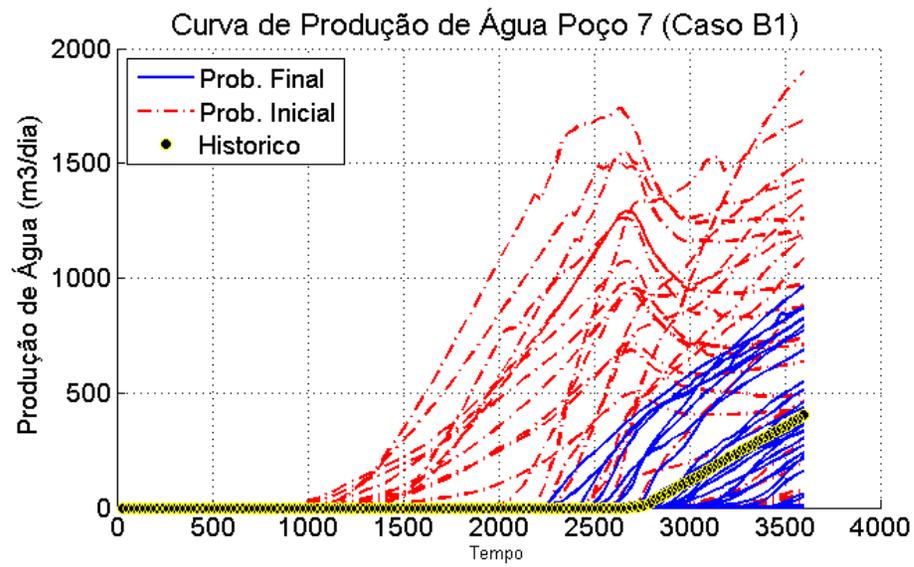
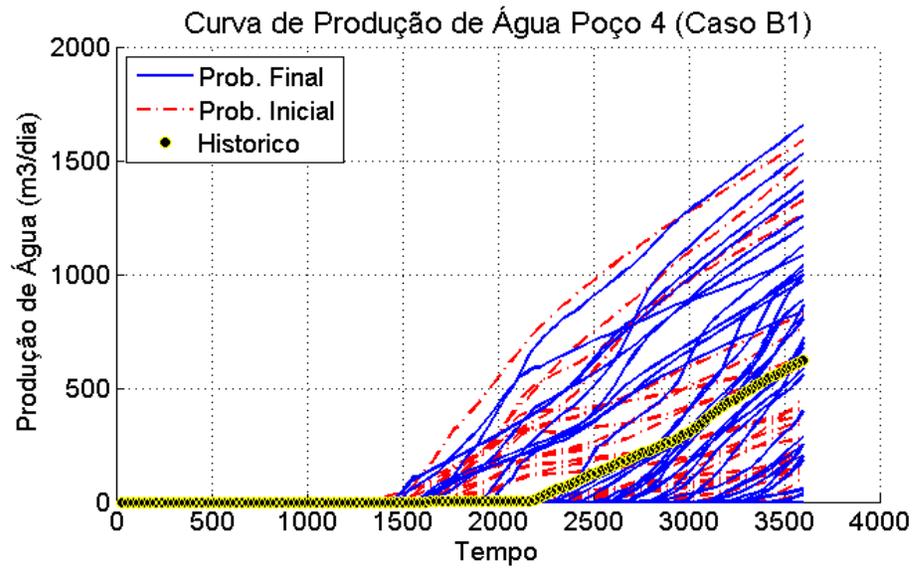


Figura 6.37 – Curvas de Produção dos Poços 4 e 7 (Caso B1).

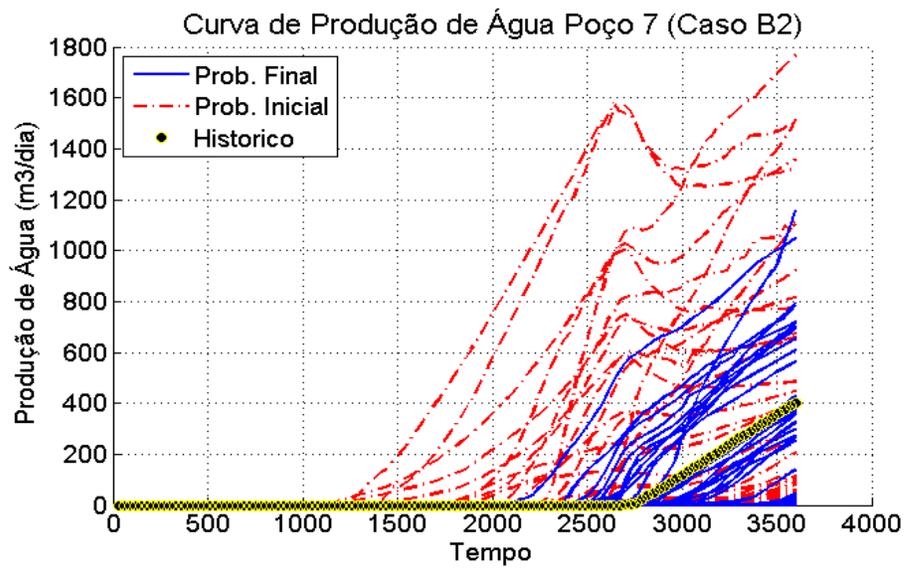
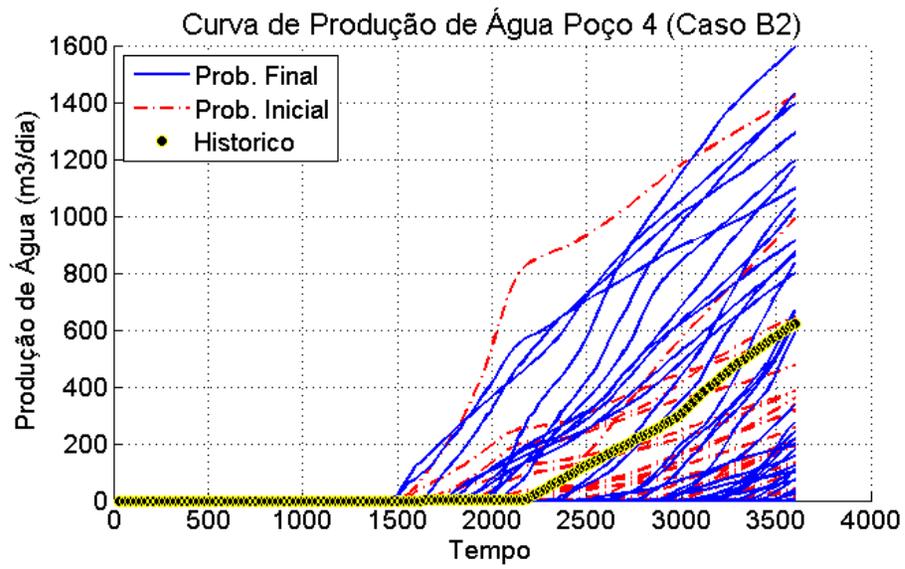


Figura 6.38 – Curvas de Produção dos Poços 4 e 7 (Caso B2).

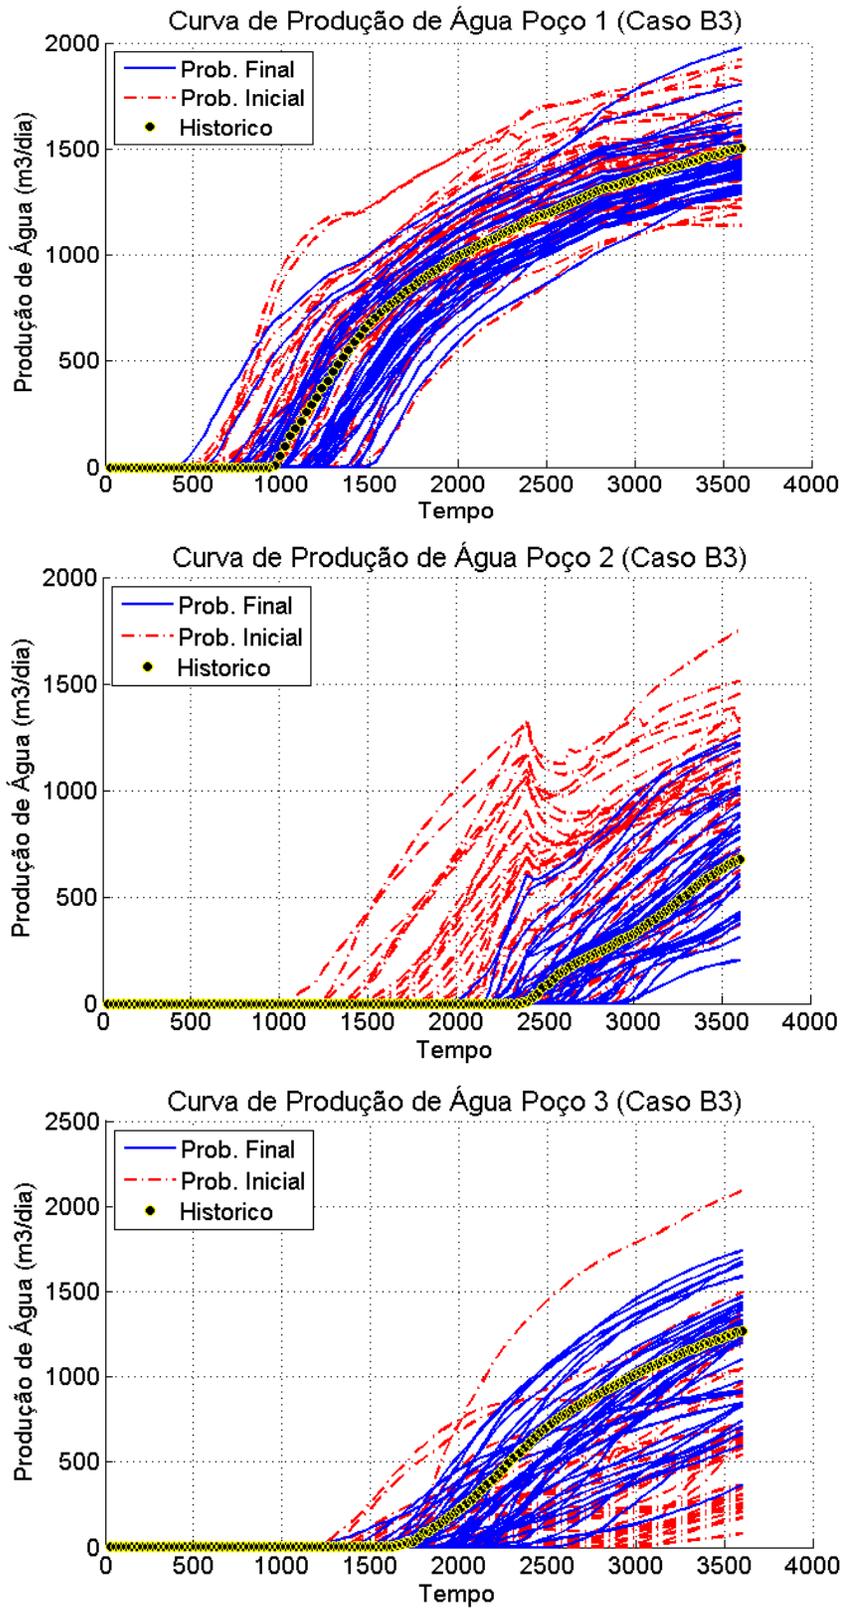


Figura 6.39 – Curvas de Produção dos Poços 1 a 3 (Caso B3).

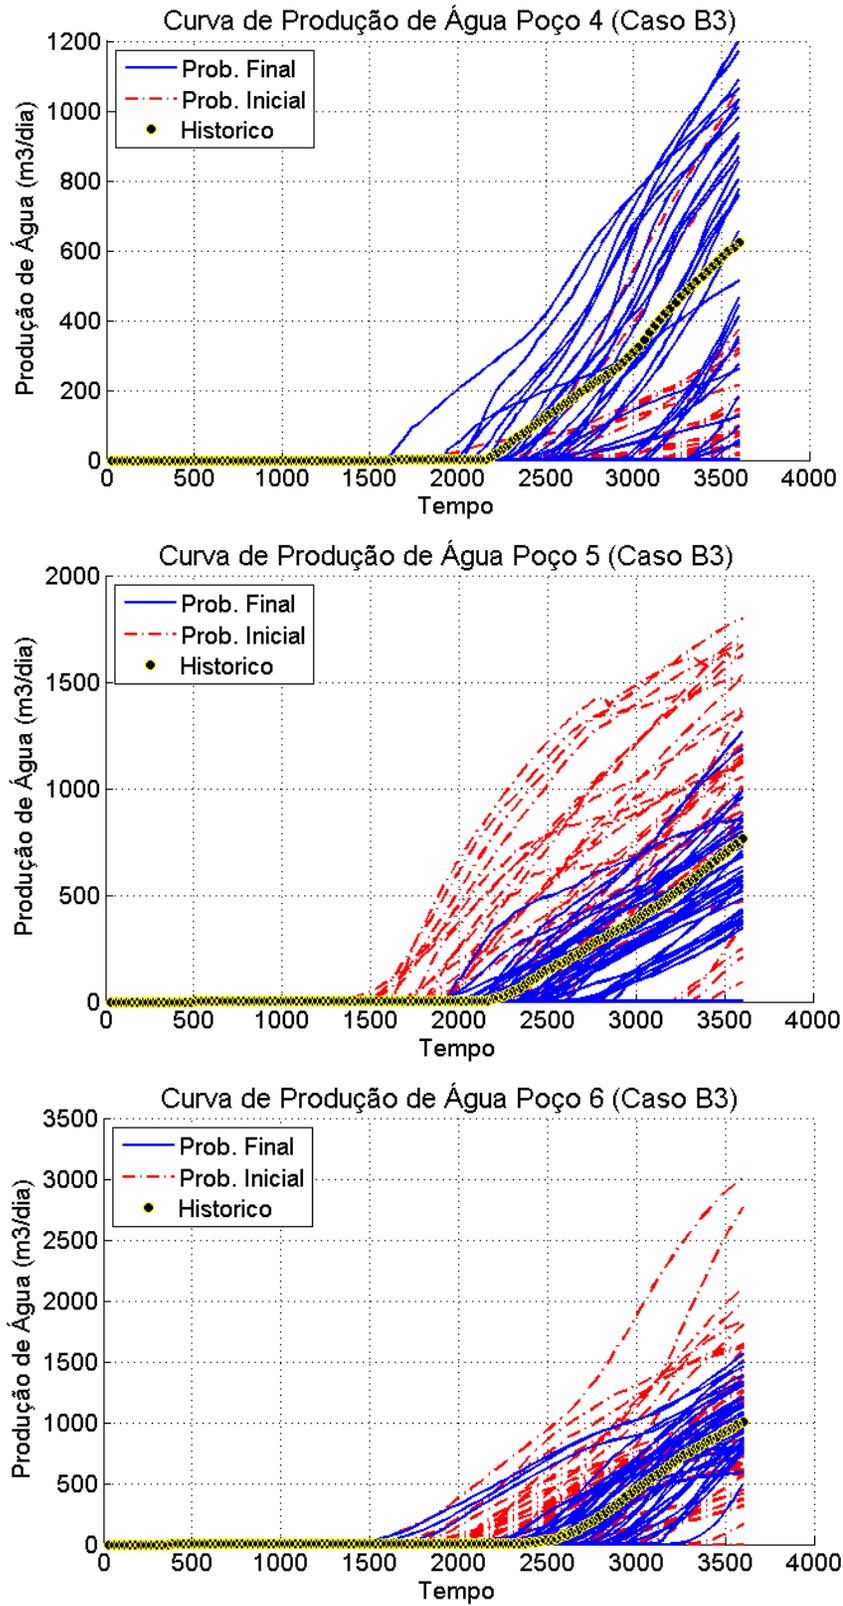


Figura 6.40 – Curvas de Produção dos Poços 4 a 6 (Caso B3).

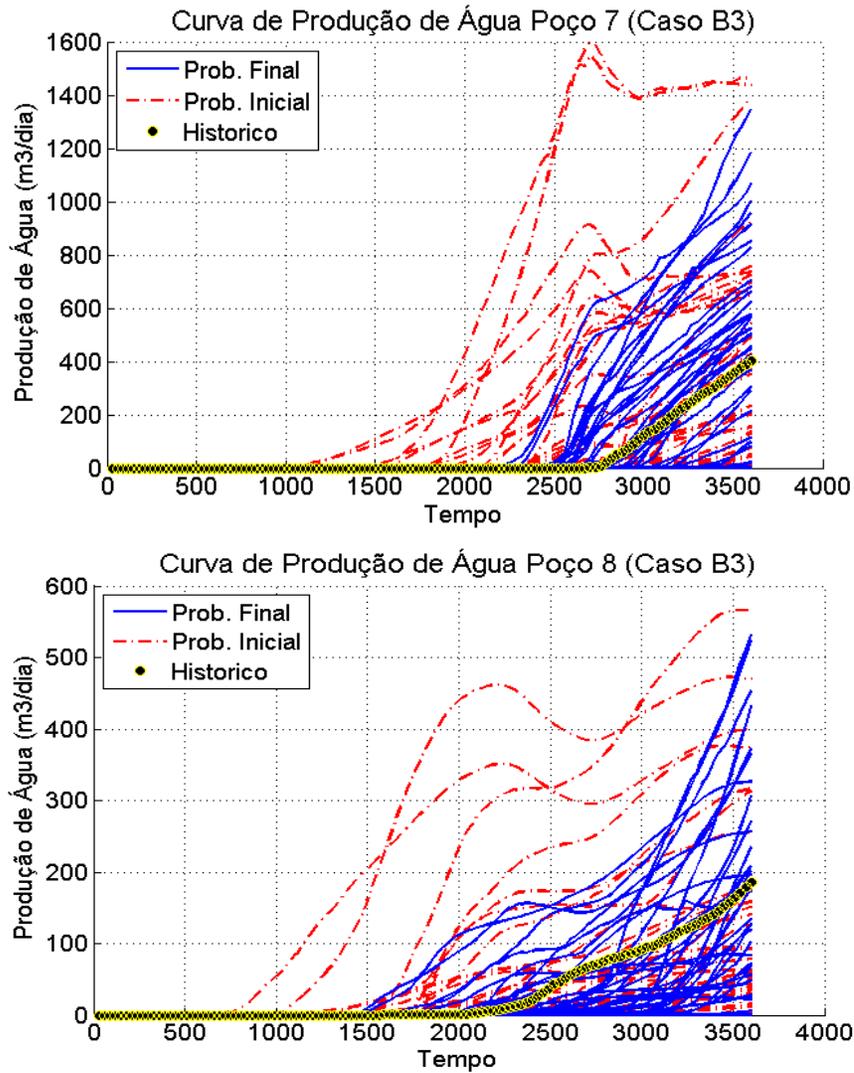


Figura 6.41 – Curvas de Produção dos Poços 7 e 8 (Caso B3).

### 6.3 Discussões

Com os resultados apresentados, é possível observar que o aumento no número de níveis, proporciona maior redução na faixa de incertezas e maior ajuste dos poços, para ambos os casos estudados. Contudo, é importante destacar que há também um aumento no número de simulações, porém pequeno quando comparado à técnica de árvore de derivação, por exemplo.

Nos casos em que os poços apresentaram pouca redução no afastamento, como o Poço 2 no Caso A e o Poço 4 no Caso B, uma análise de sensibilidade local pode avaliar o impacto dos

atributos considerados sobre esses poços, que não apresentaram ganho significativo. E posteriormente considerar a avaliação de atributos locais para esses poços, tendo em vista que nesse trabalho não foram considerados atributos locais. Ressalta-se que com a metodologia apresentada, novos atributos podem ser incluídos ao longo do processo.

Um fator que deve sempre ser analisado é o dimensionamento da quantidade mínima de modelos que devem ser amostrados ( $Ma_{\min}$ ), para os casos estudados foram adotados valores fixos para os diferentes casos e quantidade de níveis discretos (Caso A: 200 simulações e Caso B: 300 simulações). Para os casos com 3 e 5 níveis discretos esses valores foram suficientes para evitar distorções nos resultados, como anulação precoce de níveis (problema que ocorreu no início do trabalho mas foi solucionado com a metodologia proposta). Todavia, para ambos os casos com 7 níveis, esses valores foram insuficientes pois houve grande redução das probabilidades de alguns níveis com um número ainda reduzido de simulações. Este problema pode ser resolvido com a análise dinâmica proposta e a mudança gradual da probabilidade a medida que os pontos sorteados são simulados (até a estabilização).

Foram obtidos bons resultados para todos os casos avaliados, uma vez que foram obtidos modelos de simulação ajustados e houve redução nas incertezas a partir de um número reduzido de simulações.

## 7. CONCLUSÃO E RECOMENDAÇÕES

Este capítulo é composto pelas conclusões e recomendações do estudo apresentado neste trabalho. As conclusões gerais e específicas mais relevantes são citadas no Item 7.1 e 7.2 deste capítulo, e os assuntos que devem ser pesquisados como forma de complementar esta metodologia, descritos no Item 7.3. Essa dissertação propôs aprimorar uma metodologia de mitigação de incertezas, baseada na integração de técnicas de análise de incertezas, dados de histórico e técnicas de amostragem. Esse estudo apresenta como resultado um ajuste probabilístico a partir da redução das incertezas dos atributos considerados.

### 7.1 Conclusões Gerais

- Os resultados obtidos a partir da metodologia descrita nesse trabalho indicam avanços na metodologia dentro dos objetivos estabelecidos na proposta inicial. O método de mitigação de incertezas proposto (através da integração de técnicas de análise de incertezas, ajuste de histórico e técnicas de amostragem) apresentou algumas vantagens em relação aos principais métodos de referência.
- Para todos os casos foram obtidos ajustes probabilísticos a partir da redução das incertezas dos atributos considerados e um número reduzido de simulações, quando comparado à quantidade de simulações necessárias com a técnica de árvore de derivação. Foi proposta também uma nova forma de análise de resultados através de gráficos tipo “barra”, curvas de incertezas e gráficos tipo “bastão” para representar o resumo da dispersão da *FO* e os afastamentos por poço o que não só facilita a análise dos resultados, mas permite a automatização das tarefas.

## 7.2 Conclusões Específicas

- Os ajustes obtidos para cada caso avaliado possibilitam afirmar que esse método proporciona um bom balanceamento entre o ajuste global e o ajuste local de poços. Foram obtidas reduções nos afastamentos por poço e isso possibilitou uma maior redução no ajuste global do campo.
- A aplicação do método de Hipercubo Latino, na amostragem dos níveis discretos dos atributos considerados, associada ao procedimento de redistribuição gradativa de probabilidade, proposto nesse estudo, possibilitou uma convergência mais rápida ao resultado, valores conhecidos e estabilidade nas novas probabilidades, quando comparado ao método apresentado por Maschio *et al.* (2010) para o Caso A1 e para o Caso B1.
- A introdução de um procedimento que possibilita uma redistribuição gradativa de probabilidades reduziu a possibilidade da anulação precoce de alguns níveis discretos (problema que pode ocorrer se poucos pontos forem sorteados). Contudo, foi possível observar que, nas condições consideradas no Caso A3 ( $Ma_{\min} = 200$  simulações), não impossibilitou essa anulação precoce do Nível -2 do Atributo 3 (Kx3), por exemplo. Por isso, deve sempre ser avaliada a quantidade mínima de simulações a ser considerada, de modo a evitar essa anulação.
- A utilização de um método para medir a variabilidade das probabilidades dos atributos incertos considerados, utilizada com critério de parada, e o indicador de ajuste por poço, torna essa metodologia menos subjetiva. Esses indicadores possibilitam uma análise nos ajustes obtidos por poço a partir da redução das incertezas dos atributos considerados. O indicador de variabilidade das probabilidades foi utilizado para avaliar a quantidade de simulações necessárias para que as novas probabilidades estabilizem e o método, de redistribuição de probabilidades, seja finalizando.
- Com a aplicação do método de redução de incertezas em casos cujos atributos incertos possuem uma quantidade maior de níveis discretos (normalmente utilizam-se 3 níveis) foi possível observar maior qualidade nos resultados (maior redução de incertezas e modelos mais ajustados). Entretanto, dois fatores devem ser considerados:

- A discretização dos atributos em uma quantidade elevada de níveis pode levar a níveis com valores muito próximos, dificultando o método de redistribuição de probabilidades; e
- Uma maior quantidade de níveis implica em um aumento significativo no número de combinações possíveis, deve sempre ser considerada a possibilidade de aumentar a quantidade de simulações mínimas ( $Ma_{min}$ ) e, conseqüentemente, o aumento no esforço computacional (mesmo que pequeno).
- Por fim, a metodologia é flexível e permite que os objetivos do estudo, o grau de precisão desejado de resultados e número possível de simulações sejam considerados como parâmetros de controle para o tipo de análise que será efetuado em cada caso específico.

### 7.3 Recomendações

Alguns temas que surgiram e não puderam ser abordados no decorrer do desenvolvimento desta dissertação são mencionados a seguir e recomendados para ser avaliados em trabalhos futuros:

- Na metodologia proposta neste trabalho dois casos sintéticos, de complexidades distintas, são utilizados como forma de validá-la e apresentá-la. Recomenda-se a aplicação desse método em um caso real, como forma de avaliar essa metodologia em outros casos, mais complexos;
- A metodologia permite, a qualquer momento, que novos atributos sejam acrescentados para melhorar o ajuste local. Isso pode ser testado em modelos com problemas de ajustes locais em poços.
- Deve ser considerada a possibilidade de que pelo menos uma amostra de cada um dos níveis seja realizada ao longo de todo processo de amostragem, de modo a prevenir a anulações de níveis ao logo do processo de redistribuição de probabilidades;
- Nesse trabalho a quantidade mínima de modelos amostrados é estabelecida no início do processo de redistribuição de probabilidade. A criação de critérios para definir essa quantidade mínima de modelos ( $Ma_{min}$ ) deve ser considerada;

- O peso atribuído a cada nível (fator  $F$ ) utilizado nesse trabalho foi definido a partir do estudo apresentado por Maschio *et al.* (2010). Recomenda-se um estudo para definir o peso atribuído a cada nível (fato  $F$ ) para cada caso específico.

## REFERÊNCIAS BIBLIOGRÁFICAS

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

ALVARADO, M. G., **Quantification of Uncertainty During History Matching**. Texas A&M University, Texas, 2003. 46 p. Dissertação (Mestrado).

ALVARADO, M. G.; McVay, D. A.; LEE, W. J., **Quantification of Uncertainty by Combining Forecasting With History Matching**. Journal of Petroleum Science and Technology, vol. 23, nº 3 – 4, p. 445 – 462, 2005.

ARPAT, B. G., **Sequential Simulation with Patterns**. Stanford: Stanford University, 2005. 166p. Tese (Doutorado).

BALLIN, P. R.; AZIZ, K.; JOURNEL, A. G., **Quantifying the Impact of Geological Uncertainty on Reservoir Performing**. SPE 25238, Symposium on Reservoir Simulation (RSS), New Orleans, Louisiana, 28 de Fevereiro – 3 Março, 1993.

BECERRA, G. G., **Mitigação de Incertezas Através da Integração com Ajuste de Histórico de Produção**. Campinas: Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, 2007. 192p. Dissertação (Mestrado).

CAMPOZANA, F. P. E BALLIN, P. R., **Incerteza na Produção de Petróleo – Uma Proposta Simplificada**. PETROBRÁS, 1998.

COSTA, A. P. A., **Quantificação do Impacto de Incertezas e Análise de Risco no Desenvolvimento de Campos de Petróleo**. Campinas: Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, 2003. 239p. Tese (Doutorado).

DIKKERS, A. J., **Geology in Petroleum Production**. Editora Elsevier Science Publishers B.V. Amsterdam, Países Baixos, 1985.

FERAILLE, M.; MANCEAU, E.; ZABALZA-MEZGHANI, I.; ROGGERO, F.; HU, L.; E REIS, L. C., **Integration of Dynamic Data in a Mature Oil Field Reservoir Model to Reduce the Uncertainty on Production Forecasting**. American Association of Petroleum Geologists (AAPG) Annual Convention & Exhibition, Salt Lake City, Utah, 11 – 14 de Maio de 2003.

FETEL, E., E CAUMON, G., **Reservoir flow uncertainty assessment using response surface constrained by secondary information**. Journal of Petroleum Science and Engineering, vol. 60, p. 170–182, Março de 2008.

GU, Y., E OLIVER, D. S., **History Matching of the PUNQ-S3 Reservoir Model Using the Ensemble Kalman Filter**. SPE 89942. Annual Technical Conference and Exhibition (ATCE), Houston, Texas, E.U.A., 26 – 29 de Setembro de 2004.

HAMMERSLEY, J. M., E HANDSCOMB, D. C., **Monte Carlo Methods**. Editora John Wiley & Sons Ltda, p. 178. Nova Iorque, EUA, 1964.

HARBAUGH, J.; DAVIS, J.; WENDEBOURG, J., **Computing Risk for Oil Prospects: Principles and Program**. 1995. Oxford: Pergamon.

HEGSTAD, B. K., E OMRE, H., **Uncertainty in Production Forecasts Based on Well Observations, Seismic Data and Production History**. SPE 74699. SPE Journal, vol. 6, nº 4, p. 409-424, Dezembro de 2001.

JENSEN, T. B., **Estimation of Production Forecasts Uncertainty for Mature Production License**. SPE 49091, Annual Technical Conference and Exhibition (ATCE), New Orleans, Louisiana, 27 – 30 de Setembro de 1998.

KABIR, C. S.; CHIEN, M. C. H., E LANDA, J. L., Experiences With Automated History Matching. SPE 79670. Reservoir Simulation Symposium (RSS), Houston, Texas, E.U.A., 3 – 5 de Fevereiro de 2003.

LANDA, J. L., E GUYAGULER, B., **A Methodology for History Matching and the Assessment of Uncertainties Associated with Flow Prediction**. SPE 84465, Annual Technical Conference and Exhibition (ATCE), Denver, CO, 5 – 8 de Outubro de 2003.

LEITÃO, H. C., **Ajuste de Histórico Automatizado através de Otimização Multivariada e Paralelização Externa**. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1997. 145 p. Dissertação (Mestrado).

LITVAK, M.; CHRISTIE, M.; JOHNSON, D.; COLBERT, J.; E SAMBRIDGE, M., **Uncertainty Estimation in Production Constrained by Production History and Time-Lapse Seismic in a GOM Oil Field**. SPE 93146. Reservoir Simulation Symposium (RSS), Houston, Texas, E.U.A., 31 de Janeiro 02 – Fevereiro de 2005.

LOSCHIAVO, R., **Estimativa de Incertezas na Previsão de Desempenho de Reservatórios**. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1999. 86p. Dissertação (Mestrado).

LOSCHIAVO, R.; SCHIOZER, D. J.; E STEAGALL, D. E., **Estudo do Impacto de Incertezas no Desempenho de Reservatórios de Petróleo**. Encontro Nacional de Ciências Térmicas (ENCIT). Porto Alegre. Outubro de 2000.

MA, X., **History Matching and Uncertainty Quantification Using Sampling Method**. Texas A&M University, Texas, 2008. 139 p. Tese (Doutorado).

MA, X.; AL-HARBI, M.; DATTA-GUPTA, A.; EFENDIEV, Y., **A multistage sampling method for rapid quantification of uncertainty in history matching geological models**. SPE 102476. Annual Technical Conference and Exhibition (ATCE), vol. 3, Proceedings – ATCE 2006: Focus on the Future, p. 2038 – 2052, Outubro de 2006.

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

MASCHIO, C., E SCHIOZER, D. J., **Aplicação de Metodologia para a Automatização de Ajuste de Histórico**. 2º Congresso Brasileiro de P&D em Petróleo & Gás. Rio de Janeiro, 15 – 18 de Junho de 2003.

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 de 2010.

MASCHIO, C.; SCHIOZER, D. J.; MOURA FILHO, M. A. B. DE., **A Methodology to Quantify the Impact of Uncertainties in the History Matching Process and in the Production Forecast.** SPE 96613, Annual Technical Conference and Exhibition (ATCE), Dallas, Texas, 9 – 12 de Outubro de 2005.

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

MINHAS, H.; MATTEO, E.; EIKELAND, K. M.; MENGOLI, M.; BESWETHERICK, S., **Probabilistic Reserve Estimation Constrained by Limited Production Data: An Integrated Approach.** IPTC 10957, International Petroleum Technology Conference (IPTC), Doha, Qatar, 21 – 23 de Novembro de 2005.

MOURA FILHO, M. A. B. DE., **Integração de Análise de Incertezas e Ajuste de Histórico.** Campinas: Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, 2006. 150p. Dissertação (Mestrado).

MUN J., **Modeling Risk: Applying Monte Carlo Simulation, Real Options Analysis, Forecasting, and Optimization Techniques.** Editora John Wiley & Sons Ltda. p. 606. New Jersey, EUA, 2006.

NICOTRA, G.; GODI, A.; COMINELLI, A.; E CHRISTIE, M., **Production Data and Uncertainty Quantification: A Real Case Study.** SPE 93280. Reservoir Simulation Symposium (RSS), Houston, Texas, E.U.A., 31 de Janeiro – 02 de Fevereiro de 2005.

ØVREBERG, O.; DAMSLETH, E.; HALDORSEN, H. H., NORSK HYDRO A/S., **Putting Error Bars on Reservoir Engineering Forecasts.** SPE 20512, Journal of Petroleum Technology, vol. 44, n. 6, p. 732 – 738, Junho de 1992.

QUEIPO, N.V., PINTOS, S., RINCÓN, N., CONTRERAS, N., **Surrogate modeling-based optimization for the integration of static and dynamics data into a reservoir description.** Journal of Petroleum Science and Engineering, vol. 35, p. 167 – 181, Maio de 2002.

REIS, L. C.; REIS, L.C. DOS; SILVA, L. C. DA; BECERRA, G. G., **History Matching - Is it Necessary to Optimize?** SPE 122826, Latin American and Caribbean Petroleum Engineering Conference (LACPEC). Cartagena, Colômbia, 31 de Maio – 3 de Junho de 2009.

RISSO, V. F.; RISSO, F. V. A.; SCHIOZER, D. J., **Aplicação da Técnica do Hipercubo Latino na Análise de Risco de Campos de Petróleo**, 5º Congresso Brasileiro de P&D em Petróleo e Gás (5º PDPetro), Fortaleza, Ceará, 18 – 29 de Outubro de 2009.

SCHEIDT, C., E CAERS, J., **Representing Spatial Uncertainty Using Distances and Kernels**. DOI: 10.1007/s11004-008-9186-0. Mathematical Geosciences, vol. 41, nº 4, p. 397 – 419, Junho de 2008.

SCHEIDT, C., E CAERS, J., **Uncertainty Quantification in Reservoir Performance Using Distances and Kernel Methods – Application to a West Africa Deepwater Turbidite Reservoir**. SPE Journal, vol. 14, nº 4, p. 680 – 692, Dezembro de 2009.

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

SOUSA, S. H. G., **Aplicação da Metaheurística Busca Dispersa ao Problema de Ajuste de Histórico**. Campinas: Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas, 2007. 140p. Dissertação (Mestrado).

STEAGALL, D. E., **Análise de Risco nas Previsões de Produção com Simulação Numérica de Fluxo – Exemplo de um Campo na Fase de Delimitação**. Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2001. 89p. Dissertação (Mestrado).

SUZUKI, S., E CAERS, J., **A Distance Based Prior Model Parametrization for Constraining Solution of Spatial Inverse Problems**. DOI: 10.1007/s11004-008-9154-8. Mathematical Geosciences, vol. 40, n 4, p. 445 – 469, Março de 2008.

VOSE, D., **Risk Analysis: A Quantitative Guide**. Editora John Wiley & Sons Ltda. 3ª Edição, 726p. Inglaterra, 2008.

WILLIAMS, G. J. J.; MANSFIELD, M.; MacDONALD, D. G.; E BUSH, M. D., **Top-Down Reservoir Modelling**. SPE 89974. Annual Technical Conference and Exhibition (ATCE). Houston, Texas, E.U.A., 26 – 29 de Setembro de 2004.

XU, C. et al., **Latin hypercube sampling and geostatistical modeling of spatial uncertainty in a spatially explicit forest landscape model simulation**. Ecological Modelling 185, p. 255 – 269, Dezembro de 2005.

ZABALZA-MEZGHANI, I.; MANCEAU, E.; FERAILLE, M.; JOURDAN, A., **Uncertainty management: From geological scenarios to production scheme optimization**. Journal of Petroleum Science and Engineering, vol. 44, p. 11 – 25, Março de 2004.

ZERPA, L. E.; QUEIPO, N. V.; PINTOS, S.; SALAGER, J. L., **An optimization methodology of alkaline–surfactant–polymer flooding processes using field scale, numerical simulation and multiple surrogates**. Journal of Petroleum Science and Engineering, vol. 47, p. 197 – 208, Fevereiro de 2005.