



OTIMIZAÇÃO EM MALHA FECHADA DO DESENVOLVIMENTO DE CAMPOS DE PETRÓLEO SOB INCERTEZAS GEOLÓGICAS

Davi Marubayashi Hidalgo

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Civil, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Civil.

Orientadores: José Luis Drummond Alves
Paulo Couto

Rio de Janeiro
Março de 2017

OTIMIZAÇÃO EM MALHA FECHADA DO DESENVOLVIMENTO DE
CAMPOS DE PETRÓLEO SOB INCERTEZAS GEOLÓGICAS

Davi Marubayashi Hidalgo

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO
ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE
ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE
JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A
OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA
CIVIL.

Examinada por:

Prof. José Luis Drummond Alves, D.Sc.

Prof. Paulo Couto, D.Eng.

Prof. Laura Silvia Bahiense da Silva Leite, D.Sc.

Dr. Alexandre Anozé Emerick, Ph.D.

RIO DE JANEIRO, RJ – BRASIL

MARÇO DE 2017

Hidalgo, Davi Marubayashi

Otimização em Malha Fechada do Desenvolvimento de Campos de Petróleo Sob Incertezas Geológicas/Davi Marubayashi Hidalgo. – Rio de Janeiro: UFRJ/COPPE, 2017.

XXII, 137 p.: il.; 29, 7cm.

Orientadores: José Luis Drummond Alves

Paulo Couto

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Civil, 2017.

Referências Bibliográficas: p. 111 – 116.

1. Desenvolvimento de Campos de Petróleo em Malha Fechada . 2. Simulação Numérica de Reservatórios. 3. Otimização da Produção. 4. Ajuste de Histórico. 5. Incertezas Geológicas. I. Alves, José Luis Drummond *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Civil. III. Título.

*“If you only do what you can do,
you’ll never be better than what
you are.” M. Shifu.*

*Dedico este trabalho à minha
Bruna, ao Osvaldo e à Mirian.*

Agradecimentos

Em primeiro lugar quero agradecer à Bruna pelo amor, carinho e apoio incondicional nesses dois anos de mestrado. Você me inspira e com suas risadas adiciona alegria à minha vida.

Aos meus pais, Mirian e Osvaldo que sempre me deram incentivo, coragem e motivação. Vocês me fizeram ser o que sou hoje. Além disso, vocês são ótimos revisores de um texto em engenharia! Também agradeço meu irmão André que, mesmo do outro lado do Oceano Atlântico, consegue estar sempre disponível.

Sou grato também aos professores Paulo Couto e José Alves. A orientação de vocês foi fundamental para a realização deste trabalho.

Obrigado ao amigo e colega de trabalho Emerick. Suas análises perspicazes, ideias instigantes e generosidade nas explicações contribuíram de forma ímpar com este trabalho.

Vinícius, meu muito obrigado! Seu suporte foi fundamental, mostrando o caminho das pedras.

Agradeço o apoio e os conselhos do Mauro Mihaguti. Sem o seu suporte este mestrado nem teria começado.

Marco Antônio e Régis, sou muito grato pelas conversas e discussões que me ajudaram a buscar caminhos e soluções que eu não teria imaginado.

Obrigado a tantas outras pessoas que contribuíram com apoio tangível e intangível: Fabrício, Bianca, Alessandra, Ramon, Vitor, Carmen, Daniel Hallack, Pedro Wilson, Alexandre e tantos outros que sabem quem são. Meu muito obrigado.

Finalmente, gostaria de agradecer à Petrobras por proporcionar essa oportunidade única e investir em minha formação.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

OTIMIZAÇÃO EM MALHA FECHADA DO DESENVOLVIMENTO DE CAMPOS DE PETRÓLEO SOB INCERTEZAS GEOLÓGICAS

Davi Marubayashi Hidalgo

Março/2017

Orientadores: José Luis Drummond Alves

Paulo Couto

Programa: Engenharia Civil

O objetivo deste trabalho foi analisar os ganhos econômicos, em termos de Valor Presente Líquido (VPL), dos sucessivos ajustes realizados no plano de desenvolvimento (PD) de um campo de petróleo na medida em que novas informações eram disponibilizadas pela perfuração e produção dos poços. Para isso, a metodologia de otimização em malha fechada do desenvolvimento de campos de petróleo sob incertezas geológicas, também denominada de desenvolvimento de campo em malha fechada (DCMF) foi aplicada no modelo *benchmark* UNISIM-I, baseado no campo de Namorado, do *offshore* brasileiro. O DCMF utilizou ciclicamente as etapas de ajuste de histórico, seleção de modelos representativos e otimização do PD no conjunto de modelos incertos, elaborados com uma quantidade de informação inicial limitada. Os dados de produção e perfil de poço que alimentaram os ciclos foram obtidos no modelo de referência que reproduzia o comportamento do reservatório real. Para aferir os ganhos, foi realizada a comparação entre a resposta do modelo de referência ao utilizar o PD gerado pela metodologia e um PD inicial. Obteve-se um aumento de 29% no VPL ao aplicar a metodologia em comparação com o PD inicial. O DCMF também foi capaz de melhorar a tomada de decisões por aumentar sistematicamente o VPL do conjunto de modelos incertos. Os custos computacionais envolvidos, apesar de elevados, não impuseram restrição à sua utilização. Conclui-se que a utilização do DCMF trouxe ganhos econômicos consistentes sendo, portanto, aplicável em casos reais.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

CLOSED LOOP OIL FIELD DEVELOPMENT UNDER GEOLOGICAL UNCERTAINTIES

Davi Marubayashi Hidalgo

March/2017

Advisors: José Luis Drummond Alves

Paulo Couto

Department: Civil Engineering

The objective of this work was to analyze the economic gains, in terms of Net Present Value (NPV), of the successive adjustments in the development plan (DP) of an oil field as new information was made available by drilling and production of the wells. The closed-loop optimization of the development of oil fields under geological uncertainties, also referred as Closed Loop Field Development (CLFD) was applied in the UNISIM-I benchmark model, based on the field of Namorado, of the Brazilian offshore. The CLFD has cyclically used the steps of history matching, selection of representative models and optimization of DP in the ensemble of uncertain models, elaborated with a limited amount of initial information. Production data and well logs used in the cycles were obtained in a reference model that reproduces the behavior of the real reservoir. The comparison between the response of the reference model when using the DP generated by the methodology and an initial DP was used to compare the gains. The results showed a 29.0 % increase in NPV when applying the methodology compared to the initial PD. The CLFD was also able to improve decision making by systematically increasing the NPV of the set of uncertain models. Although the computational costs involved were high, they did not impose a restriction on the use of the methodology. The use of DCMF brought consistent economic gains and is, therefore, applicable in real cases.

Sumário

Lista de Figuras	xi
Lista de Tabelas	xix
Lista de Abreviaturas	xxi
1 Introdução	1
1.1 Contextualização e Motivação	1
1.2 Objetivo	2
1.3 Organização do Trabalho	3
2 Revisão Bibliográfica	4
2.1 Desenvolvimento de Campo em Malha Fechada	4
2.2 Ajuste de Histórico	10
2.3 Seleção de Modelos Representativos	20
2.3.1 <i>Multidimensional Scaling</i>	27
2.4 Otimização do Plano de Desenvolvimento	30
2.5 <i>Benchmarks</i> para Estudo de Metodologias	35
2.5.1 UNISIM-I	37
3 Metodologia	42
3.1 Ajuste de Histórico	45
3.1.1 Obtenção de Dados Observados	48
3.2 Seleção de Modelos Representativos	51
3.3 Otimização do Plano de Desenvolvimento	53
3.4 Modelagem do Valor Presente Líquido	57
3.5 Recursos Computacionais	58
4 Resultados e Discussões	60
4.1 Ajuste de Histórico	60
4.2 Seleção de Modelos Representativos	76
4.3 Otimização do Plano de Desenvolvimento	83

4.4	Desenvolvimento de Campo em Malha Fechada	97
4.5	Custo Computacional	104
5	Conclusões	107
5.1	Conclusões do Trabalho	107
5.2	Sugestões para Trabalhos Futuros	108
	Referências Bibliográficas	111
A	Resultados da Etapa de Ajuste de Histórico	117
A.1	Ajuste de histórico dos dados de produção do Ciclo 3	117
A.2	Ajuste de histórico dos dados de perfil do Ciclo 3	128
B	Resultados da Etapa de Seleção de Modelos Representativos	130
C	Resultados Complementares do DCMF	135

Lista de Figuras

2.1	Diagrama de blocos de um sistema de controle em malha fechada: os dados de saída são realimentados de maneira a mudar os controles e alterar a resposta do sistema. Adaptado de OGATA (2011).	5
2.2	Representação esquemática do desenvolvimento de campo em malha fechada entre os tempos t_1 e t_3 , adaptado de SHIRANGI e DURLOFSKY (2015).	8
2.3	Fluxograma das etapas de uma estimativa feita com o Filtro de Kalman. 13	
2.4	Assimilação sequencial dos dados observados com o Filtro de Kalman: comparação entre dados reais, dados observados e dados estimados do o Filtro de Kalman.	16
2.5	Comparação entre o ajuste de histórico com os diferentes métodos: EnKF/ES, ES-MDA(2x) e ES-MDA(4x). Adaptado de EMERICK e REYNOLDS (2013).	19
2.6	Representação esquemática do cálculo da distribuição de probabilidades utilizando um simulador de fluxo, adaptada de SCHEIDT e CAERS (2008).	20
2.7	Exemplo de P_{10} , P_{50} e P_{90} para o VPL.	21
2.8	Escolha de modelos representativos próximos ao P_{10} , P_{50} e P_{90} para o VPL que também devem ter diferenças significativas no fator de recuperação (ORF), produção acumulada de água (W_p) e produção total de óleo (N_p), SCHIOZER <i>et al.</i> (2004)	22
2.9	Representação esquemática do método de seleção de modelos representativos. Adaptado de ARMSTRONG <i>et al.</i> (2012).	25
2.10	Representação das quatro cidades utilizando o MDS.	30
2.11	Conceitos utilizados no Algoritmo Genético, adaptado de COELLO <i>et al.</i> (2006).	31
2.12	Fluxograma das etapas do Algoritmo Genético, adaptado de SHYR (2010).	32
2.13	Estrutura de dados utilizada no Algoritmo Genético.	32

2.14	Cromossomo representativo de um indivíduo em uma otimização da locação de N poços, adaptado de EMERICK <i>et al.</i> (2009).	34
2.15	A: Localização do campo offshore de Namorado, Brasil; B: Zoom da Fig. A evidenciando o campo de Namorado; C: Zoom da Fig. B com o campo de Namorado e seus poços perfurados (pontos em preto). BUENO <i>et al.</i> (2011).	37
2.16	Dados de testemunho: porosidade versus permeabilidade. AVANSI e SCHIOZER (2015).	38
2.17	Locação dos poços exploratórios em uma realização do UNISIM-I-D.	39
2.18	Mapa de porosidade e falhas do modelo UNISIM-I-R (a) e de uma realização do modelo UNISIM-I-D (b).	40
3.1	Etapas chave do desenvolvimento de campo em malha fechada (DCMF), adaptado de JANSEN <i>et al.</i> (2009) e SILVA (2016).	43
3.2	Área de influência para o poço Injetor 1, somente parâmetros localizados dentro da elipse serão alterados.	48
3.3	Obtenção de dados de produção para o ajuste de histórico com inclusão de ruído aleatório e imposição da vazão como controle da simulação.	49
3.4	Curva de pressão de fundo e histórico gerado para o poço NA2 no Ciclo 1. Os pontos de histórico (em azul) foram gerados incluindo ruído na curva em vermelho obtida no modelo UNISIM-I-R. A curva em azul representa a resposta de um dos modelos do conjunto ao especificar a vazão como controle de poço.	50
3.5	Primeira camada de um dos modelos durante o Ciclo 6. As células em vermelho correspondem àquelas em que foi considerada conhecida a porosidade.	51
3.6	Plano de drenagem correspondente à semente inicial do Ciclo 0 em um mapa de porosidade. Poços em vermelho são produtores e em azul são injetores.	55
4.1	Em preto, os poços perfurados até 30/11/2018 que foram fonte dos dados observados do Ciclo 3, em um mapa de porosidade de um dos modelos.	61
4.2	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Produtor 9.	63
4.3	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Produtor 2.	63
4.4	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Produtor 7.	64

4.5	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Injetor 1.	64
4.6	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço NA1A.	65
4.7	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço NA2.	65
4.8	Perfis para o poço Produtor 9: modelo com melhor ajuste, pior ajuste e UNISIM-I-R.	67
4.9	Perfis para o poço Produtor 2: modelo com melhor ajuste, pior ajuste e UNISIM-I-R.	67
4.10	Resultado do ajuste de histórico no poço NA2. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.	68
4.11	Resultado do ajuste de histórico no poço NA2. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	69
4.12	Resultado do ajuste de histórico no poço Produtor 7. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.	70
4.13	Resultado do ajuste de histórico no poço Produtor 7. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	71

4.14	Resultado do ajuste de histórico no poço Injetor 8. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água de injeção: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	72
4.15	Resultado do ajuste de histórico. Os mapas da esquerda representam a primeira camada do modelo inicial e o da direita o ajustado. Porosidade: (a) modelo inicial, (b) modelo ajustado. <i>Net to Gross</i> : (c) modelo inicial, (d) modelo ajustado.	73
4.16	Resultado do ajuste de histórico. Os mapas da esquerda representam a primeira camada do modelo inicial e o da direita o ajustado. Permeabilidade: (a), (c), (e) modelos iniciais; (b), (d), (f) modelos ajustados.	75
4.17	Comparação entre a porosidade da primeira camada do modelo que apresentou o melhor ajuste de histórico e o UNISIM-I-R, modelo de referência.	76
4.18	Evolução do mapa de porosidade da primeira camada após o ajuste de histórico para um dos modelos ao longo dos ciclos e para o modelo de referência.	77
4.19	Valores da função objetivo variando o número de modelos selecionados, realizado no Ciclo 0.	78
4.20	Valores da função objetivo variando o número de modelos selecionados para um conjunto de até 10 indivíduos, realizado no Ciclo 0.	79
4.21	Derivada dos valores da função objetivo para um conjunto de até 10 indivíduos, realizado no Ciclo 0.	79
4.22	Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 1. As cinco diferentes cores representam os <i>clusters</i> associados a cada um dos modelos representativos selecionados (em vermelho).	80
4.23	Gráficos combinando dois parâmetros da seleção de modelos representativos para o Ciclo 1. Os pontos em vermelho correspondem aos modelos selecionados e os pontos em azul representam os demais modelos.	81
4.24	Frequência acumulada dos parâmetros com maior peso na seleção para o Ciclo 1. Os pontos em vermelho correspondem aos modelos selecionados e os pontos em azul os demais modelos.	82
4.25	Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 2. As cinco diferentes cores representam os <i>clusters</i> associados a cada um dos modelos representativos selecionados (em vermelho).	82

4.26	Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 0. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.	85
4.27	Evolução do VME do melhor plano de drenagem (indivíduo) e da média do VME da população ao longo das 50 gerações para o Ciclo 0.	86
4.28	Histogramas do VPL para o Ciclo 0, antes e depois da otimização. . .	86
4.29	Histogramas do N_p para o Ciclo 0, antes e depois da otimização. . . .	87
4.30	Histogramas do W_p para o Ciclo 0, antes e depois da otimização. . .	87
4.31	Histogramas do FR para o Ciclo 0, antes e depois da otimização. . . .	88
4.32	Histogramas do VOIP para o Ciclo 0, antes e depois da otimização. .	88
4.33	Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 1. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.	90
4.34	Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 2. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.	91
4.35	Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 3. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.	92
4.36	Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 4. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.	94
4.37	Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 5. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.	95
4.38	Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 6. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.	96
4.39	Evolução da média do VPL para o conjunto de 500 modelos.	98
4.40	Evolução da média do fator de recuperação para o conjunto de 500 modelos.	99
4.41	Descrição dos elementos do <i>boxplot</i> para as propriedade apresentadas no estudo.	99
4.42	Boxplot do VPL ao longo dos ciclos.	100
4.43	Comparação entre o VPL do conjunto e o VPL do modelo de referência.	102
4.44	Comparação entre o resultado do VPL do plano de desenvolvimento obtido com o DCMF e a otimização determinística, ambos aplicados no modelo de referência.	102
4.45	Boxplot do N_p ao longo dos ciclos.	103

4.46	Boxplot do VOIP ao longo dos ciclos.	104
4.47	Divisão da média de tempos gastos em cada uma das etapas do DCMF.	105
A.1	Resultado do ajuste de histórico no poço Produtor 2. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Pressão de fundo: (a) modelos iniciais, (b) modelos ajustados.	117
A.2	Resultado do ajuste de histórico no poço NA3D. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.	118
A.3	Resultado do ajuste de histórico no poço NA3D. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	119
A.4	Resultado do ajuste de histórico no poço NA1A. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.	120
A.5	Resultado do ajuste de histórico no poço NA1A. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	121
A.6	Resultado do ajuste de histórico no poço RJS19. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.	122

A.7	Resultado do ajuste de histórico no poço RJS19. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	123
A.8	Resultado do ajuste de histórico no poço P9. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.	124
A.9	Resultado do ajuste de histórico no poço P9. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	125
A.10	Resultado do ajuste de histórico no poço Injetor 1. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água de injeção: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	126
A.11	Resultado do ajuste de histórico no poço Injetor 6. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água de injeção: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.	127
A.12	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Injetor 6.	128
A.13	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Injetor 8.	128
A.14	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço RJS19.	129
A.15	Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço NA3D.	129

B.1	Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo Zero. Modelos representativos em vermelho.	130
B.2	Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 3. Modelos representativos em vermelho.	131
B.3	Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 4. Modelos representativos em vermelho.	131
B.4	Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 5. Modelos representativos em vermelho.	132
B.5	Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 6. Modelos representativos em vermelho.	132
B.6	Conjunto de pares de parâmetros para o Ciclo 1.	133
B.7	Conjunto de pares de parâmetros para o Ciclo 1.	133
B.8	Frequências acumuladas para os parâmetros durante o Ciclo 1.	134
C.1	Evolução da média do N_p para o conjunto de 500 modelos.	135
C.2	Evolução da média do W_p para o conjunto de 500 modelos.	136
C.3	Boxplot do FR ao longo dos ciclos.	136
C.4	Boxplot do WP ao longo dos ciclos.	137

Lista de Tabelas

2.1	Comparação das vantagens e desvantagens dos métodos de ajuste de histórico, adaptado de OLIVER e CHEN (2010).	12
2.2	Distâncias (km) entre as cidades	28
2.3	Relação entre fácies, propriedades de reservatório e NTG, AVANSI e SCHIOZER (2015).	38
2.4	Variograma utilizado na modelagem da porosidade, AVANSI e SCHIOZER (2015).	38
2.5	Atributos incertos do UNISIM-I-D	40
3.1	Caracterização dos ciclos e cada um dos poços participantes.	45
3.2	Dados de produção e desvio padrão do erro de medição para poços produtores utilizados no ajuste de histórico.	46
3.3	Dados de produção e desvio padrão do erro de medição para poços injetores utilizados no ajuste de histórico.	46
3.4	Parâmetros escalares considerados.	47
3.5	Parâmetros de malha utilizados no ajuste de histórico.	47
3.6	Valor do desvio padrão do ruído aplicado aos dados de produção.	50
3.7	Parâmetros de malha e seus pesos utilizados para caracterizar os modelos e selecionar os representativos	52
3.8	Parâmetros escalares e seus pesos utilizados para caracterizar os modelos e selecionar os representativos	53
3.9	Parâmetro volumétrico e seu peso utilizados para caracterizar os modelos e selecionar os representativos	53
3.10	Parâmetros de produção e seus pesos utilizados para caracterizar os modelos e selecionar os representativos	54
3.11	Parâmetros da evolução e dos operadores genéticos da otimização	56
3.12	Parâmetros utilizados para o cálculo do VPL	59
3.13	Configuração por CPU do <i>cluster</i> utilizado para a realização dos estudos.	59
3.14	Configuração de cada nó e total de nós do <i>cluster</i> utilizado para a realização dos estudos.	59

4.1	Valores das funções objetivo que quantificaram o ajuste de histórico para o Ciclo 3 - produção, perfil e total.	61
4.2	Evolução da média da função objetivo ao longo dos ciclos.	76
4.3	Modelos representativos selecionados e suas probabilidades atualizadas para o Ciclo 1.	80
4.4	Número de poços durante cada ciclo.	97
4.5	Valores da média do VPL para os 500 modelos em cada ciclo, antes e depois da otimização.	97
4.6	Número de simulações realizadas em cada etapa, por ciclo.	105
4.7	Tempo (em horas) para execução das simulações de fluxo em cada etapa, por ciclo.	105
4.8	Consolidação do tempo e número de simulações realizadas no estudo.	106
C.1	Valores do VPL do modelo de referência em cada ciclo.	135

Lista de Abreviaturas

2D	Duas Dimensões, p. 9
3D	Três Dimensões, p. 9
CMG	<i>Computer Modeling Group</i> , p. 58
Cpor	Compressibilidade da Rocha, p. 40
DCMF	Otimização em Malha Fechada do Desenvolvimento de Campos de Petróleo sob Incertezas Geológicas, ou sucintamente, Desenvolvimento de Campo em Malha Fechada, p. 2
EHM	<i>Ensemble-Based History Matching</i> , p. 45
ES-MDA	<i>Ensemble Smoother With Multiple Data Assimilation</i> , p. 9
ES	<i>Ensemble Smoother</i> , p. 17
EnKF	<i>Ensemble Kalman Filter</i> , p. 11
FR	Fator de Recuperação, p. 22
GRMF	Gerenciamento de Reservatório em Malha Fechada, p. 2
Genocop III	<i>Genetic Algorithm for Numerical Optimization of Constrained Problems</i> , p. 33
Krw	Ponto Terminal da Curva de Permeabilidade Relativa, p. 40
MDS	<i>Multidimensional Scaling</i> , p. 4
MR	Modelos Representativos, p. 4
NTG	<i>Net to Gross</i> , p. 36
Np	Produção Acumulada de Óleo, p. 21
OSV	<i>Optimization With Sample Validation</i> , p. 9

PD	Plano de Desenvolvimento, p. 1
PUNQ	<i>Production Forecast Uncertainty Quantification</i> , p. 36
PVT	<i>Pressure, Volume, Temperature</i> , p. 40
Swcr	Saturação Crítica, p. 40
UNISIM-I-D	Modelos Incertos, elaborados somente com os dados dos poços NA1A, NA3D, NA2 e RJS-19, p. 4
UNISIM-I-R	Modelo de Referência, elaborado com todos os dados do campo de Namorado, p. 4
UNISIM-I	Modelo <i>Benchmark</i> baseado no campo de Namorado - composto pelo UNISIM-I-R e UNISIM-I-D, p. 3
VME	Valor Monetário Esperado, p. 7
VOIP	<i>Volume of Oil in Place</i> , p. 20
VPL	Valor Presente Líquido, p. 1
Woc	Contato Óleo-Água, p. 40
Wp	Produção Acumulada de Água, p. 21

Capítulo 1

Introdução

1.1 Contextualização e Motivação

A atual realidade da indústria do petróleo mundial na qual se tem um superávit de produção em relação à demanda e uma conseqüente redução dos preços do barril de petróleo tem levado as empresas a buscar uma maior disciplina de capital e financeira. Para os projetos de desenvolvimento da produção, isso pode ser entendido como a busca pela maximização de sua economicidade. Dentre as métricas utilizadas para avaliar e priorizar um projeto, uma das mais recorrentes é o Valor Presente Líquido (VPL) .

Nesse contexto, um dos papéis fundamentais da equipe multidisciplinar de reservatórios consiste em definir o melhor Plano de Desenvolvimento (PD) possível já que ele influencia diretamente na atratividade do projeto, medido pelo seu VPL. Pode-se entender o PD como a definição de características chave do projeto tais como o número de poços, sua locação, seu tipo (produtor ou injetor) e a ordem de perfuração. A sua determinação é um processo complexo por diversos fatores dentre os quais podem-se citar: o alto nível de incerteza presente nos modelos (decorrente das poucas informações disponíveis), os altos investimentos relacionados à perfuração, completação e interligação dos poços, a irreversibilidade das decisões tomadas e a necessidade de se ter uma previsão acurada do comportamento do reservatório.

A solução para esse tipo de problema passa por dois elementos principais: o modelo geológico e o simulador de fluxo. Em relação ao primeiro, devido ao escasso conhecimento do reservatório, hoje é comum a utilização de um conjunto de modelos que buscam retratar as incertezas presentes. Esse conjunto serve então como dado de entrada para, em conjunto com outros parâmetros, gerar a previsão de produção do campo pelo simulador de fluxo.

É evidente que à medida que o projeto avança em sua execução, novos dados de produção e de perfis se tornam disponíveis. Assim, os modelos devem ser constante-

mente atualizados de maneira a tentar representar todo o conhecimento disponível no momento. Entretanto, não raramente, isso é feito de uma maneira não sistemática ou então o conhecimento adquirido não é desdobrado em uma nova otimização do restante do plano de desenvolvimento. Na realidade, ainda existem casos em que o mesmo é determinado por meio de um processo de tentativa e erro ou então pela otimização do conjunto inicial de modelos, sem considerar as novas informações que vão sendo obtidas.

A metodologia que envolve um processo cíclico submetido à atualização do conjunto de modelos, a otimização do plano de desenvolvimento e a obtenção de novos dados é denominada de Otimização em Malha Fechada do Desenvolvimento de Campos de Petróleo sob Incertezas Geológicas ou, de uma maneira mais sucinta, Desenvolvimento de Campos em Malha Fechada (DCMF). Ela surgiu como uma extensão do conceito de Gerenciamento de Reservatórios em Malha Fechada (GRMF) no qual o foco não é a fase de desenvolvimento da produção, mas a otimização dos controles de poço de um campo que já está em produção. A ideia subjacente a ambas metodologias consiste em trazer valor ao projeto (ou seja, obter ganhos no VPL) por meio de uma atuação nas variáveis de decisão, a partir das novas informações que vão sendo obtidas.

A proposta formal da metodologia do DCMF é recente (SHIRANGI e DURLLOFSKY (2015)) e até o momento existem poucos resultados publicados comprovando a sua aplicabilidade em casos práticos. Dessa forma, uma das motivações do presente trabalho consiste em verificar os potenciais ganhos de sua aplicação ao trabalhar em um reservatório de relativa complexidade do *offshore* brasileiro. Além disso, cada uma das etapas do DCMF pode ser abordada de diferentes maneiras, devendo-se optar por um conjunto específico de soluções para uma aplicação prática. Isso também serviu de inspiração para se verificar se as escolhas feitas neste trabalho, quando utilizadas no arcabouço do DCMF, levam aos ganhos econômicos esperados. Finalmente, por ser um processo iterativo e computacionalmente demandante, seja em relação aos recursos necessários quanto ao tempo gasto, procurou-se verificar se sua aplicabilidade não é inviabilizada por essas restrições.

1.2 Objetivo

Esta dissertação teve como objetivo avaliar os ganhos econômicos decorrentes do contínuo ajuste do plano de desenvolvimento de um campo de petróleo conforme novas informações foram disponibilizadas pela perfuração e produção dos poços. Esse processo foi repetido de maneira cíclica em um reservatório baseado no Campo de Namorado até o final da campanha de perfuração, utilizando a metodologia da otimização em malha fechada do desenvolvimento de campos de petróleo sob

incertezas geológicas, ou DCMF.

Em adição, este trabalho propôs um conjunto específico de métodos a serem utilizados em cada uma das etapas do DCMF. A avaliação do desempenho dos métodos escolhidos também consistiu em um dos objetivos deste trabalho.

1.3 Organização do Trabalho

Este trabalho é composto por cinco capítulos. No Capítulo 1 foi apresentada uma contextualização do tema assim como a motivação e o objetivo da dissertação.

No Capítulo 2 é realizada a revisão bibliográfica de todos os conceitos necessários para o trabalho, iniciando pela apresentação da metodologia de DCMF. Cada uma de suas etapas é detalhada: ajuste de histórico, seleção de modelos representativos e otimização do plano de desenvolvimento. Em seguida é feita uma revisão dos modelos *benchmark* utilizados para avaliar o desempenho de metodologias e, posteriormente, é apresentado o objeto de estudo deste trabalho, o UNISIM-I.

No Capítulo 3 é detalhada a metodologia utilizada na dissertação, baseada no trabalho de SHIRANGI e DURLOFSKY (2015). Os métodos específicos utilizados em cada uma das etapas são detalhados. Além disso, é apresentada a modelagem do VPL, parâmetro adotado para quantificar os ganhos obtidos ao se aplicar a metodologia. Ao final do capítulo são apresentados os recursos computacionais utilizados para a realização deste estudo.

No Capítulo 4 são apresentados os resultados e é feita a análise e discussão dos mesmos. Primeiramente, cada etapa é examinada em separado para, em seguida, expor a metodologia como um todo ao longo dos ciclos. Ainda nesse capítulo são feitas ponderações a respeito do custo computacional do estudo.

O Capítulo 5 encerra a dissertação apresentando as conclusões e sugerindo possíveis trabalhos futuros.

Nos Apêndices A, B e C estão disponíveis para consulta alguns resultados complementares àqueles apresentados ao longo do texto.

Capítulo 2

Revisão Bibliográfica

Neste capítulo é feita uma revisão bibliográfica sobre a otimização em malha fechada do desenvolvimento de campos de petróleo sob incertezas geológicas. Isso é iniciado com definições básicas da teoria de controle, em seguida é apresentado o GRMF e seu desdobramento para campos em desenvolvimento, o DCMF.

O DCMF é composto por três passos fundamentais: ajuste de histórico, otimização do plano de desenvolvimento e aquisição de novos dados. Um passo intermediário – a seleção de Modelos Representativos (MR) – é incluído devido à necessidade de reduzir o tempo gasto em simulações de fluxo. Assim, uma revisão bibliográfica é feita sobre esses tópicos, com exceção da aquisição de novos dados que é tratada no Capítulo 3. É imprescindível revisar esses assuntos para dar suporte à escolha dos métodos específicos utilizados neste trabalho já que o DCMF pode ser entendido como uma metodologia genérica que aceita diversos tipos de solução para cada uma das etapas. Na seção que trata da seleção de modelos representativos é visto também o conceito de Escalonamento Multidimensional ou *Multidimensional Scaling* (MDS), importante ferramenta na visualização dos resultados.

Ao final, é feita a revisão bibliográfica de diferentes *benchmarks* de modelos de simulação. Eles propõem solucionar o problema da avaliação da aplicabilidade de novas metodologias. Por fim, é apresentado o objeto de estudo deste trabalho, o UNISIM-I, composto pelo modelo de referência (UNISIM-I-R) e o conjunto de modelos incertos utilizados para caracterizar as incertezas do campo (UNISIM-I-D).

2.1 Desenvolvimento de Campo em Malha Fechada

Na teoria de controle, um sistema com realimentação é aquele que, segundo OGATA (2011), estabelece uma relação de comparação entre a saída e a entrada de referência utilizando a diferença como meio de controle. Frequentemente é também denomi-

nado de sistema em malha fechada. Uma representação esquemática é dada pela Figura 2.1.




Figura 2.1: Diagrama de blocos de um sistema de controle em malha fechada: os dados de saída são realimentados de maneira a mudar os controles e alterar a resposta do sistema. Adaptado de OGATA (2011).

Nesse sentido, é possível considerar o desenvolvimento de um campo de petróleo como um sistema em malha fechada: o sistema é o próprio reservatório no qual atuarão diversos controles (tais como: perfuração de novos poços, injeção de água, abertura e fechamento de poços). As respostas do sistema (dados de perfis, dados de produção, testes de produtividade) serão medidas e servirão de base para a tomada de decisões que alterarão os controles previamente existentes (por exemplo, pode-se decidir pela perfuração de um poço produtor que não estava inicialmente previsto). Estes, por sua vez, influenciarão na resposta do sistema (com um poço produtor a mais, as curvas de produção serão alteradas).

Conceitos da teoria de controle combinados com técnicas de assimilação de dados provenientes da meteorologia e oceanografia inspiraram JANSEN *et al.* (2009) a proporem a metodologia do Gerenciamento de Reservatórios em Malha Fechada. Como o próprio nome diz, nessa abordagem o foco é no gerenciamento de um campo já desenvolvido. O GRMF consiste em uma combinação da otimização dos controles de poço e do ajuste de histórico buscando maximizar o desempenho do reservatório, seja em termos de fator de recuperação ou econômicos. A metodologia segue os seguintes passos:

1. Otimização do controle dos poços existentes baseado no conhecimento geológico disponível;
2. Operação da produção durante um certo período de tempo para obtenção de dados de produção;
3. Ajuste de histórico dos dados de produção para atualização dos modelos geológicos.

Quando esses passos são repetidos de maneira cíclica ao longo de toda a vida de um campo, o GRMF pode trazer ganhos significativos quando comparado com

outras abordagens. O estudo de JANSEN *et al.* (2009) trabalhou com um campo que contava com 12 poços (4 produtores e 8 injetores) e aplicando ciclos de 4 anos, 2 anos, 1 ano e 30 dias foram obtidos ganhos no VPL de respectivamente 6,68%, 8,29%, 8,30% e 8,71% quando comparados com um gerenciamento reativo.

SILVA (2016) aplicou o GRMF no campo UNISIM-I tendo como parâmetros de controle a abertura das válvulas de completação inteligente dos poços. A malha de drenagem consistia em 14 produtores e 11 injetores. Durante o período de concessão do campo foram aplicados 6 ciclos com durações variadas: dois de 2 anos, dois de 4 anos, um de 6 anos e um de 7 anos. Obteve-se um aumento de 18,3% do VPL do reservatório de referência quando comparado com a estratégia base. Além disso, o autor concluiu que o poder preditivo dos modelos foi aumentado ao longo dos ciclos da malha fechada.

Tendo em vista os resultados obtidos ao se trabalhar com o gerenciamento de um campo já desenvolvido, vislumbra-se a possibilidade da extensão dessa ideia para o desenvolvimento de campos de petróleo.

PETTAN e STROMSVIK (2013) apresentaram a visão geral de uma metodologia implementada no campo de Peregrino, na Bacia de Campos. Buscaram manter os modelos consistentes e atualizados à medida que novas informações eram obtidas com o desenvolvimento do campo. Para isso foi adotada a seguinte sequência de passos:

1. Revisão das premissas dos modelos (como fácies, modelo deposicional, PVT etc);
2. Inclusão da informação dos novos poços perfurados;
3. Atualização do histórico da produção de injeção;
4. Verificação de consistência e abrangência dos modelos;
5. Ajuste de histórico;
6. Otimização da produção.

Os autores detalham sobretudo o item 4, que pode ser entendido como um controle de qualidade dos novos dados e premissas assumidas na criação dos modelos. Os resultados da simulação de fluxo eram confrontados com os dados reais e, caso necessário, podiam ser feitas alterações antes de prosseguir com o ajuste de histórico e a otimização da produção. Foram apresentados três estudos de caso dessa etapa de verificação: modelagem de fácies, condicionamento da sísmica e modelagem de falhas. Ainda que nos dois primeiros o resultado não tenha sido satisfatório (levando

a uma revisão das premissas), na modelagem de falhas foi obtida uma melhora substancial nos modelos facilitando a etapa do ajuste de histórico. Apesar dos demais passos não terem sido detalhados, foi evidenciada a necessidade da automatização das tarefas para diminuir o tempo gasto em sua execução. No campo de Peregrino a implementação de toda a metodologia levou um ano e consistiu em três rodadas de inclusão de dados (média de 3 poços em cada uma). Os autores avaliaram que essa abordagem foi uma boa maneira de manter os modelos confiáveis em um cenário real no qual se tem uma grande quantidade de poços perfurados em um curto período de tempo.

A apresentação mais formal do conceito de Otimização em Malha Fechada do Desenvolvimento de Campos de Petróleo Sob Incertezas Geológicas foi feita por SHIRANGI e DURLOFSKY (2015). Por consistir no marco teórico para o presente trabalho, suas três principais etapas serão detalhadas:

1. Otimizar o plano de desenvolvimento do campo baseado na informação geológica disponível no momento;
2. Perfurar novos poços e obter informações geológicas e de produção;
3. Atualizar os modelos com base nas novas informações adquiridas.

Na primeira etapa, o número, localização, tipo e controle dos poços é otimizado buscando o maior VPL possível. Em seguida, na segunda etapa, são adquiridos novos dados – de produção e de perfil – por meio da perfuração de novos poços e da produção/injeção dos poços existentes. Finalmente, na terceira etapa, tendo disponíveis novos dados, é realizado um ajuste de histórico de maneira a atualizar os modelos. Esse processo é repetido a cada novo poço perfurado.

Uma representação esquemática do DCMF é dada pela Figura 2.2. Inicia-se o processo no tempo t_1 , partindo de um conjunto inicial de modelos geológicos M_1 e um plano de desenvolvimento inicial, o PD_0 , que contém informações a respeito dos poços da malha de drenagem (quantidade, tipo, localização e controle). O Valor Monetário Esperado (VME) é otimizado por um algoritmo (como, por exemplo, enxame de partículas ou algoritmo genético) gerando o PD_1 , ou seja, o plano de desenvolvimento otimizado. Com isso, dá-se por concluída a primeira das três etapas. Para posteriormente poder avaliar o desempenho, é calculado o VPL do PD_1 quando aplicado ao modelo de referência, m_{real} . Assume-se, por hipótese, que este modelo de referência represente o reservatório real. Assim, ele é a fonte dos dados observados de produção e de perfil que serão utilizados nos passos seguintes.

Entre t_1 e t_2 temos a obtenção das informações de produção do poço 1 além da perfuração, completação e interligação do poço 2, ambos definidos previamente no

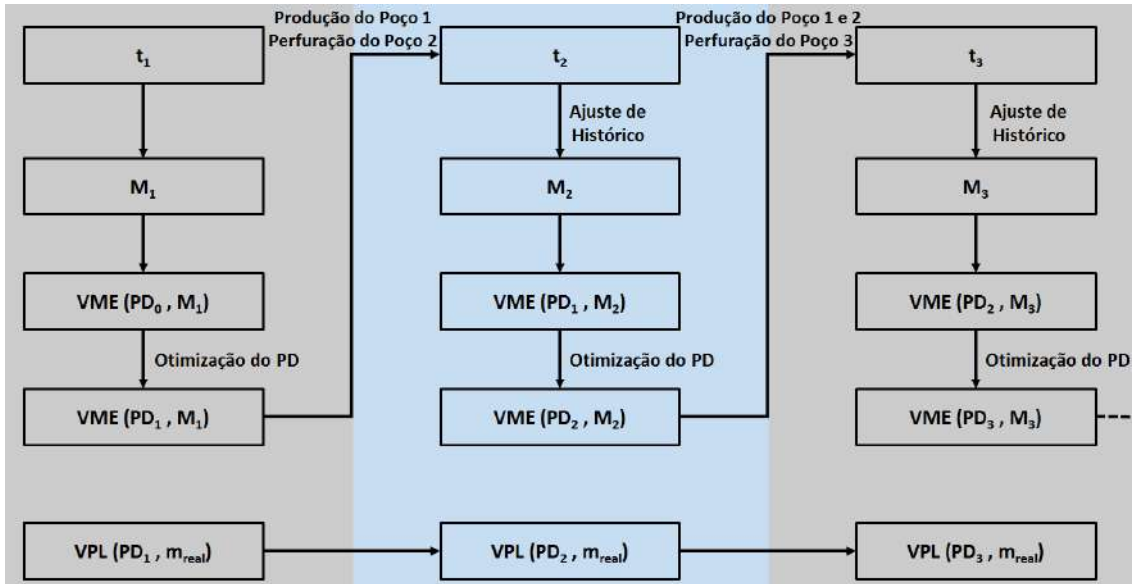


Figura 2.2: Representação esquemática do desenvolvimento de campo em malha fechada entre os tempos t_1 e t_3 , adaptado de SHIRANGI e DURLOFSKY (2015).

PD_1 . Obtém-se no modelo de referência essas informações, finalizando a segunda etapa.

Passa-se então à terceira etapa na qual é feito o ajuste de histórico com a atualização dos modelos geológicos de forma a honrar os dados obtidos entre t_1 e t_2 . Para tanto, utiliza-se algum método de ajuste de histórico gerando o novo conjunto de modelos atualizados, M_2 . Partindo do PD_1 como estimativa inicial para o problema de otimização da malha de drenagem, tem-se como solução o PD_2 . Este é então aplicado ao modelo de referência para que se possa aferir os ganhos decorrentes da utilização do DCMF por meio da comparação entre o $VPL(PD_1, m_{real})$ e o $VPL(PD_2, m_{real})$. Entre t_2 e t_3 as etapas são repetidas e assim sucessivamente até o final da perfuração de todos os poços.

Nota-se que a metodologia é genérica e as etapas de otimização e de ajuste de histórico podem ser feitas com diferentes métodos. No trabalho de SHIRANGI e DURLOFSKY (2015), a otimização do plano de desenvolvimento é feita com um algoritmo baseado no Enxame de Partículas, detalhado em ISEBOR *et al.* (2014). Já para a etapa de ajuste de histórico é utilizado o algoritmo de *Adjoint-Gradient Based Randomized Maximum Likelihood Procedure* ou em uma tradução livre¹, Procedimento Randomizado de Máxima Probabilidade Baseado em Gradiente Adjunto, conforme OLIVER *et al.* (1996).

É conveniente ressaltar que, apesar de possuir um conjunto M com diversos

¹Devido a dificuldade da tradução de nomenclatura de alguns termos para o português, optou-se por incluir os termos originais em inglês como uma forma de facilitar a busca pelas referências originais. Para os termos em que não foi encontrado uma tradução bem estabelecida na literatura em português foram feitas traduções livres pelo autor.

modelos geológicos, a otimização é feita sobre um número selecionado de modelos, denominados modelos representativos. A quantidade selecionada é escolhida por um critério de aceitação definido pelo autores. Essa otimização do plano de desenvolvimento no qual o número de MR é revalidado a cada ciclo é denominado pelos autores de *Optimization with Sample Validation* (OSV) ou, Otimização com Validação da Amostra.

O primeiro exemplo no qual a metodologia foi testada consistia em um reservatório 2D com uma malha uniforme de 60×60 blocos no qual seriam perfurados, no máximo, 8 poços. O tempo de perfuração de cada poço foi de 210 dias, seguido de um período de 1.320 dias até o final da vida produtiva do campo. Para o caso em que a otimização foi com 3 modelos representativos, o PD final, quando aplicado ao modelo real, apresentou um VPL 2,4 vezes maior do que aquele que foi otimizado no primeiro ciclo. Os autores repetiram o problema com 5 e 10 modelos representativos. Com mais MR participando da otimização, a diferença entre a média dos selecionados e o modelo de referência diminuiu, porém, com um maior custo computacional. A solução de compromisso oferecida pelos autores consistiu na utilização do OSV. Este apresentou um VPL final intermediário - maior do que o obtido com 5 modelos representativos e menor do que o obtido com 10 - mas com um menor custo computacional (MR = 10 com 350.000 simulações; MR = 5 com 180.000 simulações e OSV com 220.000 simulações).

O segundo exemplo tratou de um modelo 3D composto por um reservatório $30 \times 30 \times 5$ no qual se queria otimizar a locação e os controles de 3 poços produtores e 3 poços injetores perfurados alternadamente com um intervalo de 210 dias, seguido de um período final de 720 dias. A aplicação do DCMF com OSV levou a um ganho de 20% em relação à estratégia inicial.

Os resultados obtidos por SHIRANGI e DURLOFSKY (2015) se mostram promissores, com ganhos interessantes, ainda que atrelados a um alto custo computacional. Nota-se também que a metodologia do DCMF é genérica, de forma que métodos alternativos para cada uma das etapas podem ser explorados.

Em um trabalho voltado para evolução do risco durante o desenvolvimento de campos de petróleo, MOROSOV (2016), MOROSOV e SCHIOZER (2016) utilizaram o DCMF no campo UNISIM-I. O plano de desenvolvimento consistia em 13 poços produtores e 7 injetores e foram realizados três ciclos de aquisição de dados. A incorporação dos dados de perfis foi feito gerando novas realizações geológicas a cada ciclo por meio de simulação geostatística. Para o ajuste do histórico de produção foi utilizado o método *Ensemble Smoother With Multiple Data Assimilation* (ES-MDA) ou Suavizador por Conjunto com Múltipla Assimilação de Dados (EMERICK e REYNOLDS (2013)). A seleção dos modelos representativos seguiu o trabalho de MEIRA *et al.* (2016). Já a otimização do plano de desenvolvimento

foi feito com o Exploração Definida e Evolução Controlada (*Designed Exploration and Controlled Evolution*), disponível no software CMOST da CMG. É importante ressaltar que o número de poços foi mantido fixo e as locações podiam variar em torno de uma malha de drenagem inicialmente proposta. Ao final dos três ciclos, o autor chegou a um PD que apresentou uma redução das incertezas e um VPL médio (calculado no conjunto de modelos) maior em 19% quando comparado com o plano de desenvolvimento inicial. Entretanto, de uma maneira surpreendente, a aplicação do DCMF não resultou em ganhos quando aplicado no modelo de referência. Em outras palavras, o PD inicial obteve um VPL maior do que o PD fruto da aplicação do DCMF ao longo da fase do desenvolvimento da produção. O autor expôs algumas possíveis causas para tal comportamento. Cita o fato do modelo de referência ser mais heterogêneo e o processo de transferência de escala possivelmente ter comprometido a produtividade dos poços.

Os resultados promissores de SHIRANGI e DURLOFSKY (2015) em contraponto aos resultados de MOROSOV (2016), aliados à pouca literatura de casos reais na qual a metodologia do DCMF é aplicada evidencia a necessidade da continuidade dos estudos, fato que este trabalho se propôs a fazer. Outra possível causa para essa discrepância de resultados pode ser atribuída aos métodos específicos utilizados em cada uma das etapas. De fato, o conceito de DCMF é bastante geral, contudo, o sucesso do processo é dependente do desempenho das técnicas específicas utilizadas. A seguir é apresentada uma revisão dos métodos utilizados no presente trabalho.

2.2 Ajuste de Histórico

O ajuste de histórico pode ser entendido como a busca pelo vetor de variáveis do modelo, \mathbf{m} , representativo das propriedades do reservatório sobre o qual é aplicada uma transformação matemática $\mathbf{g}(\cdot)$ para obtenção dos dados previstos \mathbf{d} . Uma forma de denotar essa relação é dada por:

$$\mathbf{g}(\mathbf{m}) = \mathbf{d}. \quad (2.1)$$

Quando são conhecidos os parâmetros e é feita a previsão do comportamento futuro por meio de $\mathbf{g}(\mathbf{m})$, tem-se o problema direto. Conceitualmente, caso fossem conhecidas todas as propriedades do reservatório, seria possível desenvolver uma transformação (a própria simulação de fluxo) capaz de prever o resultado de qualquer ação tomada. Entretanto, as características intrínsecas dos reservatórios de petróleo, localizados geralmente a vários metros de profundidade e com uma disponibilidade escassa de dados, impedem o seu conhecimento por completo. O que se tem são

algumas poucas observações diretas nos locais em que foram perfurados poços e observações indiretas como dados de produção e sísmica. Dessa forma, o ajuste de histórico pode ser entendido como um problema inverso no qual em posse de alguns poucos dados observados, \mathbf{d}_{obs} , deseja-se inferir as propriedades dos reservatórios, \mathbf{m} . A equação a ser resolvida, considerando que existem erros nas medições dos dados, ϵ , é dada por:

$$\mathbf{d}_{\text{obs}} = \mathbf{g}(\mathbf{m}) + \epsilon. \quad (2.2)$$

Problemas inversos geralmente são mal postos e o ajuste de histórico também se comporta dessa maneira. Devido a existência de ruído, dificilmente existirá o vetor \mathbf{m} que forneça um ajuste exato. Entretanto, existirão diversos vetores \mathbf{m} que levarão a ajustes igualmente satisfatórios dentro de uma certa tolerância. Além disso, segundo OLIVER *et al.* (2001), a não linearidade entre as variáveis do modelo e os dados observados torna o processo de ajuste de histórico de dados de produção particularmente desafiador.

Ainda que o ajuste de histórico sirva para a obtenção do vetor de propriedades \mathbf{m} capaz de honrar os dados observados, o seu objetivo final consiste em obter modelos ajustados capazes de prever o comportamento futuro do reservatório com um maior grau de confiança. Em posse dos modelos ajustados, diversos estudos são possíveis: previsão da produção futura, locação dos poços, esquemas de injeção etc. Devido ao desenvolvimento dessa linha de estudo, hoje não basta obter um único modelo ajustado, trabalha-se um conjunto de modelos ajustados que quantifique as incertezas do comportamento futuro do reservatório.

OLIVER e CHEN (2010) fizeram uma extensa revisão dos avanços no problema do ajuste de histórico: abordaram as formas de parametrização dos modelos, os tipos de dados a serem ajustados, o formato da função objetivo que será minimizada e os métodos de quantificação de incerteza. Discorreram ainda sobre os diferentes métodos de ajuste de histórico, o que é de particular interesse uma vez que um método específico foi utilizado neste trabalho como parte integrante do DCMF. Segundo os autores, ainda não existe um método que seja o melhor independentemente do problema, a escolha depende dos parâmetros envolvidos e dos dados a serem ajustados. A Tabela 2.1 apresenta as vantagens e desvantagens de cada um dos principais métodos de ajuste de histórico. Pode-se observar que o *Ensemble Kalman Filter* (EnKF) ou Filtro de Kalman por Conjunto, no qual incluem-se suas variações, possuem vantagens interessantes quando é levado em conta o problema que foi estudado neste trabalho: um caso baseado em um campo real, com vários parâmetros a serem ajustados utilizando um simulador de fluxo comercial e contando com o auxílio de um *cluster* de computadores. Ainda, segundo os autores,

entre todos os métodos, o EnKF é o que mais se aproxima como solução para o problema de ajuste de histórico em casos reais.

Tabela 2.1: Comparação das vantagens e desvantagens dos métodos de ajuste de histórico, adaptado de OLIVER e CHEN (2010).

Método	Vantagens	Desvantagens
Manual	- Grande flexibilidade para parâmetros e dados	- Avaliação das incertezas ruim - Grande esforço para obtenção de um único modelo ajustado - Não recomendada para grande número de variáveis - Não consegue ajustes detalhados
Evolutivo	- Recomendado para parâmetros discretos - Recomendado para distribuições não gaussianas - Facilmente adaptável para simuladores	- Convergência lenta - Não recomendada para grande número de variáveis - Avaliação das incertezas é ruim
Adjunto	- Rápida convergência perto do mínimo - Relativamente eficiente para um ajuste único de histórico	- A avaliação das incertezas requer inúmeros ajustes de histórico - Difícil adaptação para simuladores ou variáveis
Ensamble	- Altamente paralelizável	- Geralmente subestima as incertezas
Kalman	- Recomendado para grande número de variáveis	- Requer parametrização adicional para variáveis discretas
Filter	- Facilmente adaptável para simuladores - Avaliação das incertezas é um produto da assimilação de dados	- Não se adapta muito bem em variáveis que possuem distribuições multimodais

PETERS *et al.* (2010b) apresentaram os resultados de uma competição que antecedeu o *SPE Applied Technology Workshop*. Nela, foi proposto às equipes participantes (Universidades, Operadoras e Companhias de Serviço) buscar maximizar o VPL durante a vida de produção de 30 anos de um campo seguindo uma metodologia de otimização da produção em malha fechada. O campo utilizado, Brugge, possuía mais de 44 mil células ativas, 20 produtores e 10 injetores. As equipes ficaram livres para escolher tanto o método de ajuste de histórico quanto os métodos de otimização da produção. Na comparação final, as três equipes que obtiveram melhores resultados utilizaram o EnKF ou uma de suas variantes na etapa de ajuste de histórico.

A formulação proposta por KALMAN (1960) é a origem dos métodos baseados no Filtro de Kalman. Ela é composta basicamente por duas etapas: previsão e análise (ou assimilação). A primeira consiste nas equações 2.3 e 2.4.

$$\mathbf{y}_n^f = \mathbf{A}\mathbf{y}_{n-1}^a, \quad (2.3)$$

$$\mathbf{C}_{\mathbf{y}_n}^f = \mathbf{A}\mathbf{C}_{\mathbf{y}_{n-1}}^a\mathbf{A}^T + \mathbf{C}_\varepsilon. \quad (2.4)$$

Aqui \mathbf{y} representa o vetor de estado a ser estimado para o sistema, \mathbf{A} é a matriz que descreve a dinâmica do sistema, \mathbf{C}_y a matriz de covariância do sistema, \mathbf{C}_ε a matriz de covariância representando o ruído do modelo. O subscrito n é referente ao tempo e os sobrescritos f e a referem-se aos passos de previsão (*forecast*) e análise (*analysis*). O sobrescrito T refere-se a operação de transposição da matriz. Nesta

etapa são previstos valores para o vetor de estado e para a sua covariância baseado na etapa anterior (caso for a primeira previsão, a previsão é feita baseado nos valores iniciais). Em seguida, temos o cálculo do ganho de Kalman dado por:

$$\mathbf{K}_n = \mathbf{C}_{y_n}^f \mathbf{H}^T (\mathbf{H} \mathbf{C}_{y_n}^f \mathbf{H}^T + \mathbf{C}_{d_n})^{-1}, \quad (2.5)$$

onde \mathbf{K} é o ganho de Kalman, \mathbf{H} dá a relação linear entre dados observados e estados e \mathbf{C}_d é a matriz de covariância dos erros de medição. O subscrito n e os sobrescritos f , a e T seguem as mesmas definições anteriores. Finalmente, na etapa de análise, os valores previstos são corrigidos para incluir os novos dados medidos.

$$\mathbf{y}_n^a = \mathbf{y}_n^f + \mathbf{K}_n (\mathbf{d}_{obs,n} - \mathbf{H} \mathbf{y}_n^f), \quad (2.6)$$

$$\mathbf{C}_{y_n}^a = (\mathbf{I} - \mathbf{K}_n \mathbf{H}) \mathbf{C}_{y_n}^f. \quad (2.7)$$

Aqui \mathbf{d}_{obs} representa os dados observados e \mathbf{I} é a matriz identidade. O fluxograma desse processo pode ser visto na Figura 2.3.

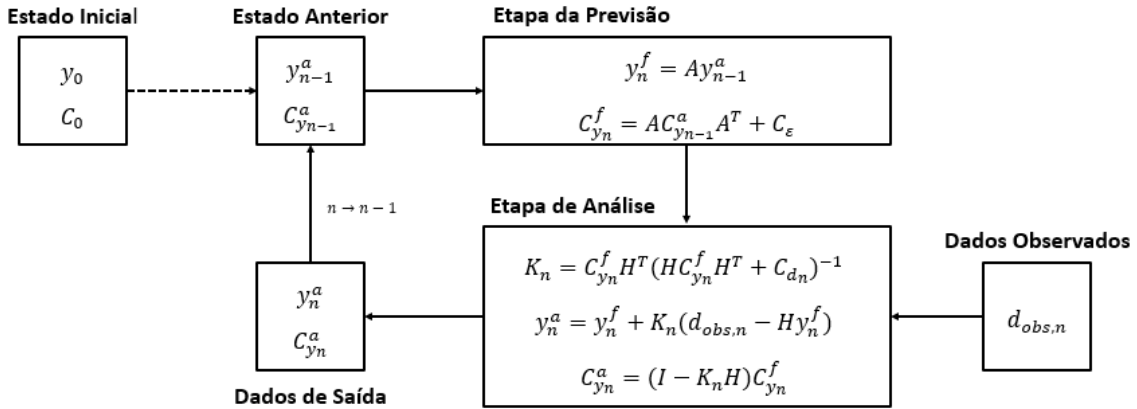


Figura 2.3: Fluxograma das etapas de uma estimativa feita com o Filtro de Kalman.

Uma forma de melhor compreender a sequência de etapas do Filtro de Kalman consiste na resolução de um exemplo simples. Tome-se o caso em que se quer estimar a posição (altura) de uma esfera em queda livre em um local em que a gravidade vale $9,8 \text{ m/s}^2$. Assume-se que o arrasto é nulo, que as variâncias do sistema são dadas por $\sigma_y^2 = 25 \text{ m}^2$ e $\sigma_v^2 = 4 \text{ (m/s)}^2$. Além disso, assume-se que são feitas medições de altura e a variância dessas observações é dada por $\sigma_{y_{obs}}^2 = 4 \text{ m}^2$. Assim, serão assimilados sequencialmente dados observados relativos à altura da esfera. A altura inicial verdadeira é desconhecida e como estimativa inicial, adota-se $y_0 = 70 \text{ m}$ e que $v_0 = 0 \text{ m/s}$. Com base nessas premissas é possível definir o estado inicial.

$$\mathbf{y}_0 = \begin{bmatrix} y_0(m) \\ v_0(m/s) \end{bmatrix} = \begin{bmatrix} 70 \\ 0 \end{bmatrix}.$$

A matrix de covariância do estado inicial, \mathbf{C}_0 é formada pelas variâncias na diagonal principal e pelas covariâncias nos demais lugares. Considerando uma independência dos dados tem-se covariâncias nulas.

$$\mathbf{C}_0 = \begin{bmatrix} \sigma_y^2 & 0 \\ 0 & \sigma_v^2 \end{bmatrix} = \begin{bmatrix} 25 & 0 \\ 0 & 4 \end{bmatrix}.$$

Como \mathbf{y}_0 e \mathbf{C}_0 na primeira previsão é o próprio estado anterior, pode-se passar para a etapa da previsão, conforme a Figura 2.3. A previsão da altura é dada pela relação de movimento uniforme variado.

$$y(t) = y(t_0) + v(t_0)(t - t_0) - \frac{g}{2}(t - t_0)^2.$$

Com isso, é possível elaborar um esquema recursivo no qual a altura da esfera na etapa n é função de sua posição e velocidade na etapa precedente, ou seja, $n - 1$. Para $t_0 = 0$ e as medições feitas em incrementos de $\Delta t = 1$ segundos, pode-se definir a matriz \mathbf{A} .

$$\mathbf{y}_{n+1}^f = \mathbf{A}\mathbf{y}_n^a + \mathbf{b} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} \mathbf{y}_n + \begin{bmatrix} \frac{-1}{2} \\ -1 \end{bmatrix} g.$$

Pode-se fazer, portanto, a primeira previsão.

$$\begin{aligned} \mathbf{y}_1^f &= \mathbf{A}\mathbf{y}_0^a + \mathbf{b} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 70 \\ 0 \end{bmatrix} + \begin{bmatrix} \frac{-9,8}{2} \\ -9,8 \end{bmatrix} \\ &= \begin{bmatrix} 65, 1 \\ -9, 8 \end{bmatrix}. \end{aligned}$$

Desprezando o erro de modelagem, o que corresponde a assumir que \mathbf{C}_ε é nulo, a previsão da matriz $\mathbf{C}_{\mathbf{y}_1}^f$ utilizando a Equação 2.4 é dada por:

$$\mathbf{C}_{\mathbf{y}_1}^f = \mathbf{A}\mathbf{C}_{\mathbf{y}_0}^a\mathbf{A}^T + \mathbf{C}_\varepsilon = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 25 & 0 \\ 0 & 4 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 1 & 1 \end{bmatrix} = \begin{bmatrix} 29 & 4 \\ 4 & 4 \end{bmatrix}.$$

Para o cálculo do ganho de Kalman é necessário a obtenção da matriz \mathbf{H} , que relaciona os dados observados e os estados. Como são feitas medidas da altura se tem,

$$d_{obs} = \mathbf{H}\mathbf{y}_n = \begin{bmatrix} 1 & 0 \end{bmatrix} \mathbf{y}_n.$$

Inicia-se então a etapa de análise com o cálculo do ganho de Kalman, dado pela Equação 2.5.

$$\begin{aligned} \mathbf{K}_1 &= \mathbf{C}_{y_1}^f \mathbf{H}^T (\mathbf{H} \mathbf{C}_{y_1}^f \mathbf{H}^T + \mathbf{C}_{d_1})^{-1} \\ &= \begin{bmatrix} 29 & 4 \\ 4 & 4 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} \left(\begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} 29 & 4 \\ 4 & 4 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} + \begin{bmatrix} 4 \end{bmatrix} \right)^{-1} \\ &= \begin{bmatrix} 0,88 \\ 0,12 \end{bmatrix}. \end{aligned}$$

Um ponto interessante a ser ressaltado é o significado do ganho de Kalman. Na Equação 2.6 nota-se que ele pondera os valores estimados pela relação linear e os valores observados. Valores maiores de \mathbf{K} significam que os erros nos dados observados são menores, e portanto, dá-se um peso maior a eles no vetor de estado estimado após a análise. Analogamente, valores menores de \mathbf{K} indicam que os erros nos dados observados são impactantes e, portanto, são estes que devem receber um maior peso.

Pode-se passar para a etapa da análise. Supondo que os primeiros dados observados sejam $d_{obs,1} = 99,2 \text{ m}$, para a estimativa altura é utilizada a Equação 2.6.

$$\begin{aligned} \mathbf{y}_1^a &= \mathbf{y}_1^f + \mathbf{K}_1(d_{obs,1} - \mathbf{H}\mathbf{y}_1^f) \\ &= \begin{bmatrix} 65,1 \\ -9,8 \end{bmatrix} + \begin{bmatrix} 0,88 \\ 0,12 \end{bmatrix} \left(\begin{bmatrix} 99,2 \end{bmatrix} - \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} 65,1 \\ -9,8 \end{bmatrix} \right) \\ &= \begin{bmatrix} 95,07 \\ -5,67 \end{bmatrix}. \end{aligned}$$

Calcula-se a estimativa da matriz de covariância com a Equação 2.7.

$$\begin{aligned} \mathbf{C}_{y_1}^a &= (\mathbf{I} - \mathbf{K}_n \mathbf{H}) \mathbf{C}_{y_n}^f \\ &= \left(\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} - \begin{bmatrix} 0,88 \\ 0,12 \end{bmatrix} \begin{bmatrix} 1 & 0 \end{bmatrix} \right) \begin{bmatrix} 29 & 4 \\ 4 & 4 \end{bmatrix} \\ &= \begin{bmatrix} 3,52 & 0,49 \\ 0,49 & 3,52 \end{bmatrix}. \end{aligned}$$

Na Figura 2.3 nota-se que \mathbf{y}_1^a e $\mathbf{C}_{\mathbf{y}_1}^a$ é o resultado obtido após a assimilação dos primeiros dados. Como é um processo sequencial, o próximo passo (passado um $\Delta t = 1$ segundo) utiliza \mathbf{y}_1^a e $\mathbf{C}_{\mathbf{y}_1}^a$ como estado inicial e uma nova observação, d_{obs_2} é assimilado. Supondo $d_{obs,2} = 75,5 m$ e seguindo os passos acima a estimativa após a análise é de $\mathbf{y}_2^a = 78,5 m$. A Figura 2.4.

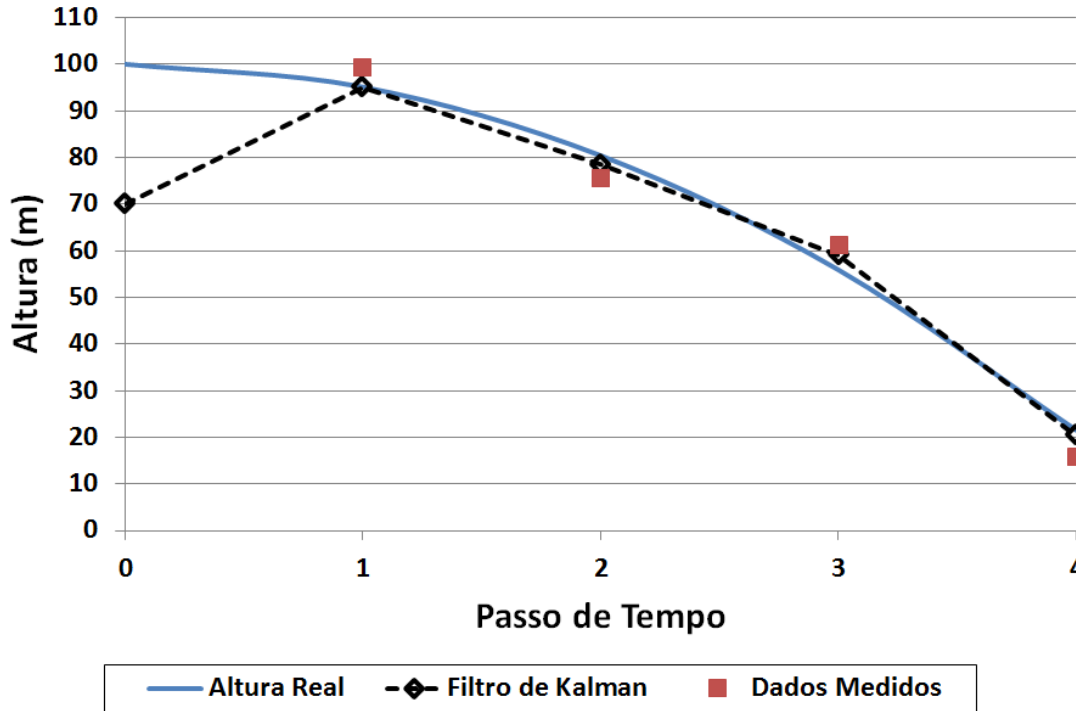


Figura 2.4: Assimilação sequencial dos dados observados com o Filtro de Kalman: comparação entre dados reais, dados observados e dados estimados do o Filtro de Kalman.

Conforme pôde ser visto no exemplo, o filtro de Kalman solicita o cálculo da matriz de covariância a cada incorporação de dados. Em problemas envolvendo o fluxo no meio poroso essa matriz é tipicamente muito grande e exige um esforço computacional que, segundo OLIVER *et al.* (2008), torna o método impraticável para o ajuste de histórico. Além disso, a linearidade presumida na equação 2.3 não é válida para reservatórios multifásicos. Foi proposto o Filtro de Kalman Estendido ou *Ensemble Kalman Filter* como uma forma de tratar problemas com modelos não lineares, mas o esforço computacional no cálculo da matriz de covariância persistia.

Para lidar com problemas de assimilação em sistemas de larga escala foram introduzidos os métodos baseados em conjuntos, ou *Ensembled-Based Methods*. A diferença consiste que as matrizes de covariância são calculadas de maneira aproximada. Um dos mais populares, devido às vantagens anteriormente elencadas, foi o *Ensemble Kalman Filter*, introduzido por EVENSEN (1994). No problema de ajuste de histórico, a primeira aplicação utilizando o EnKF foi apresentada por NÆVDAL

et al. (2002), ao atualizar o modelo do reservatório nas proximidades do poço à medida em que novos dados eram obtidos. Observou-se uma melhora na previsão conforme novos dados se tornavam disponíveis. SKJERVHEIM *et al.* (2007) apresentaram uma dedução detalhada do EnKF ao tratar do problema da atualização contínua de modelos com a incorporação de dados de produção e de sísmica. Isso foi feito tanto para casos sintéticos como em uma aplicação real em um campo do mar do Norte. AANONSEN *et al.* (2009) fizeram uma extensa revisão do desenvolvimento e das técnicas do EnKF na engenharia de reservatórios e concluiu que os principais desafios na utilização do EnKF estavam relacionados com a aplicação em modelos em campos de larga escala, a não linearidades nos modelos de fluxo, a não representatividade da matriz de covariância calculada de forma aproximada e um conjunto de modelos iniciais não Gaussianos.

Em relação à dificuldade de aplicação em campos de larga escala, pode-se entender que isso em parte é devido ao fato do EnKF ser uma forma de assimilação de dados sequencial. A cada novo passo de tempo um novo vetor de estado aumentado (com a representação tanto das variáveis do modelo quanto do sistema dinâmico) é calculado, o que equivale, na simulação de reservatórios, à criação de uma re-inicialização (*restart*) o que traz dificuldades de desempenho. Outro problema está relacionado com as aproximações que são adotadas no passo da análise que podem levar a resultados inconsistentes ou não realísticos e a instabilidades numéricas.

Para contornar o problema do uso de *restarts*, foi proposto o Suavizador por Conjunto ou *Ensemble Smoother* (ES). Nele, ao invés de uma assimilação sequencial, todos os dados são assimilados de uma única vez. SKJERVHEIM *et al.* (2011) aplicaram essa metodologia pela primeira vez e ao compará-la com o EnKF tanto em casos sintéticos como em um modelo de um campo do Mar do Norte, concluíram que os desempenhos eram similares em relação à qualidade do ajuste. Entretanto, o ES acabava com o problema dos *restarts* o que o tornava muito mais rápido e fácil de implementar. O equacionamento do ES pode ser dado por:

$$\mathbf{m}_j^a = \mathbf{m}_j^f + \mathbf{C}_{\mathbf{md}}^f \left(\mathbf{C}_{\mathbf{dd}}^f + \mathbf{C}_{\mathbf{d}} \right)^{-1} \left(\mathbf{d}_{obs,j} - \mathbf{d}_j^f \right). \quad (2.8)$$

Nota-se que no ES são estimados somente os parâmetros do modelo \mathbf{m} tais como porosidade, permeabilidade, contato óleo-água etc. Não há mais a necessidade de armazenar sequencialmente as variáveis do sistema dinâmico, o que equivale a eliminar o uso dos *restarts*. $\mathbf{C}_{\mathbf{md}}$ é a matriz de covariância entre parâmetros e dados simulados, $\mathbf{C}_{\mathbf{dd}}$ é a matriz de covariância dos dados simulados e $\mathbf{C}_{\mathbf{d}}$ é a matriz de covariância do ruído dos dados observados. Caso não exista correlação entre os erros de medição, $\mathbf{C}_{\mathbf{d}}$ se torna diagonal com os valores correspondendo à variância dos dados observados tal como no exemplo resolvido anteriormente. Ainda se têm os

dados observados, \mathbf{d}_{obs} e os dados simulados \mathbf{d} . A equação 2.8 seria a equivalente à equação 2.6 do filtro de Kalman. Por se tratar de um conjunto, tem-se o subscrito $j = 1, 2, \dots, N_e$ onde N_e é o número de elementos. Assim como no equacionamento do Filtro de Kalman, o sobrescrito f se refere à previsão e a à análise. As matrizes de covariância \mathbf{C}_{md} e \mathbf{C}_{dd} são obtidas a partir do conjunto por meio das equações:

$$\mathbf{C}_{md}^f = \frac{1}{N_e - 1} \sum_{j=1}^{N_e} (\mathbf{m}_j^f - \bar{\mathbf{m}}^f)(\mathbf{d}_j^f - \bar{\mathbf{d}}^f)^T, \quad (2.9)$$

$$\mathbf{C}_{dd}^f = \frac{1}{N_e - 1} \sum_{j=1}^{N_e} (\mathbf{d}_j^f - \bar{\mathbf{d}}^f)(\mathbf{d}_j^f - \bar{\mathbf{d}}^f)^T, \quad (2.10)$$

$$\bar{\mathbf{m}}^f = \frac{1}{N_e} \sum_{j=1}^{N_e} \mathbf{m}_j^f, \quad (2.11)$$

$$\bar{\mathbf{d}}^f = \frac{1}{N_e} \sum_{j=1}^{N_e} \mathbf{d}_j^f. \quad (2.12)$$

Apesar de solucionar o problema dos *restarts*, no ES é feita uma única assimilação de todos os dados disponíveis o que pode, segundo EMERICK e REYNOLDS (2013), não ser suficiente para condicionar os modelos de uma maneira aceitável. Um método iterativo, entretanto, poderia resolver esse problema. Assim, os autores propuseram o *Ensemble Smoother with Multiple Data Assimilation* (ES-MDA) que pode ser entendido como a aplicação iterativa do ES. Ao invés de aplicar uma única assimilação são feitas com sucessivas correções menores em um número pré-determinado de vezes. Os resultados obtidos pelos autores mostraram que a utilização do ES-MDA conseguiu melhores ajustes do que o EnKF, com um custo computacional compatível. A Figura 2.5 mostra um dos resultados obtidos. O problema em questão consistia em tentar ajustar o valor da permeabilidade de um conjunto de 100 modelos a partir da observação de dados de vazão de óleo. As curvas em cinza representam os valores da permeabilidade ao longo do poço para o conjunto. A curva vermelha, o valor real e a curva verde, a média do conjunto. Nota-se um ajuste muito mais preciso com a utilização do ES-MDA, sobretudo quando o dado é assimilado 4 vezes.

O equacionamento do ES-MDA é próximo ao do ES mas por ser iterativo, a equação 2.8 passa a ser assimilada um número pré-determinado de vezes, N_a . A covariância do ruído dos dados observados é inflada por um valor $\alpha > 1$:

$$\mathbf{m}_j^{k+1} = \mathbf{m}_j^k + \mathbf{C}_{md}^k (\mathbf{C}_{dd}^k + \alpha_k \mathbf{C}_d)^{-1} (\mathbf{d}_{obs,j} - \mathbf{d}_j^k). \quad (2.13)$$

O sobrescrito k pode ser entendido como a contagem da iteração e a assimilação

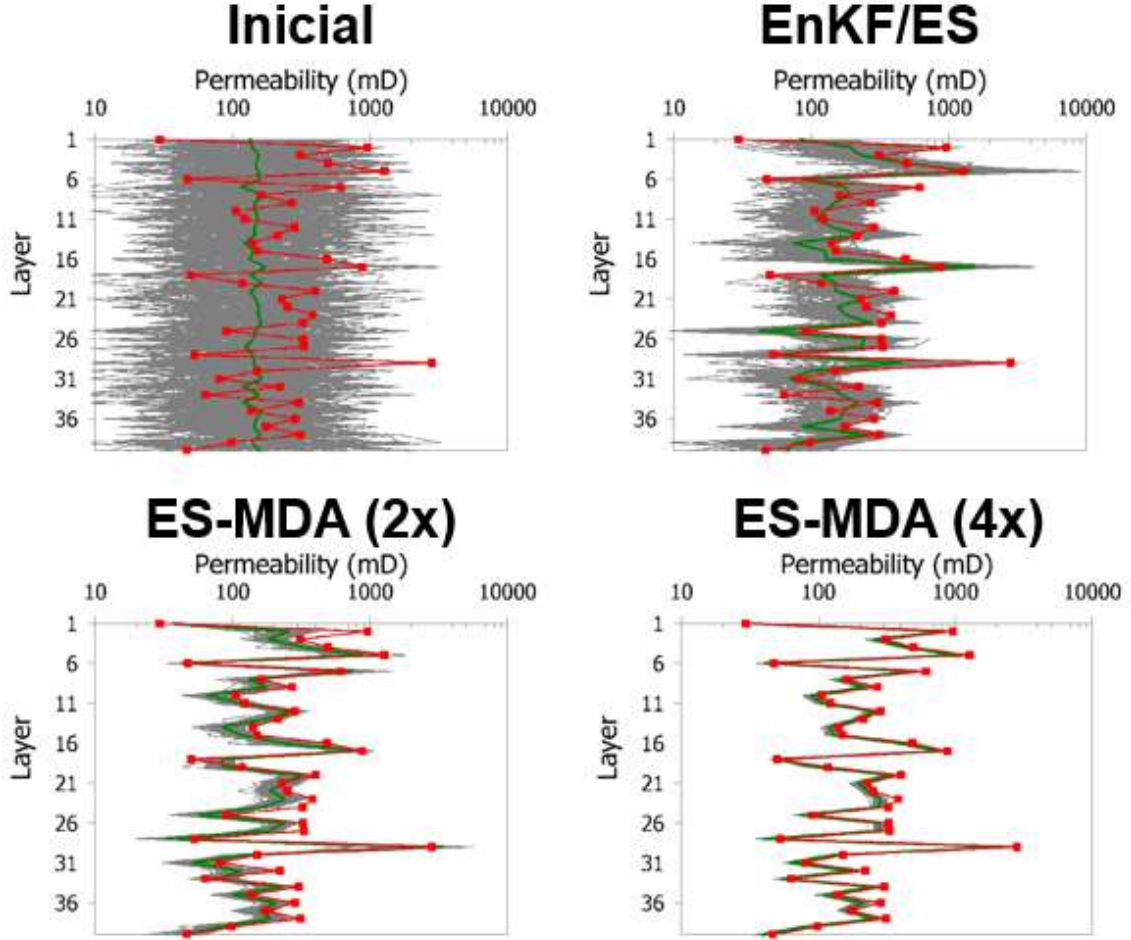


Figura 2.5: Comparação entre o ajuste de histórico com os diferentes métodos: EnKF/ES, ES-MDA(2x) e ES-MDA(4x). Adaptado de EMERICK e REYNOLDS (2013).

dos dados será feita com $k = 1, 2, \dots, N_a$. O valor de α deve ser escolhido de tal maneira que ao final seja válida a condição:

$$\sum_{k=1}^{N_a} \frac{1}{\alpha_k} = 1. \quad (2.14)$$

Em todos os métodos de ajuste de histórico é necessário avaliar a qualidade do ajuste. Isso é feito por meio da utilização de uma função objetivo que quantifique a diferença entre os dados simulados e os dados observados. Uma forma de representá-la considerando a soma dos quadrados da diferença entre dados medidos e simulados é:

$$O_j = \frac{1}{N_d} (\mathbf{d}_{obs} - \mathbf{d})^T \mathbf{C}_d^{-1} (\mathbf{d}_{obs} - \mathbf{d}), \quad (2.15)$$

onde para um elemento j do conjunto calcula-se a função objetivo O na qual \mathbf{d} são os dados simulados, \mathbf{d}_{obs} são os dados observados, \mathbf{C}_d é a matriz de covariância do

ruído dos dados observados e N_d é o número de dados observados. Logo, para um bom ajuste de histórico, a função objetivo deve ser minimizada.

2.3 Seleção de Modelos Representativos

É inegável que metodologias relacionadas ao gerenciamento de reservatórios, ajuste de histórico, otimizações e até mesmo o desenvolvimento de campos de petróleo, como é o caso deste trabalho, estão caminhando na direção de abordagens que utilizem conjuntos. Devido aos progressos na área de geoestatística, hoje é possível gerar inúmeras realizações, isto é, modelos de reservatório que respeitem as restrições de dados de sísmica, poços etc. Esses modelos passam a seguir por algum tipo de função de transferência, como um simulador de fluxo, para obter uma resposta de interesse. Quando feito para todo o conjunto de modelos pode-se criar uma distribuição de probabilidade para quantificar a incerteza, conforme a Figura 2.6.

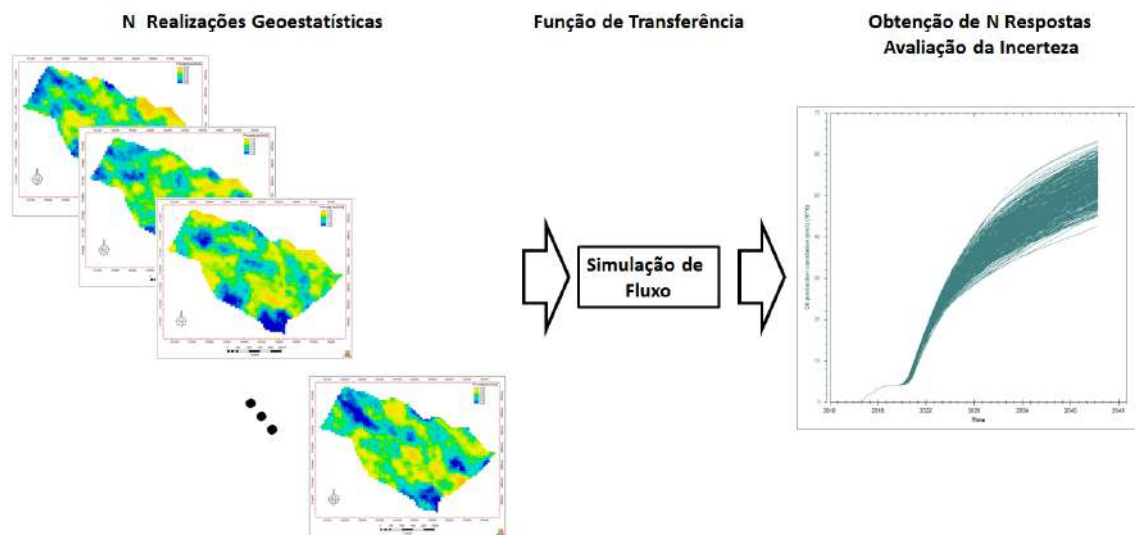


Figura 2.6: Representação esquemática do cálculo da distribuição de probabilidades utilizando um simulador de fluxo, adaptada de SCHEIDT e CAERS (2008).

Entretanto, ainda hoje, as simulações de fluxo representam um gargalo nesse tipo de análise. Por depender muito tempo em sua execução, podem tornar impraticável a correta avaliação de todos os modelos disponíveis. A forma usual adotada pela indústria de petróleo para contornar esse problema consiste em escolher um subconjunto de modelos capaz de representar de maneira adequada o conjunto inicial. A esse processo de escolha dá-se o nome de seleção de modelos representativos.

Existem duas notações utilizadas quando se trabalha com os percentis de uma determinada resposta. A primeira traz no eixo das abscissas, valores crescentes da resposta desejada (como, por exemplo, o VOIP - *Volume of Oil in Place*) e no eixo das ordenadas, a probabilidade acumulada do valor da resposta ser maior ou

igual ao ponto em que se está. Assim, ao se referir ao P_{10} do VOIP existe uma probabilidade de 10% de que o valor real seja maior do que o estimado. É comum se trabalhar com três valores principais, P_{10} , P_{50} e P_{90} que seriam representativos de uma situação otimista, moderada e pessimista. Essa notação fica mais clara ao analisarmos a Figura 2.7, representativa de uma curva de risco. A segunda forma consiste na notação tradicional empregada na estatística com percentis equivalentes à distribuição acumulada até o ponto em questão.

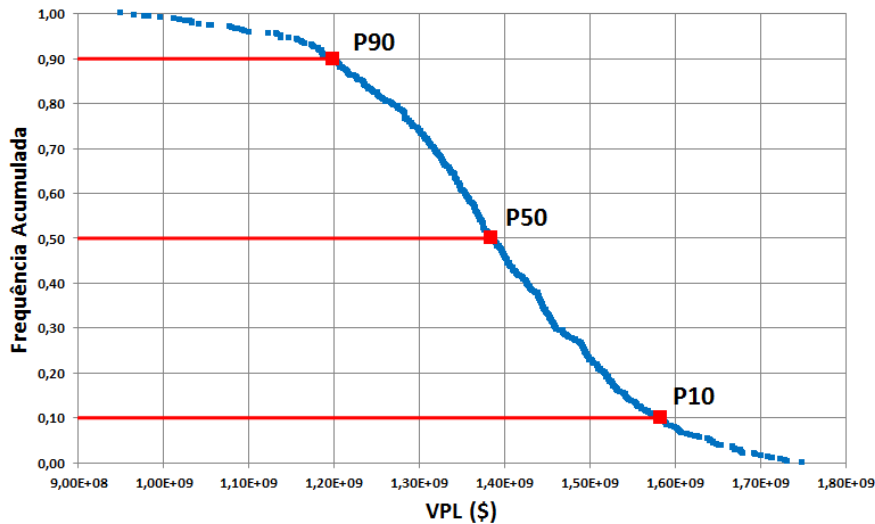


Figura 2.7: Exemplo de P_{10} , P_{50} e P_{90} para o VPL.

Existem diversas formas de abordar o problema de seleção de modelos sendo que de uma maneira geral, pode-se dividir em duas principais estratégias: baseadas em curvas de risco e baseadas em *clusters*.

STEAGALL e SCHIOZER (2001) utilizaram a primeira ao trabalhar com um caso real da Bacia de Campos, realizando a seleção de modelos representativos levando em conta a proximidade em relação aos percentis P_{10} , P_{50} e P_{90} do VPL. De um conjunto inicial possível de 6.561 modelos foram selecionados 7: dois próximos ao P_{90} , três próximos ao P_{50} e dois próximos ao P_{10} . Em cada percentil, a seleção buscava uma variação maior no fator de recuperação.

Seguindo nessa linha, SCHIOZER *et al.* (2004) propuseram uma extensão da ideia, indicando que a escolha dos MR fosse feita selecionando 9 modelos que possuíssem diferenças significativas no fator de recuperação e que estivessem próximas aos percentis P_{10} , P_{50} e P_{90} do VPL. Deveriam ainda apresentar uma grande variação em relação ao N_p (produção acumulada de óleo) e W_p (produção acumulada de água). Isso foi feito com a utilização de gráficos com duas das grandezas que eram analisadas em conjunto. A Figura 2.8 exemplifica o descrito. Fica evidente que, por ser uma seleção manual dos modelos (analisando os gráficos), existe uma grande subjetividade envolvida no processo.

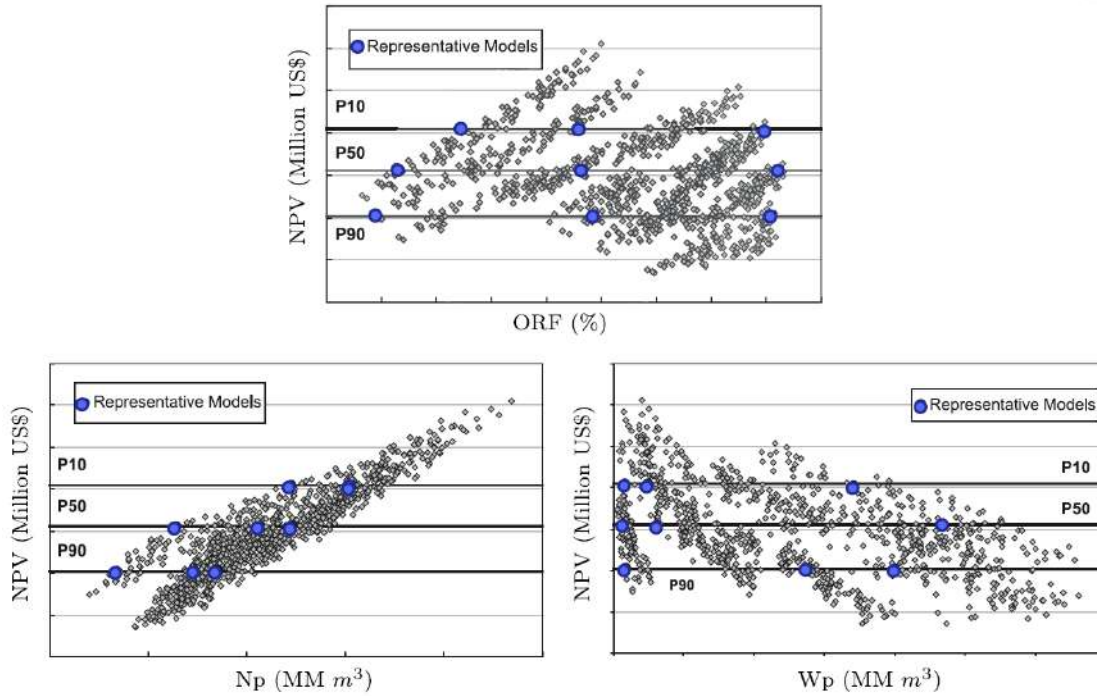


Figura 2.8: Escolha de modelos representativos próximos ao P_{10} , P_{50} e P_{90} para o VPL que também devem ter diferenças significativas no fator de recuperação (ORF), produção acumulada de água (W_p) e produção total de óleo (N_p), SCHIOZER *et al.* (2004)

Uma metodologia próxima a de SCHIOZER *et al.* (2004) foi proposta por MEIRA *et al.* (2016) na qual se buscou eliminar a parte manual e subjetiva envolvida na seleção pelo procedimento em questão. A representatividade de um determinado modelo foi equacionada levando em conta três critérios. O primeiro computou as combinações dois a dois dos resultados normalizados (N_p , FR, VPL etc). O segundo levou em conta a distribuição do conjunto de modelos selecionados na curva de risco, priorizando conjuntos que mantivessem a forma inicial da mesma e que possuísem um espaçamento uniforme. O terceiro valorizou conjuntos no qual a frequência relativa dos atributos incertos fosse a mais próxima dos valores dos conjuntos iniciais. Considerando os três critérios, uma função objetivo geral foi criada para selecionar um subconjunto de modelos. Segundo os autores, bons resultados foram obtidos quando comparados com a seleção manual.

A segunda forma de abordar a seleção de modelos representativos consiste em estratégias baseadas em *clusters*. Neste tipo de seleção, é necessário definir *a priori* o número de modelos que serão escolhidos. Geralmente esse valor está relacionado com tempo disponível para realizar as simulações. Além disso, nesse tipo de seleção são seguidas as seguintes etapas:

1. Cálculo da distância entre modelos;
2. Avaliação da similaridade/dissimilaridade entre o conjunto inicial de modelos

e o subconjunto escolhido;

3. Seleção do melhor subconjunto.

Para a primeira etapa, SUZUKI e CAERS (2008) utilizaram a distância de Hausdorff como uma maneira adequada de capturar as similaridades entre modelos em um caso de fluxo em canais de alta permeabilidade. SCHEIDT e CAERS (2009) propuseram calcular a distância entre modelos utilizando os valores de produção acumulada de óleo e água obtidos a partir de simuladores de fluxo por linhas de corrente.

A escolha do cálculo da distância é um ponto importante sendo que a principal característica a ser considerada consiste na presença de uma correlação razoável com a diferença de resposta entre dois modelos diferentes. Considere, por exemplo, um modelo descrito por w parâmetros tais como: VOIP, FR, Np, Wp, Porosidade, Permeabilidade etc. Seja \mathbf{w} o vetor coluna com esses valores

$$\mathbf{w} = \begin{bmatrix} w_1 & w_2 & \dots & w_w \end{bmatrix}^T. \quad (2.16)$$

Uma medida de distância entre dois modelos quaisquer j e q pode ser dada pela própria distância euclidiana, ou seja:

$$d_{j,q} = ((\mathbf{w}_j - \mathbf{w}_q)^T(\mathbf{w}_j - \mathbf{w}_q))^{0.5}. \quad (2.17)$$

Sabendo que as propriedades possuem ordem de grandeza diferente, faz-se necessário uma adimensionalização. Considerando que se tem um conjunto inicial com N modelos pode-se calcular o parâmetro adimensionalizado w_{ad} .

$$w_{ad} = \frac{w - \bar{w}}{\sigma_w}, \quad (2.18)$$

onde w é o parâmetro, \bar{w} e σ_w são a média e o desvio padrão do parâmetro no conjunto N . Com isso, a equação 2.16 passa a utilizar w_{ad} no lugar de w .

Assim, pode-se calcular a distância entre cada par fazendo variar j e q entre 1 e N . Obtém-se, com isso, a matriz de distâncias, \mathbf{D} com a seguinte forma

$$\mathbf{D} = \begin{bmatrix} 0 & d_{1,2} & d_{1,3} & \dots & d_{1,N} \\ d_{2,1} & 0 & d_{2,3} & \dots & d_{2,N} \\ d_{3,1} & d_{3,2} & 0 & \dots & d_{3,N} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ d_{N,1} & d_{N,2} & d_{N,3} & \dots & 0 \end{bmatrix}. \quad (2.19)$$

Nota-se que devido à definição dada pela Equação 2.17, a matriz \mathbf{D} possui dimensão N por N , é simétrica, ou seja, $d_{j,q} = d_{q,j}$ e possui diagonal nula uma vez que a distância entre um modelo e ele mesmo é zero.

Utilizando métodos de seleção de cenários desenvolvidos no campo de otimização estocástica (HEITSCH (2003) e DUPACOVA *et al.* (2003)), foi proposto um procedimento de busca randômica por ARMSTRONG *et al.* (2012) cobrindo os itens dois e três do processo de seleção de cenários representativos baseados em *clusters*. Parte-se de um conjunto inicial de N modelos, cada um com uma probabilidade p_i e um vetor \mathbf{m}_i , tal como definindo na Equação 2.16 que descreve as propriedades analisadas. Seja ainda $P = \{i = 1, 2, 3, \dots, N\}$ o conjunto de seus índices que, por extensão, pode ser entendido como o próprio conjunto inicial. Suponha que se deseje selecionar n modelos com um conjunto de índices definido como Q e elementos representados por q . Suas probabilidades são dadas por p_q . Pode-se ainda definir o conjunto de índices dos modelos descartados, J , que possui $N - n$ modelos representados por j , cada um com sua probabilidade associada p_j . O que se deseja é minimizar a perda de informação ao eliminar os $N - n$ modelos, ou seja, determinar um conjunto J de uma maneira ótima. Para tanto, considere-se a equação

$$D(J) = \sum_{j \in J} p_j \min_{q \in Q} d_{j,q}, \quad (2.20)$$

onde p_j é a probabilidade do modelo descartado $j \in J$, q os modelos pertencentes ao conjunto selecionado Q e $d_{j,q}$ a distância entre um par de modelos conforme definido pela Equação 2.17. A Equação 2.20 pode ser entendida como a soma das distâncias entre cada modelo descartado e o modelo selecionado mais próximo, ponderado por sua probabilidade. DUPACOVA *et al.* (2003) mostraram que a perda de informação é mínima quando encontramos o conjunto J tal que $D(J)$ é mínimo e ARMSTRONG *et al.* (2012) propuseram o método para encontrá-lo. A primeira etapa consiste em calcular a matriz de distâncias \mathbf{D} entre os pares de modelos. Um conjunto Q com n elementos é selecionado de maneira aleatória dentre os elementos de P . Para os $N - n$ elementos do conjunto J encontra-se qual é o elemento de Q que é mais próximo computando o valor de $D(J)$. Isso é repetido até encontrar o conjunto que forneça o menor valor de $D(J)$. A Figura 2.9 mostra uma representação esquemática dessa sequência. É importante notar que o cálculo de $D(J)$ é repetido para todos os possíveis conjuntos J sendo que o número de combinações possíveis é dado pela combinação de N modelos selecionados n a n , ou seja, $C(N, n) = \binom{N}{n}$.

Uma vez obtido o conjunto Q selecionado, deve-se determinar as probabilidades atualizadas dos cenários mantidos, $p_{q,atualizada}$. Isso é feito somando a probabilidade de cada modelo selecionado com as probabilidades dos modelos descartados mais próximos, isto é

$$p_{q,atualizada} = p_q + \sum_{j \in J_Q} p_j \quad \text{onde } J_Q = \{j \in J : q \in \arg \min_{q \in Q} d_{j,q}\}. \quad (2.21)$$

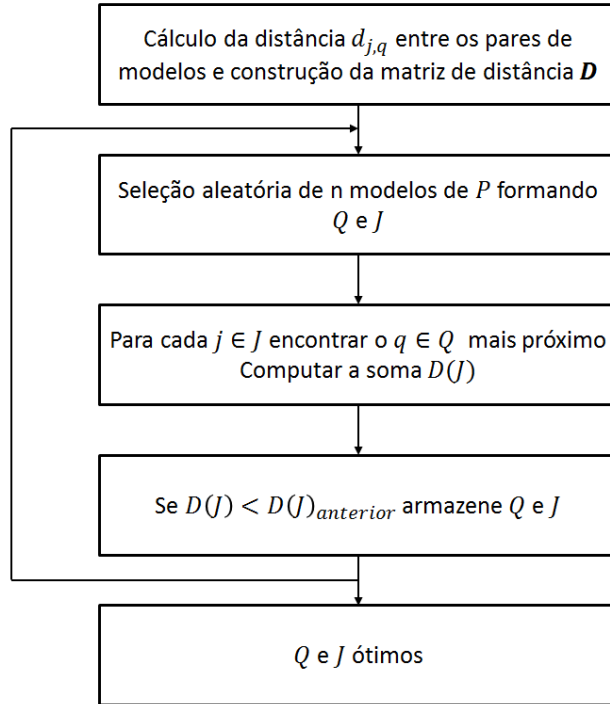


Figura 2.9: Representação esquemática do método de seleção de modelos representativos. Adaptado de ARMSTRONG *et al.* (2012).

Aqui $p_{q,atualizada}$ é a probabilidade atualizada de cada elemento do conjunto Q , p_q é a probabilidade inicial dos modelo q e p_j a probabilidade do modelo descartado j . Pode-se entender a Equação 2.21 como a migração da probabilidade de cada cenário descartado para o modelo mais próximo a ele. O resultado final consiste no conjunto Q de n modelos selecionados e suas respectivas probabilidades $p_{q,atualizada}$.

Para entender de uma maneira mais clara o processo de seleção de cenários representativos, convém realizar um exemplo simplificado. Suponha que existam 10 modelos geológicos equiprováveis (ou seja, $P = \{1, 2, 3, \dots, 10\}$) dos quais se queira selecionar 3 modelos representativos. Admite-se também que já tenham sido feitas as simulações de fluxo e que os parâmetros a serem analisados sejam apenas o VOIP e o VPL.

O vetor \mathbf{w} da Equação 2.16 é dado por $\mathbf{w} = \left[VOIP_{ad} \quad VPL_{ad} \right]^T$. O primeiro passo da Figura 2.9 consiste no cálculo da matriz de distâncias \mathbf{D} com as equações 2.17 e 2.19. Aqui é apresentada a matriz \mathbf{D} calculada já que foi feita a suposição que as simulações foram realizadas e que estão disponíveis os dados de VOIP e VPL para os 10 modelos. Convém ressaltar que, conforme o esperado, ela possui dimensão de 10 por 10, é simétrica e sua diagonal principal é nula.

$$\mathbf{D} = \begin{bmatrix} 0,00 & 2,81 & \mathbf{2,18} & 1,14 & \mathbf{2,28} & \mathbf{0,44} & 1,52 & 2,30 & 1,17 & 1,78 \\ 2,81 & 0,00 & 3,00 & 1,84 & 0,54 & 3,20 & 2,70 & 3,69 & 3,68 & 2,04 \\ 2,18 & 3,00 & 0,00 & 2,60 & 2,58 & 2,13 & 0,67 & 0,76 & 1,85 & 0,98 \\ 1,14 & 1,84 & 2,60 & 0,00 & 1,38 & 1,58 & 1,98 & 3,00 & 2,26 & 1,79 \\ 2,28 & 0,54 & 2,58 & 1,38 & 0,00 & 2,66 & 2,21 & 3,23 & 3,14 & 1,60 \\ 0,44 & 3,20 & 2,13 & 1,58 & 2,66 & 0,00 & 1,50 & 2,09 & 0,76 & 1,93 \\ 1,52 & 2,70 & 0,67 & 1,98 & 2,21 & 1,50 & 0,00 & 1,05 & 1,38 & 0,72 \\ 2,30 & 3,69 & 0,76 & 3,00 & 3,23 & 2,09 & 1,05 & 0,00 & 1,56 & 1,64 \\ 1,17 & 3,68 & 1,85 & 2,26 & 3,14 & 0,76 & 1,38 & 1,56 & 0,00 & 2,02 \\ 1,78 & 2,04 & 0,98 & 1,79 & 1,60 & 1,93 & 0,72 & 1,64 & 2,02 & 0,00 \end{bmatrix}$$

Seleciona-se $n = 3$ modelos descartando os outros $N - n = 7$. Suponha que em uma primeira tentativa A, sejam escolhidos os modelos de índice $Q_A = \{3, 5, 6\}$. Assim, o conjunto dos modelos descartados é $J_A = \{1, 2, 4, 7, 8, 9\}$. A seguir, para cada $j \in J_A$ temos que encontrar o $q \in Q_A$ mais próximo para computar $D(J_A)$.

Para $j = 1$ temos na matriz \mathbf{D} , $d_{1,3} = 2,18$, $d_{1,5} = 2,28$ e $d_{1,6} = 0,44$ de tal forma que $\min_{q \in Q} d_{1,q} = 0,44$. Deve-se repetir a análise para todo $j \in J_A$ o que permite calcular o valor de $D(J_A)$ dado pela Equação 2.20. Como os modelos são equiprováveis, $p_j = 0,1$:

$$D(J_A) = 0,10(0,44 + 0,54 + 1,38 + \dots) = 0,55.$$

Supondo uma nova tentativa, B, de conjunto de três modelos com $Q_B = \{1, 8, 10\}$. Tem-se então:

$$D(J_B) = 0,10(2,04 + 0,76 + 1,79 + \dots) = 1,04.$$

Como $D(J_A) < D(J_B)$ temos que o conjunto A é melhor solução do que B. Isso deveria ser repetido para todos os conjuntos possíveis o que equivaleria a avaliar a Equação 2.20 um número de vezes igual $C(10, 3) = 120$. Fica evidente que ao se trabalhar com um caso real (por exemplo, $N = 500$ e $n = 10$ tem-se $C(500, 10) = 2,45 \cdot 10^{20}$) o cálculo de todas as combinações possíveis torna-se impraticável. Pode-se, no entanto, resolver o problema de minimização utilizando alguma técnica como o algoritmo genético.

Continuando com o exemplo, resta calcular as probabilidades atualizadas do conjunto selecionado. Supondo que o menor $D(J)$ foi obtido com o conjunto $Q_A = \{3, 5, 6\}$ e utilizando a 2.21 para $q = 3$:

$$p_{3,atualizada} = p_3 + \sum_{j \in J_Q} p_j \quad \text{onde } J_Q = \{7, 8, 10\},$$

$$p_{3,atualizada} = 0,10 + 0,10 + 0,10 + 0,10 = 0,40.$$

Procedendo da mesma maneira tem-se $p_{5,atualizada} = 0,3$ e $p_{6,atualizada} = 0,3$. É interessante ressaltar que conforme o esperado, $\sum p_q = 1$.

2.3.1 *Multidimensional Scaling*

Uma vez que foi selecionado o conjunto de modelos representativos é necessária uma ferramenta para analisar a distribuição dessa escolha. Nesse sentido, o *Multidimensional Scaling* (MDS) é uma possível solução. É um método para a visualização de informação que busca revelar a estrutura de um conjunto de dados ao plotar pontos em duas ou três dimensões representando medidas de similaridade (ou dissimilaridade) entre elementos.

Os dados de entrada do MDS possuem a forma de uma medida global da similaridade dos pares de indivíduos que são objeto do estudo como, por exemplo, a matriz de distâncias. A saída, por sua vez, consiste em uma representação espacial na qual cada elemento é representado como um ponto. Isso é feito de tal maneira que a distância entre os pontos é correlacionada com a sua similaridade, ou seja, pontos próximos correspondem a elementos similares e pontos distantes correspondem a elementos dissimilares. A vantagem desta abordagem é que torna visíveis padrões que por vezes permanecem ocultos ao se trabalhar com um conjunto muito grande de parâmetros.

A ideia básica do MDS pode ser melhor entendida com um exemplo geográfico. Olhando para a localização das cidades em um mapa, facilmente são obtidas as distâncias entre elas. Entretanto, suponha o problema inverso: dadas as distâncias entre os pares de cidades, como reconstruir o mapa em duas dimensões? Uma alternativa seria ir alterando a localização por tentativa e erro até conseguir as distâncias desejadas. O procedimento que resolve esse problema de maneira automatizada é o MDS. Neste caso o “multi” do nome do método é igual a dois (já que se está trabalhando em duas dimensões - um mapa) mas não existe restrição ao número de dimensões utilizado. Entretanto, convém ressaltar que a ideia inicial é a de reconhecer visualmente padrões em um gráfico e isso vai se tornar cada vez mais difícil à medida que o número de dimensões aumenta.

Conforme dito anteriormente, o dado de entrada do MDS consiste em uma medida global da similaridade dos pares de indivíduos. Neste caso pode-se utilizar a matriz de distância dada pela Equação 2.19. O algoritmo de implementação foi des-

critério em COX e COX (2000) e é reproduzido a seguir para o caso de duas dimensões.

1. Calcular a matriz $\mathbf{A} = [a_{ij}]$, onde $a_{ij} = d_{ij}^2$ sendo d_{ij} os elementos da matriz de distância \mathbf{D} .
2. Calcular a matriz $\mathbf{B} = -\frac{1}{2}\mathbf{H}\mathbf{A}\mathbf{H}$, onde \mathbf{H} é a matriz de centralização $\mathbf{H} = \mathbf{I} - \frac{1}{N}\mathbf{1}_N\mathbf{1}_N^T$, \mathbf{I} é a matriz identidade N por N e $\mathbf{1}_N$ é um vetor com N linhas de uns.
3. Calcular a decomposição espectral de \mathbf{B} , $\mathbf{B} = \mathbf{E}\mathbf{\Lambda}\mathbf{E}^T$, onde $\mathbf{\Lambda}$ é a matriz diagonal formada pelos autovalores de \mathbf{B} e \mathbf{E} é a matriz com os autovetores de \mathbf{B} .
4. Tomar os dois maiores autovalores positivos de $\mathbf{\Lambda}$ e seus respectivos autovetores, gerando \mathbf{E}_1 e $\mathbf{\Lambda}_1$.
5. Calcular $\mathbf{X} = \mathbf{E}_1\mathbf{\Lambda}_1^{\frac{1}{2}}$, onde as coordenadas dos pontos são dadas pelas colunas de \mathbf{X} .

Para melhor entendimento do algoritmo, pode-se retornar ao problema da reconstrução do mapa em duas dimensões a partir das distâncias. Suponha que sejam conhecidas as distâncias entre quatro cidades: Rio de Janeiro, São Paulo, Maringá e Recife. Os valores são dados pela Tabela 2.2

Tabela 2.2: Distâncias (km) entre as cidades

	Rio de Janeiro	São Paulo	Maringá	Recife
Rio de Janeiro	0.0	434.0	1074.0	2314.0
São Paulo	434.0	0.0	650.0	2645.0
Maringá	1074.0	650.0	0.0	2972.0
Recife	2314.0	2645.0	2972.0	0.0

Com isso tem-se a matriz de distâncias \mathbf{D} .

$$\mathbf{D} = \begin{bmatrix} 0 & 434 & 1074 & 2314 \\ 434 & 0 & 650 & 2645 \\ 1074 & 650 & 0 & 2972 \\ 2314 & 2645 & 2972 & 0 \end{bmatrix} \quad (2.22)$$

O primeiro passo consiste no cálculo da matriz \mathbf{A} , ou seja:

$$\mathbf{A} = \begin{bmatrix} 0 & 188356 & 1153476 & 5354596 \\ 188356 & 0 & 422500 & 6996025 \\ 1153476 & 422500 & 0 & 8832784 \\ 5354596 & 6996025 & 8832784 & 0 \end{bmatrix} \quad (2.23)$$

Sabendo que $N = 4$ pode-se calcular a matriz \mathbf{H} e a matriz \mathbf{B} :

$$\mathbf{H} = \mathbf{I} - \frac{1}{N} \mathbf{1}_N \mathbf{1}_N^T = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} - \frac{1}{4} \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \end{bmatrix}$$

$$\mathbf{H} = \begin{bmatrix} 0.75 & -0.25 & -0.25 & -0.25 \\ -0.25 & 0.75 & -0.25 & -0.25 \\ -0.25 & -0.25 & 0.75 & -0.25 \\ -0.25 & -0.25 & -0.25 & 0.75 \end{bmatrix}. \quad (2.24)$$

$$\mathbf{B} = -\frac{1}{2} \mathbf{H} \mathbf{A} \mathbf{H} = \begin{bmatrix} 239873.4 & 259502.1 & 127176.9 & -626552.4 \\ 259502.1 & 467486.7 & 606471.5 & -1333460.3 \\ 127176.9 & 606471.5 & 1167956.4 & -1901604.9 \\ -626552.4 & -133346.3 & -1901604.9 & 3861617.7 \end{bmatrix}. \quad (2.25)$$

Os dois maiores autovalores positivos de \mathbf{B} são $\lambda_1 = 5375177.1$ e $\lambda_2 = 368696.1$. Seus respectivos autovetores são dados por $\mathbf{e}_1 = \begin{bmatrix} -0.128 & -0.290 & -0.428 & 0.846 \end{bmatrix}^T$ e $\mathbf{e}_2 = \begin{bmatrix} 0.645 & 0.237 & -0.705 & -0.177 \end{bmatrix}^T$.

Pode-se então calcular o último passo:

$$\mathbf{X} = \mathbf{E}_1 \mathbf{\Lambda}_1^{\frac{1}{2}} = \begin{bmatrix} -0.128 & 0.645 \\ -0.290 & 0.237 \\ -0.428 & -0.705 \\ 0.846 & -0.177 \end{bmatrix} \begin{bmatrix} \sqrt{5375177.1} & 0 \\ 0 & \sqrt{368696.1} \end{bmatrix}$$

$$\mathbf{X} = \begin{bmatrix} -297.919 & 391.563 \\ -671.556 & 143.984 \\ -992.675 & -427.833 \\ 1962.150 & -107.714 \end{bmatrix}. \quad (2.26)$$

Plotando os pontos e suas coordenadas em um gráfico tem-se o resultado dado pela Figura 2.10.

Naturalmente que uma rotação ainda seria necessária para tornar a interpretação mais clara, mas já se tem uma boa noção espacial das localizações.

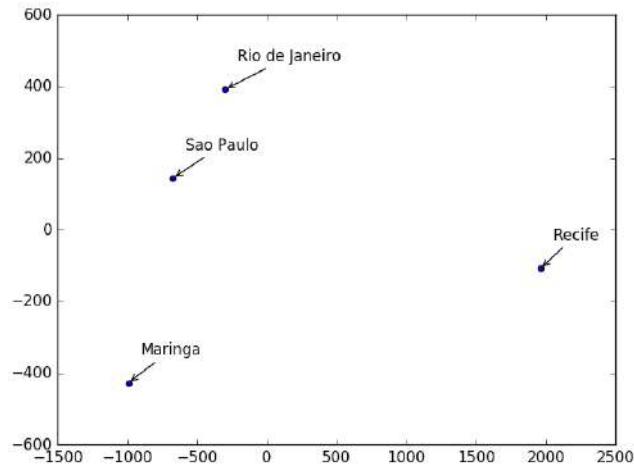


Figura 2.10: Representação das quatro cidades utilizando o MDS.

2.4 Otimização do Plano de Desenvolvimento

A definição do plano de drenagem do reservatório possui importância fundamental no desenvolvimento de um campo de petróleo. Ainda hoje, é bastante comum que um procedimento exclusivamente manual de tentativa e erro baseado na experiência da equipe seja utilizado para determinar a melhor opção de locação dos poços. Entretanto, devido à alta complexidade dos reservatórios e sua não linearidade entre a resposta e os parâmetros de decisão, o uso de algoritmos de otimização pode complementar o conhecimento intuitivo da equipe, trazendo melhores resultados econômicos para o projeto.

Em relação aos algoritmos de otimização, os métodos enumerativos são os mais simples, avaliando cada possível solução, mas isso se pode tornar inviável em casos em que conjunto de possíveis soluções, ou seja, o domínio, é muito grande. Uma forma de contornar essa situação consiste em delimitar o espaço de busca encontrando uma solução “aceitável” em um tempo “aceitável”. Os algoritmos determinísticos são, portanto, os que incorporam esse conhecimento sobre o domínio. Já os algoritmos estocásticos são utilizados quando as técnicas enumerativas e determinísticas não são aplicáveis devido às características do problema. Requerem a atribuição de um valor para as possíveis (ou parte das possíveis) soluções por meio de uma função objetivo além de utilizar uma forma de mapear o domínio. Os algoritmos evolutivos designam diversos métodos estocásticos baseados na biologia evolutiva. Eles buscam simular computacionalmente os processos naturais de evolução tais como hereditariedade, mutação, recombinação e o conceito de Darwin da sobrevivência do mais apto em uma população. O Algoritmo Genético, introduzido por HOLLAND (1975) é o mais difundido. Sua estrutura básica será apresentada a seguir sendo que os termos e conceitos são, em geral, análogos às suas contrapartes

da biologia.

O indivíduo consiste na potencial solução para o problema a ser otimizado e seu genótipo é dado por cromossomos. Estes, por sua vez, são compostos por uma sequência das variáveis que serão otimizadas, os genes. O conjunto de indivíduos é denominado de população. A otimização consiste em submeter a população a um processo evolutivo que, assim como na natureza, ocorre em ciclos, sendo que cada um é denominado de geração. Esses conceitos são ilustrados na Figura 2.11 .

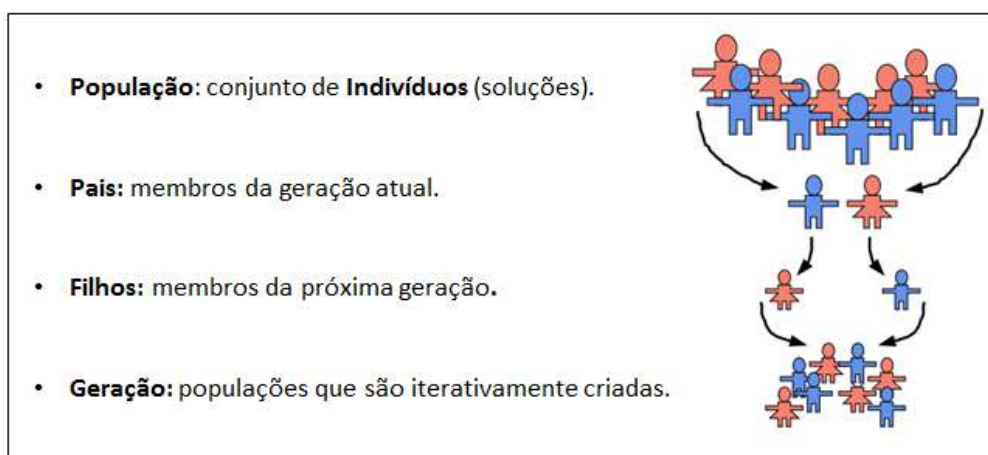


Figura 2.11: Conceitos utilizados no Algoritmo Genético, adaptado de COELLO *et al.* (2006).

O processo evolutivo compreende 4 etapas: avaliação, seleção, recombinação e mutação, conforme pode ser visto na Figura 2.12.

Na avaliação, a aptidão do indivíduo é comparada com a do restante da população por meio de uma função objetivo de modo que os mais aptos possuam maiores chances de serem selecionados como pais. A recombinação e a mutação, dois operadores genéticos, correspondem à reprodução. O primeiro combina os cromossomos dos pais e os passa para os filhos. Já o segundo realiza alterações pontuais randômicas nos genes de maneira a incluir nova informação genética. As taxas de recombinação e mutação, ou seja, a probabilidade desses operadores ocorrerem em cada geração também é relevante já que impactam diretamente no desempenho do algoritmo genético e devem ser ajustadas conforme o problema estudado. Depois de várias gerações é de se esperar que a população conterà indivíduos mais aptos, ou seja, que retornam maiores valores da função objetivo quando comparados com a população inicial. A estrutura de dados presente no processo pode ser vista na Figura 2.13.

Os algoritmos genéticos já são usados na otimização da locação de poços há algum tempo. BITTENCOURT e HORNE (1997) utilizaram um híbrido do algoritmo genético na locação de 33 poços que podiam ser posicionados em qualquer local do reservatório, ser produtores ou injetores, além de verticais ou horizontais, totalizando

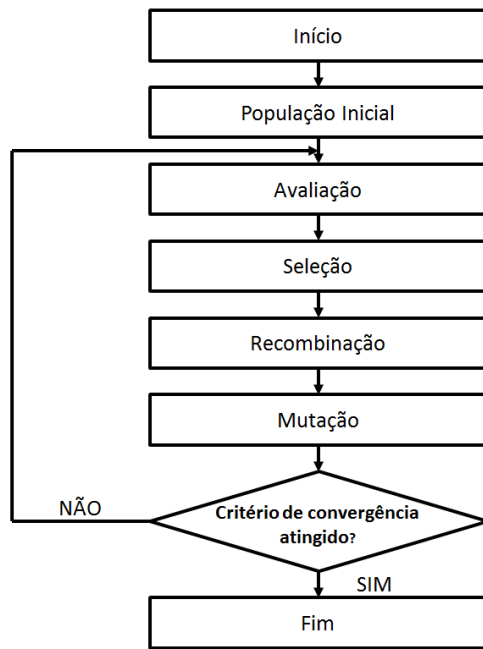


Figura 2.12: Fluxograma das etapas do Algoritmo Genético, adaptado de SHYR (2010).

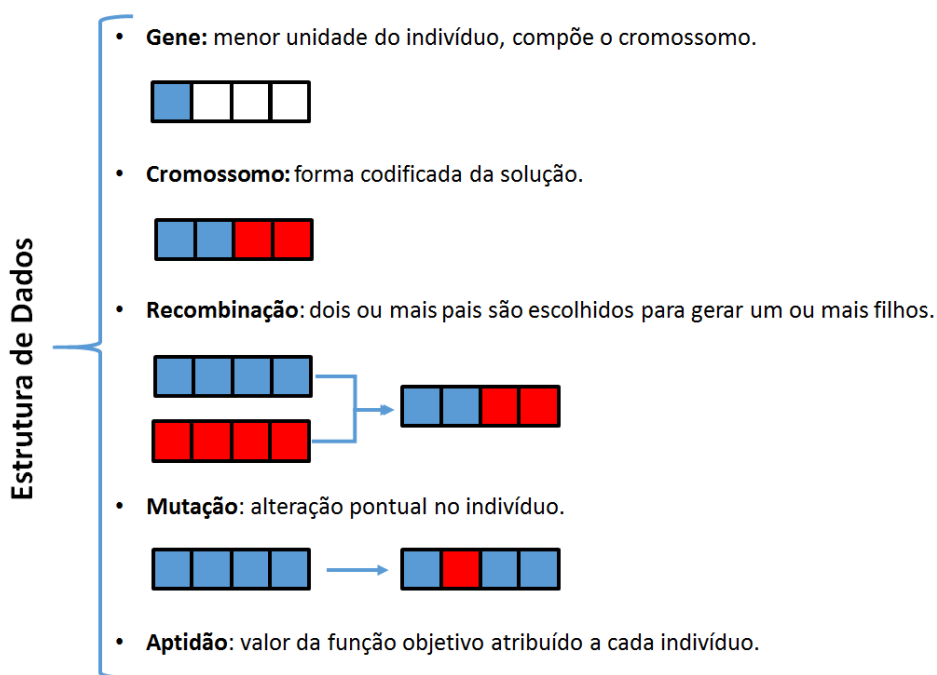


Figura 2.13: Estrutura de dados utilizada no Algoritmo Genético.

99 variáveis de decisão. Além disso, sua otimização considerou duas abordagens: na primeira uma proposta inicial de plano de desenvolvimento era fornecida e na segunda não. Para o primeiro caso se obteve um ganho financeiro de 6,08% ao passo que na segunda se obteve um ganho financeiro de 4,82%.

OZDOGAN *et al.* (2005) também utilizaram um algoritmo genético híbrido que

adicionava a restrição da locação dos poços seguir um determinado padrão (linha, five-spot etc) já que, segundo os autores, casos reais de desenvolvimento de campos de petróleo tendiam a ter os poços perfurados seguindo um desses padrões. Sua metodologia, denominada *Fixed Patter Approach* eliminava, portanto, diversas possibilidades de planos de drenagem diminuindo o número de simulações. Na aplicação estudada, o número de simulações diminuiu cerca de 50% ao passo que o VPL aumentou cerca de 14%.

Mais recentemente, MORALES *et al.* (2005) apresentaram um algoritmo genético modificado para realizar a otimização sob incerteza geológica na qual o indivíduo mais apto era escolhido levando em conta o nível de risco fornecido pelo usuário, ou seja, uma maior ou menor confiança em determinado cenário geológico. O estudo de caso realizado foi baseado em um campo de gás real e apesar de otimizar apenas a locação de um poço, mostrou uma maneira de dar pesos aos cenários quando se trabalha com incertezas.

EMERICK *et al.* (2009) também propuseram uma otimização por algoritmo genético. Por ter sido utilizada no presente trabalho, seus principais pontos serão discutidos a seguir.

As condições de contorno do processo de otimização que devem ser respeitadas são:

- Tamanho da malha;
- Tamanho máximo do poço;
- Distância mínima entre poços;
- Células inativas: o poço não pode iniciar ou terminar em uma célula inativa (mas pode atravessar células inativas);
- Regiões definidas pelo usuário que não podem ter poços.

Para lidar com essas restrições do problema de otimização de locação dos poços é utilizado o Genocop III - *Genetic Algorithm for Numerical Optimization of Constrained Problems*, proposto por MICHALEWICZ e NAZHIYATH (1995). O Genocop III utiliza duas populações distintas: população de busca e população de referência. A primeira contém indivíduos que satisfazem somente as restrições lineares e a segunda é composta por indivíduos que satisfazem todas as restrições (lineares e não lineares). Os indivíduos possíveis, R , (que atendem todas as restrições) da população de referência são avaliados no início da otimização e os indivíduos não possíveis, S , (da população de busca) são reparados por meio de uma recombinação com indivíduos da população de referência gerando um novo indivíduo, Z . Essa recombinação é repetida até que Z também seja possível. Além disso, caso a avaliação

de Z seja melhor do que a de R , esse novo indivíduo toma o lugar de R na população de referência. Adicionalmente, Z pode tomar o lugar de S com uma determinada probabilidade pr .

Para cada poço, são definidos oito genes, ou variáveis de decisão:

- Três genes para as coordenadas do início do poço no reservatório;
- Três genes para as coordenadas do final do poço no reservatório;
- Um gene para definir o tipo de poço: produtor ou injetor;
- Um gene para definir o status do poço: ativo ou inativo;

Para a otimização da locação de N poços, o cromossomo de um indivíduo pode ser representado pela Figura 2.14. É importante notar que a otimização compreende um grande número de variáveis. Por exemplo, se forem otimizados 20 poços, temos um total de 160 variáveis a serem otimizadas.

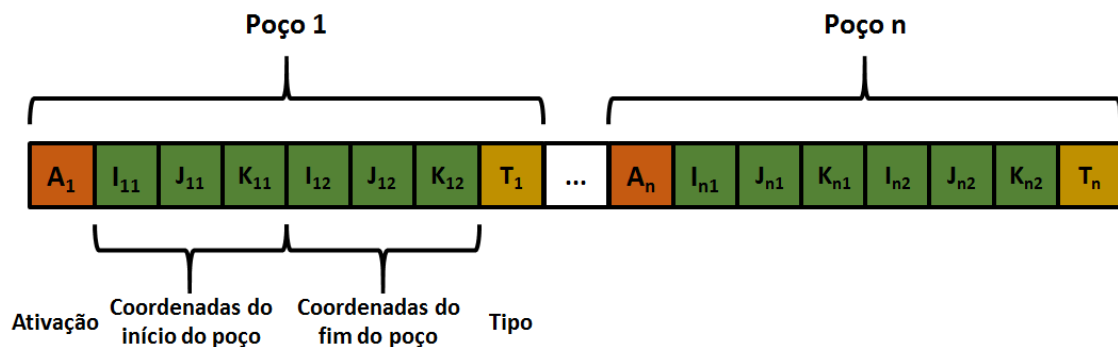


Figura 2.14: Cromossomo representativo de um indivíduo em uma otimização da locação de N poços, adaptado de EMERICK *et al.* (2009).

A definição da população inicial pode ser feita de duas formas: com ou sem um plano de desenvolvimento inicial fornecido pelo usuário. No primeiro caso, a população de busca é composta por 90% de indivíduos gerados aleatoriamente e 10% de indivíduos sugeridos pelo usuário. A população de referência conta com 50% de indivíduos gerados aleatoriamente e 50% de indivíduos sugeridos pelo usuário. No segundo caso as populações são aleatórias. Segundo os autores, chegou-se a melhores resultados quando se forneceu uma malha de drenagem inicial do que quando a mesma foi gerada aleatoriamente. Entretanto, deve-se atentar que um plano inicial incoerente pode levar a resultados sub-ótimos.

A função objetivo que serve para definir a aptidão dos indivíduos é o VPL que foi implementada por meio de um modelo econômico. Os parâmetros que influenciam no VPL são dados por:

- Custos de produção de óleo e gás;
- Preços de venda do óleo e do gás;
- Custo de injeção de água;
- Custo da plataforma;
- Custo da perfuração, completação e interligação dos poços;
- Taxas e impostos.

Os operadores genéticos (mutação e recombinação) são adaptativos, isto é, vão sendo alterados conforme as gerações se sucedem. São definidos valores iniciais e finais para as taxas e é estipulado um comportamento linear ao longo das gerações. Isso é importante pois inicialmente deve-se ter uma taxa de recombinação alta (para dar mais peso à população inicial) e uma taxa de mutação baixa. À medida que as gerações vão se sucedendo, a taxa de recombinação deve diminuir e a de mutação aumentar (para trazer novas informações genéticas à população).

Na otimização da locação de poços é considerado que todos iniciam a produção ou injeção ao mesmo tempo, ou seja, não há otimização do cronograma. Ainda que essa situação não seja real, ela é assumida para que o comportamento dos poços seja comparado sob as mesmas condições.

EMERICK *et al.* (2009) realizaram dois estudos de caso do offshore brasileiro. No primeiro, otimizaram a locação de 13 poços totalizando 104 variáveis de decisão. Os resultados obtidos mostraram um ganho de 28% de VPL em relação à estratégia inicial fornecida e um ganho de 13% no volume de óleo recuperado. No segundo estudo de caso, a locação de 11 poços foi otimizada resultado em um aumento de 30% do VPL e 13% no volume de óleo recuperado.

Finalmente, é importante notar que a otimização pressupõe um acoplamento com algum simulador comercial já que não são utilizadas *proxies* para substituir o modelo de fluxo numérico. Devido à quantidade de variáveis de decisão, um grande número de simulações deve ser realizado. Assim, para que seja viável, é necessário que estejam disponíveis *cluster* e computação paralelizada.

2.5 *Benchmarks* para Estudo de Metodologias

O estudo de metodologias relacionadas ao desenvolvimento e gerenciamento de campos de petróleo em malha fechada sempre encontrará como obstáculo a avaliação de sua aplicabilidade. Uma primeira forma de validar os resultados obtidos é a aplicação direta em um campo real. Entretanto, essa solução traz inúmeras dificuldades sendo que as principais consistem no alto custo do desenvolvimento e no

longo período de tempo associado, o que inviabiliza as análises. Além disso, em geral, problemas de ajuste de histórico e de otimização tendem a ser tratados e testados de maneira separada, de modo que se torna difícil analisar uma metodologia que englobe ambos.

Uma maneira eficaz de avaliar novas metodologias consiste no uso de *benchmarks*. Neles se tem um modelo que representa o comportamento do reservatório real – o modelo de referência – e um conjunto de modelos para estudo – as realizações. No primeiro, as propriedades do reservatório são conhecidas e no segundo, o conhecimento que se tem não é completo. Isso é feito de maneira proposital de forma a representar as incertezas em um campo de petróleo no qual o conhecimento existente sobre as características do reservatório no início do desenvolvimento é limitado. O resultado do estudo feito nas realizações (seja uma malha de drenagem, um ajuste de propriedades, um maior VPL etc.) pode então ser comparado com o resultado que seria obtido no caso real, ou seja, com aquele obtido quando aplicado no modelo de referência.

Um primeiro desenvolvimento nesse sentido foi apresentado por FLORIS *et al.* (2001). O *benchmark* PUNQ (*Production Forecast Uncertainty Quantification*), baseado em um campo operado pela Elf, consistia em um modelo de referência com $19 \times 28 \times 5$ células das quais 1.761 eram ativas. Foi incluído ruído gaussiano nos dados de permeabilidade e porosidade gerando realizações com o mesmo número de células. Forneceu-se também o histórico de produção de 8 anos sendo que no primeiro se tinha dados produção, nos três seguintes dados de pressão e nos quatro últimos mais dados de produção.

Outro exemplo de *benchmark* foi apresentado por PETERS *et al.* (2010a), o modelo Brugge, que foi desenvolvido já pensando em um contexto de gerenciamento de campo de petróleo em malha fechada. O modelo de referência era composto por uma malha de $75 \times 75 \times 2,5$ metros com um total de 327.067 células ativas e consistia em um reservatório de óleo subsaturado. As realizações possuíam valores distintos de permeabilidade, porosidade, NTG (*Net-to-Gross*), saturação de água e fácies em uma malha na qual já havia sido feito a mudança de escala (*upscale*). Os dados de produção dos 10 primeiros anos foram gerados a partir do modelo de referência e serviram para o ajuste de histórico.

Mais recentemente, AVANSI e SCHIOZER (2015) propuseram o *benchmark* UNISIM-I, baseado no Campo de Namorado. Ele é composto por um modelo de referência (UNISIM-I-R) e por realizações (UNISIM-I-D). Ambos serão detalhados nas seções seguintes.

2.5.1 UNISIM-I

O Campo de Namorado foi descoberto em 1975 com a perfuração do poço 1-RJS-19 em uma lâmina d'água de 166 m e está localizado na Bacia de Campos, conforme pode ser visto na Figura 2.15. De acordo com GUARDADO *et al.* (2000), essa é uma das bacias mais prolíficas do Brasil sendo que nela já foram descobertas mais de 70 acumulações de hidrocarbonetos incluindo 7 campos gigantes.

O reservatório principal do campo (arenito Namorado) ocorre em profundidades variando entre 2.900 e 3.000 m. Segundo BUENO *et al.* (2011), consiste em arenitos turbidíticos que foram depositados durante o Cenomaniano/Turoniano intercalados com folhelho e carbonatos. A direção deposicional dos paleocanais se dá na direção NW-SE. O reservatório consiste em uma estrutura falhada e está dividido em 5 blocos principais, separados por falhas normais.

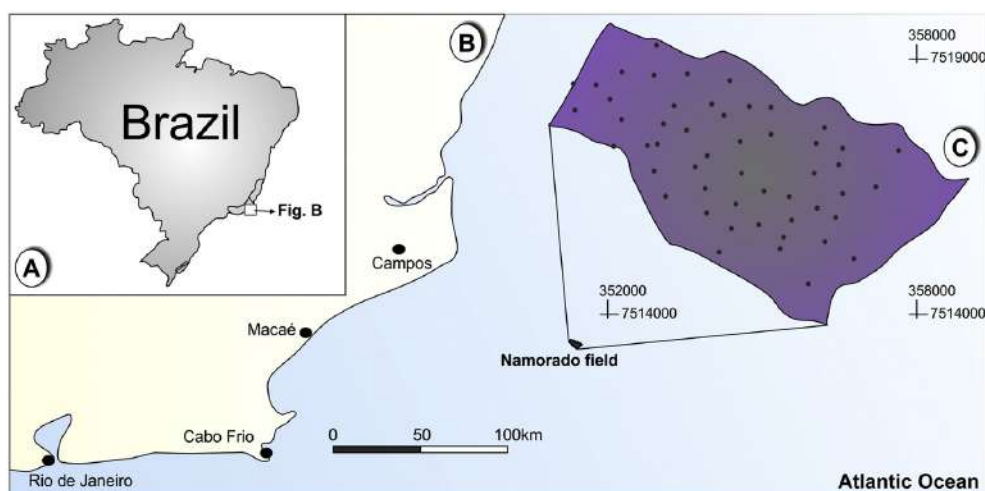


Figura 2.15: **A:** Localização do campo offshore de Namorado, Brasil; **B:** Zoom da Fig. A evidenciando o campo de Namorado; **C:** Zoom da Fig. B com o campo de Namorado e seus poços perfurados (pontos em preto). BUENO *et al.* (2011).

O modelo de referência UNISIM-I-R foi elaborado utilizando informação pública fornecida pela Agência Nacional do Petróleo. Seu modelo estrutural, petrofísico e de fácies considerou os 56 poços perfurados no campo de Namorado, além dos dados de sísmica disponíveis.

Foi construído um modelo de alta resolução com uma malha do tipo *corner point* e discretização $25 \times 25 \times 1$ metros com um total de 3.408.633 células ativas. Esse número é significativamente mais alto do que os outros *benchmarks* supracitados e reflete a tendência atual de modelos geológicos cada vez mais refinados. As fácies foram modeladas utilizando o *Sequential Indicator Simulation* gerando uma distribuição com quatro classes. A classe 0 é considerada uma fácies com boas propriedades de reservatório, as classes 1 e 2 são fácies com propriedades médias e a classe 3 representa o não reservatório. Para cada uma das fácies foi atribuído um

NTG conforme a Tabela 2.3.

Tabela 2.3: Relação entre fácies, propriedades de reservatório e NTG, AVANSI e SCHIOZER (2015).

Fácies	Propriedade	NTG
0	Bom	1,0
1	Médio	0,8
2	Médio	0,6
3	Não Reservatório	0,0

Para distribuir os valores de porosidade foi utilizada uma modelagem estocástica, *Sequential Gaussian Simulation*. Esta combinou dados de perfil dos poços, variograma e a modelagem de fácies descrita anteriormente.

Tabela 2.4: Variograma utilizado na modelagem da porosidade, AVANSI e SCHIOZER (2015).

Propriedade	Intervalo			Azimute
	Paralelo	Normal	Vertical	
Porosidade	1000	700	9,5	135

Para a distribuição da permeabilidade foi considerada uma dependência linear (em escala logarítmica) entre os dados de porosidade obtidos em testemunhos dos poços e a permeabilidade efetiva.




Figura 2.16: Dados de testemunho: porosidade versus permeabilidade. AVANSI e SCHIOZER (2015).

Utilizando uma regressão linear chegou-se à equação que relaciona permeabilidade e porosidade.

$$K_h = 10^{(0,1346 \cdot \Phi - 0,9794)} \quad (2.27)$$

Para caracterizar as incertezas relacionadas a um estágio inicial de desenvolvimento de um campo, foi criado o caso UNISIM-I-D. Para sua construção foram considerados apenas os dados dos 4 primeiros poços verticais com os quais se condicionou as distribuições das propriedades geológicas. A localização dos poços é dada pela Figura 2.17.

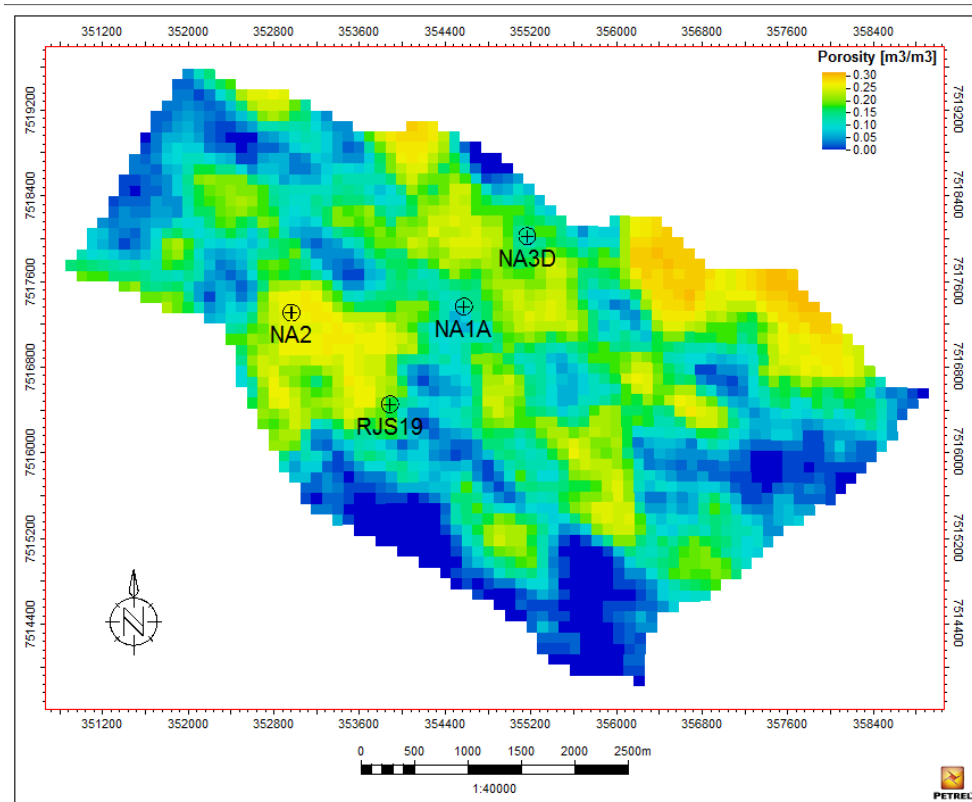
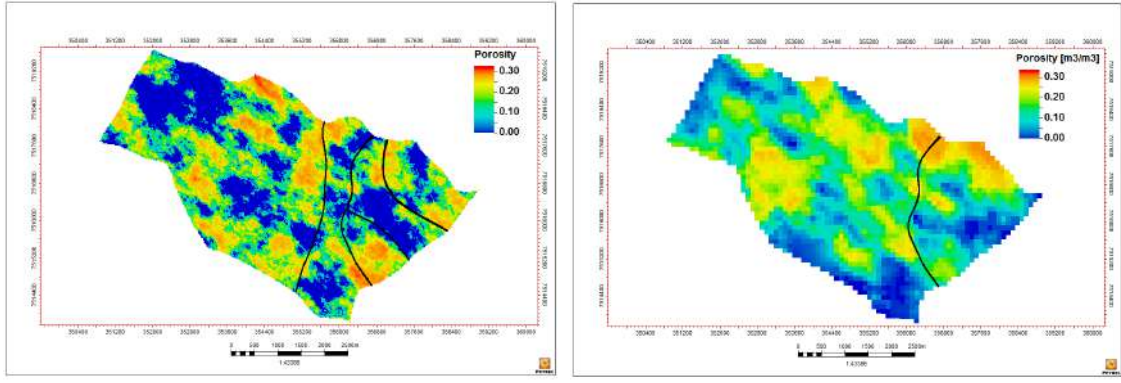


Figura 2.17: Localização dos poços exploratórios em uma realização do UNISIM-I-D.

Foi feito um *upscale* das propriedades para que o tempo de simulação fosse reduzido. Para a porosidade e NTG, a mudança de escala foi feita por meio de uma média aritmética ponderada pelo volume. Já para a permeabilidade foi utilizada uma técnica que buscava replicar o comportamento do fluxo monofásico tanto na malha fina quanto na grossa. Maiores detalhes podem ser obtidos em AVANSI e SCHIOZER (2015). Com isso, chegou-se a um modelo com células de tamanho $100 \times 100 \times 8$ metros e com um total de 36.739 células ativas.

Ainda no âmbito de um menor conhecimento devido ao estágio inicial de desenvolvimento de um campo, considerou-se que a sísmica existente no momento fosse capaz de mapear apenas uma das quatro falhas presentes no campo. Essa diferença fica evidenciada na Figura 2.18. Assim, para o caso UNISIM-I-D o reservatório é dividido pela falha em dois: o bloco principal e o bloco leste.

Quatro poços verticais (NA1A, RJS19, NA3D e NA2) fornecem os dados da fase inicial de exploração. Com isso, tem-se um histórico de produção de 4 anos: do dia



(a) UNISIM-I-R

(b) UNISIM-I-D

Figura 2.18: Mapa de porosidade e falhas do modelo UNISIM-I-R (a) e de uma realização do modelo UNISIM-I-D (b).

zero (31/5/2015) até o dia 1.461 (31/5/2017).

Os atributos incertos do UNISIM-I-D buscaram representar as incertezas presentes no desenvolvimento de um campo de produção. Foi considerado um conjunto inicial de 500 realizações petrofísicas distintas no qual a distribuição espacial da porosidade, NTG e permeabilidade (vertical e horizontal) variava. Também foi considerada como incerta a permeabilidade relativa, modelada por meio do ponto terminal (K_{rw}) e pela saturação crítica (S_{wcr}); a compressibilidade da rocha (C_{por}); o contato óleo-água (WOC) e o tipo de fluido (PVT), ambos no bloco leste. A Tabela 2.5 sumariza os atributos incertos utilizados no estudo.

Tabela 2.5: Atributos incertos do UNISIM-I-D

Atributo	Tipo de Incerteza	Pdf
Porosidade	Discreta	500 Realizações Equiprováveis
NTG	Discreta	
Permeabilidade (mD)	Discreta	
K_{rw}	Contínua	Triangular Min(0,15) Moda(0,35) Max(0,55)
$C_{por} (10^6 \text{kgf/cm}^2)^{-1}$	Contínua	Triangular Min(1,0) Moda(5,3) Max(9,6)
S_{wcr}	Contínua	Triangular Min(0,30) Moda(0,35) Max(0,40)
PVT	Discreta	PVT 1, 2 ou 3
$Woc (m)$	Contínua	Triangular Min(3024) Moda(3174) Max(3324)

Em posse do UNISIM-I-D, foi desenvolver um campo por um período de 30 anos decorridos do início da perfuração do primeiro poço (31/5/2013) e o abandono do campo (31/5/2043). Com o UNISIM-I-R obtém-se o comportamento do reservatório real.

O conjunto das 500 realizações do UNISIM-I-D assim como informações a respeito do *benchmark* UNISIM-I podem ser obtidas no endereço eletrônico <http://www.unisim.cepetro.unicamp.br/benchmarks/en/>.

Capítulo 3

Metodologia

A metodologia utilizada neste trabalho foi baseada na proposta por SHIRANGI e DURLOFSKY (2015). O campo a ser desenvolvido foi o *benchmark* UNISIM-I proposto por AVANSI e SCHIOZER (2015). Foi utilizado um *benchmark* neste estudo como forma de contornar o problema de avaliação da aplicabilidade de metodologia evidenciado na Seção 2.5. O UNISIM-I-R consiste no modelo de referência e as realizações do UNISIM-I-D, o conjunto de modelos geológicos submetidos ao DCMF. Duas razões principais levaram à escolha do UNISIM-I. Primeiro, esse foi o mesmo *benchmark* utilizado por MOROSOV (2016) que concluiu que o uso do DCMF resultou em um VPL inferior ao obtido com o plano de desenvolvimento inicial quando aplicado no UNISIM-I-R. Dessa forma, um dos objetivos é verificar se a mesma situação acontece com a implementação proposta neste trabalho. A segunda razão foi a de poder trabalhar com um *benchmark* cuja elaboração foi baseada em um campo real do *offshore* brasileiro. Deve ser destacada a diferença de conhecimento geológico empregado na elaboração do modelo de referência e das realizações. Ao passo que o modelo de referência utilizou todo o conhecimento disponível do campo (dados de 56 poços), o conjunto de modelos incertos partiam do pressuposto que só se conhecia parte do reservatório (dados de 4 poços). Esse tipo de situação reflete a realidade dos projetos de desenvolvimento de campos de petróleo, ou seja, há uma quantidade limitada de informação no momento em que decisões críticas têm que ser tomadas. Com a perfuração de novos poços, a aquisição de dados de produção traz novas informações mas a flexibilidade para mudanças vai diminuindo. O UNISIM-I também conta com uma excelente documentação com todas as premissas adotadas em sua elaboração, além de fornecer uma gama de atributos incertos coerente com um desenvolvimento de projeto. Os modelos estão disponíveis aos interessados no site do grupo UNISIM da Unicamp no endereço fornecido na Seção 2.5.1.

Conforme apresentado na Seção 2.1, sabe-se que o DCMF é composto por três principais etapas: ajuste de histórico, otimização do plano de desenvolvimento e aquisição de novos dados. A essas três foi adicionada uma quarta etapa que, embora

já estivesse presente no trabalho de SHIRANGI e DURLOFSKY (2015), não era tratada em separado: a seleção de modelos representativos. Dessa forma, a sequência de etapas (já na ordem de sua aplicação neste trabalho) do DCMF é dada por:

1. Ajuste de histórico com os dados disponíveis;
2. Seleção de cenários representativos;
3. Otimização do plano de desenvolvimento;
4. Obtenção de novos dados de produção e perfis dos poços perfurados.

Ainda que a sequência de passos do DCMF tenha sido mostrada na Figura 2.2, uma forma alternativa de apresentação que evidencia seu caráter de malha fechada é dado pela Figura 3.1.

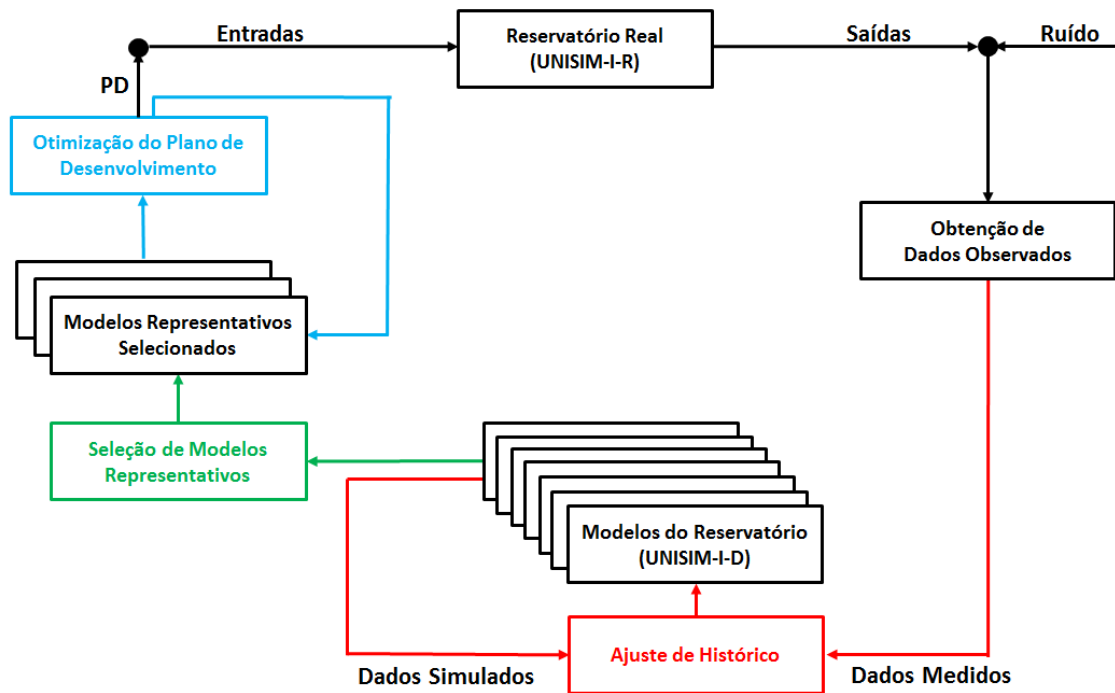


Figura 3.1: Etapas chave do desenvolvimento de campo em malha fechada (DCMF), adaptado de JANSEN *et al.* (2009) e SILVA (2016).

Na parte superior, tem-se o reservatório real, que neste trabalho foi dado pelo modelo de referência e que em uma aplicação prática seria o próprio campo de petróleo a ser desenvolvido. No centro, na parte inferior, encontram-se os modelos que buscam retratar esse reservatório real da melhor maneira possível baseado nos dados presentes naquele momento. Para este estudo, esses modelos foram dados pelo conjunto de realizações do UNISIM-I-D. Trabalhou-se com 500 realizações desse modelo devido à existência de incertezas inerentes ao conhecimento limitado que se

tem do campo. Esperou-se obter um conjunto de respostas dentre as quais se encontrasse a resposta do modelo de referência. À direita, tem-se a obtenção de dados observados. Ela consistiu na medição das cotas de produção, injeção e de pressão de fundo além dos perfis dos poços que são perfurados. Esses dados medidos, originados do modelo de referência, serviram para alimentar o ajuste de histórico que é feito nas realizações. Nesse sentido, o ajuste de histórico correspondeu à incorporação de dados estáticos oriundos dos poços perfurados e dados dinâmicos oriundos da produção dos poços. Estas geraram previsões de produção, ou seja, dados simulados que tanto foram reutilizadas no ajuste de histórico como foram o insumo para a seleção dos modelos representativos. Feita a seleção dos representativos, passou-se para a otimização do plano de desenvolvimento que é feita no conjunto de modelos representativos selecionados. O resultado dessa otimização é o plano de desenvolvimento do qual serão perfurados os próximos poços. Com a perfuração de poços no reservatório real, são obtidos os dados de perfil e de produção e um novo ciclo é iniciado. As etapas de ajuste de histórico, seleção de modelos representativos e otimização do plano de desenvolvimento estão destacadas com as cores vermelho, verde e azul, respectivamente.

Ao total foram realizados 8 ciclos. O primeiro deles não envolveu a perfuração de novos poços, mas sim o ajuste dos modelos ao histórico fornecido pelos 4 poços já existentes. Em seguida, foram feitos mais 7 ciclos que corresponderam ao total de poços a serem perfurados no plano de desenvolvimento. O intervalo entre a entrada de cada poço é de 3 meses, tempo suficiente para realizar as tarefas de perfuração, completação e interligação dos poços. Cada ciclo teve uma duração de 6 meses incluindo, dessa forma, a entrada de 2 poços: do primeiro foram obtidos dados de produção e de perfil e do segundo, dados de perfil e um ponto de pressão de fundo (o que seria correspondente, por exemplo, a um dado de pré-teste). O tempo de duração do ciclo foi baseado em alguns fatores: o primeiro diz respeito ao tempo mínimo necessário para atualização dos modelos em uma aplicação real. Foi considerado também o tempo disponível para a realização deste estudo já que, conforme será evidenciado na Seção 4.5, a execução de cada ciclo demandou valores consideráveis de recursos computacionais e de tempo. Finalmente, com 8 ciclos já foi possível verificar o comportamento dos parâmetros analisados ao longo do tempo e foi possível supor que ciclos mais curtos (um ciclo a cada poço perfurado) trariam apenas um refinamento dessas tendências.

Foram perfurados alternadamente poços injetores e produtores. Iniciou-se pelos injetores, devido ao fato do reservatório já ter produzido 4 anos sem um método de recuperação secundário. A ordem de entrada dos poços injetores foi dada de tal forma a dar o suporte de pressão necessário aos poços produtores. Já a ordem de perfuração dos poços produtores foi dada pelo VPL do Ciclo Zero, ou seja, os poços

que traziam maior retorno foram perfurados primeiro. A Tabela 3.1 traz a duração dos ciclos, os poços participantes, assim como sua data de entrada em produção.

Tabela 3.1: Caracterização dos ciclos e cada um dos poços participantes.

Ciclo	Duração Ciclo		Entrada de Poços	
	Início	Fim	Nome	Data
Ciclo 0	31/5/13	31/5/17	NA1A	30/6/13
			RJS19	30/11/13
			NA3D	28/2/14
			NA2	31/5/14
Ciclo 1	31/5/17	31/11/17	Injetor de Água 8	31/8/17
			Produtor 7	31/11/17
Ciclo 2	31/11/17	31/5/18	Injetor de Água 1	28/2/18
			Produtor 9	31/5/18
Ciclo 3	31/5/18	30/11/18	Injetor de Água 6	31/8/18
			Produtor 2	30/11/18
Ciclo 4	30/11/18	31/5/19	Injetor de Água 2	28/2/19
			Produtor 8	30/5/19
Ciclo 5	31/5/19	30/11/19	Injetor de Água 5	31/8/19
			Produtor 5	30/11/19
Ciclo 6	30/11/19	31/5/20	Produtor 1	29/2/20
			Produtor 10	30/05/20
Ciclo 7	31/5/20	30/11/20	Produtor 6	31/8/20
			Injetor de Água 3	30/11/20

Por ser uma metodologia genérica, cada etapa do DCMF possui diversas formas de abordagem que constituem, por si só, linhas de pesquisa diferentes na Engenharia de Reservatórios. Assim, será apresentado o método específico utilizado em cada uma das etapas utilizado neste trabalho.

3.1 Ajuste de Histórico

Conforme visto na Seção 2.2, o ajuste de histórico é um problema inverso e mal posto. Dadas as características da proposta deste trabalho, os métodos baseados no Filtro de Kalman se mostraram como os mais recomendados para a etapa de ajuste de histórico. Dentre eles, o ES-MDA apresentou um bom desempenho além de não possuir o inconveniente relacionado com a necessidade da criação de restarts. Em adição, sua implementação está disponível para engenheiros da Petrobras por meio do sistema *Ensemble-Based History Matching* (EHM), ou em uma tradução livre, Ajuste de Histórico Baseado em Conjuntos. O software empregado foi o Petrel versão 2015 em conjunto com o *Plug-in BR-Kalman* versão 21.116 (no qual se encontra o EHM). Para este trabalho, foram desenvolvidas algumas alterações especificamente

para este trabalho sendo que o maior destaque foi a incorporação da capacidade de realizar ajuste de histórico de dados de perfis.

Dessa forma, o ES-MDA foi a solução escolhida para a realização dessa etapa. Foram utilizadas 4 iterações ($N_a = 4$ na Equação 2.14) já que esse valor se mostrou suficiente em outros casos estudados (EMERICK e REYNOLDS (2013)).

A Equação 2.15 referente à função objetivo mostra que para seu cálculo é necessário definir: o conjunto de modelos, os dados observados, os dados simulados e os erros de medição. Para o primeiro item, foram adotadas as 500 realizações do UNISIM-I-D, apresentado na Seção 2.5.1. Foram considerados dois tipos de dados observados, a saber, dados de produção e dados de perfil. Em ambos os casos, foi realizado um ajuste poço a poço. Nas Tabelas 3.2 e 3.3 encontram-se o tipo de dados de produção e injeção considerados, assim como os valores de desvio padrão para o erro de medição. A periodicidade da coleta de dados para os dados de produção foi semanal.

Tabela 3.2: Dados de produção e desvio padrão do erro de medição para poços produtores utilizados no ajuste de histórico.

Dados de Produção	Desvio Padrão do Erro de Mediçã
Vazão de Óleo (m^3/d)	5%
Vazão de Gás (m^3/d)	10%
Vazão de Água (m^3/d)	5%
Pressão de Fundo (kgf/cm^2)	10 kgf/cm^2

Tabela 3.3: Dados de produção e desvio padrão do erro de medição para poços injetores utilizados no ajuste de histórico.

Dados de Injeção	Desvio Padrão do Erro de Mediçã
Vazão de Água (m^3/d)	5%
Pressão de Fundo (kgf/cm^2)	10 kgf/cm^2

Para os dados de perfil adotou-se que, a partir do momento em que um novo poço fosse perfurado, seu perfil de porosidade estaria disponível para condicionar os modelos. Foi adotado um erro de medição igual a 0,01 para os valores de porosidade. Esse valor é pequeno para refletir o fato que esse tipo de dado é tipicamente muito preciso sendo que na geoestatística ele chega até mesmo a ser considerado como sem ruído.

Nas simulações foram adotados parâmetros que podem ser classificados como escalares e ou de malha. Os primeiros referem-se a grandezas que influenciam parte ou até mesmo todo o modelo de simulação. Para os parâmetros escalares tem-se a Tabela 3.4, na qual se a compressibilidade da rocha (C_{por}), o contato óleo-água

(Woc) e o tipo de fluido representado por três possíveis tabelas PVT, tabela que caracteriza o fluido do reservatório.

Tabela 3.4: Parâmetros escalares considerados.

Atributo	Pdf ou Valor
Cpor (10^6kgf/cm^2) ⁻¹	Triangular Min(1,0) Moda(5,3) Max(9,6)
Woc (<i>m</i>)	Triangular Min(3024) Moda(3174) Max(3324)
Tipo de Fluido	PVT 1, 2 ou 3

Ainda que todos os parâmetros escalares fossem utilizados para gerar uma variabilidade de modelos iniciais, nem sempre foram atualizados durante a etapa do ajuste de histórico, exceção feita para a compressibilidade da rocha que esteve presente em todos os ciclos. Isso se deve à evolução das informações disponíveis sobre o reservatório. Por exemplo, a partir do momento em se que perfura um poço na área em que o contato óleo-água era incerto, esse dado deixa de ser desconhecido. O detalhamento da utilização dos parâmetros escalares será dado em conjunto com sua análise na Seção 4.

Os parâmetros de malha são aqueles que correspondem a cada uma das células do modelo de fluxo e estão apresentados na Tabela 3.5. Foi estipulado o intervalo no qual o parâmetro poderia variar para fazer o ajuste. Tem-se ainda o detalhamento de qual o tipo de transformação utilizado. Para a transformação log-normal foi calculado o logaritmo do parâmetro e esse valor foi utilizado no ajuste. Isso foi aplicado na permeabilidade devido a tendência dessa propriedade apresentar esse tipo de distribuição. Para os outros não se fez transformação, ou seja, o valor da propriedade foi igual ao parâmetro de ajuste.

Tabela 3.5: Parâmetros de malha utilizados no ajuste de histórico.

Parâmetro	Mínimo	Máximo	Tipo de Transformação
Porosidade	0 %	35%	Sem transformação
Permeabilidade em I	1 mD	3.500 mD	Log Normal
Permeabilidade em J	1 mD	3.500 mD	Log Normal
Permeabilidade em K	1 mD	3.500 mD	Log Normal
<i>Net to Gross</i>	0.0	1.0	Sem transformação

Para os dois tipos de parâmetros utilizou-se a técnica conhecida como *localization* com a correlação de Gaspari-Cohn como uma forma de melhorar o desempenho do ES-MDA. Para os dados de produção, foi adotado um alcance correspondendo ao dobro do alcance do variograma utilizado na geração do parâmetro em questão. Por exemplo, para a porosidade conforme a Tabela 2.4 os alcances correspondiam

a um intervalo paralelo de 1.000 m, normal de 700 m. Dessa forma, no *localization* da propriedade porosidade foi utilizado um alcance paralelo de 2.000 m, normal de 1.400 m. É evidente que o azimute foi mantido o mesmo. Para o dado de perfil também foi utilizado o *localization* com alcance igual ao de sua modelagem, uma vez que não contém informações referentes a dados dinâmicos.

O papel do *localization* consistiu em restringir a área de influência dos dados de maneira a eliminar possíveis correlações espúrias. Isso é melhor entendido ao ver a Figura 3.2, que mostra a área de influência do Injetor 1. Dessa forma, somente foram alterados os parâmetros dentro dessa elipse sendo que o seu peso foi diminuindo na medida em que se afasta do poço.


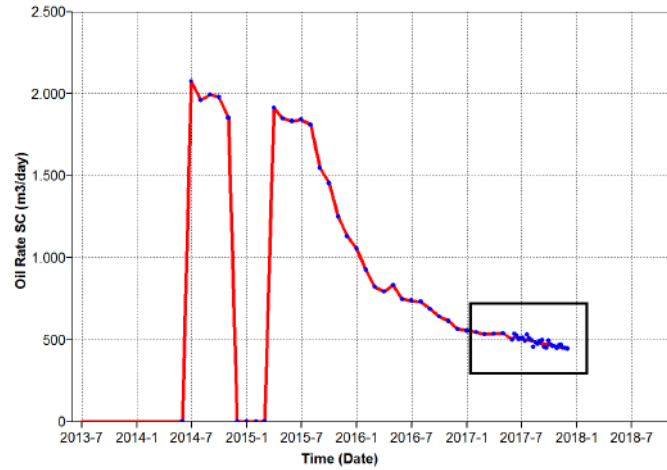


Figura 3.2: Área de influência para o poço Injetor 1, somente parâmetros localizados dentro da elipse serão alterados.


3.1.1 Obtenção de Dados Observados

Como o histórico de produção inicial contava com dados até 31/5/2017, foi necessário gerar mais dados à medida que o campo ia sendo desenvolvido. Os dados de produção dos poços produtores e injetores foram obtidos posicionando a malha de drenagem no modelo de referência e realizando uma simulação até a data em que se desejava criar o histórico. Aos valores obtidos, foi acrescentado um ruído aleatório de medição que possuía média nula e desvio padrão dado pela Tabela 3.6. A inclusão do ruído buscou reproduzir as medições de um campo real, que não apresentam valores suaves como os obtidos por meio de uma simulação numérica.


Em posse desses dados, a vazão de óleo (para os produtores) e vazão de água (para os injetores) foi especificada no controle de poço durante a etapa de ajuste.



(a) Vazão de óleo para o poço NA2 a partir do modelo UNISIM-I-R para o Ciclo 1.



(b) Ampliação da Figura 3.3a, a curva vermelha representa o dado gerado pelo UNISIM-I-R e os pontos representam os dados de histórico (que incluem o ruído).



(c) Imposição da vazão: a curva vermelha representa o dado gerado pelo UNISIM-I-R, os pontos representam os dados de histórico e a linha em azul corresponde a resposta de um modelo do conjunto com a imposição da vazão.

Figura 3.3: Obtenção de dados de produção para o ajuste de histórico com inclusão de ruído aleatório e imposição da vazão como controle da simulação.

Tabela 3.6: Valor do desvio padrão do ruído aplicado aos dados de produção.

Grandeza	Desvio Padrão
Vazão de Óleo	5%
Vazão de Água	5%
Vazão de Gás	10%
Pressão de Fundo	2 kgf/cm^3

Para exemplificar a obtenção de dados observados pode-se analisar a Figura 3.3. Nas Figuras 3.3a e 3.3b vê-se o período no qual foi gerado o histórico, que é identificado pela maior concentração dados: os pontos azuis (conforme dito anteriormente, foi considerada uma coleta semanal de dados a partir de 31/5/7). A linha em vermelho corresponde à resposta do modelo de referência. Os pontos em azul consistem nos dados do simulador acrescidos do ruído aleatório. Ao realizar o processo de histórico, os valores de vazão foram impostos como controle de poço, fato que pode ser visto na Figura 3.3c. Nesse caso, como o modelo possuía as características necessárias, foi capaz de honrar o histórico especificado.

Obviamente, ao impor o dado de vazão de óleo, os demais parâmetros foram calculados. Assim pode-se verificar na Figura 3.4 que, para o mesmo modelo, não se tem um bom ajuste inicial da pressão de fundo quando comparado com os dados históricos gerados.




Figura 3.4: Curva de pressão de fundo e histórico gerado para o poço NA2 no Ciclo 1. Os pontos de histórico (em azul) foram gerados incluindo ruído na curva em vermelho obtida no modelo UNISIM-I-R. A curva em azul representa a resposta de um dos modelos do conjunto ao especificar a vazão como controle de poço.

Foi também assimilado o dado de perfil de porosidade dos poços perfurados. Para tanto, tomou-se a trajetória do poço no modelo de referência e em seguida foi feita uma transferência de escala para o modelo grosso utilizando as mesmas métricas apresentadas na Seção 2.5.1. Em todas as células cortadas pela trajetória do poço foi considerado que a porosidade era conhecida. A Figura 3.5 mostra isso para o Ciclo 6 na primeira camada. As células em vermelho são aquelas em que foi considerada conhecida a porosidade. Nota-se ainda que o Injetor 3 e Produtor 6 não aparecem com porosidades conhecidas por não fazer parte do Ciclo mencionado.

É importante ressaltar que, conforme descrito na Seção 3.1, tanto os dados de produção como os dados de perfis obtidos foram incorporados por meio do método ES-MDA com a utilização da adaptação feita no BR-Kalman especificamente para este estudo.

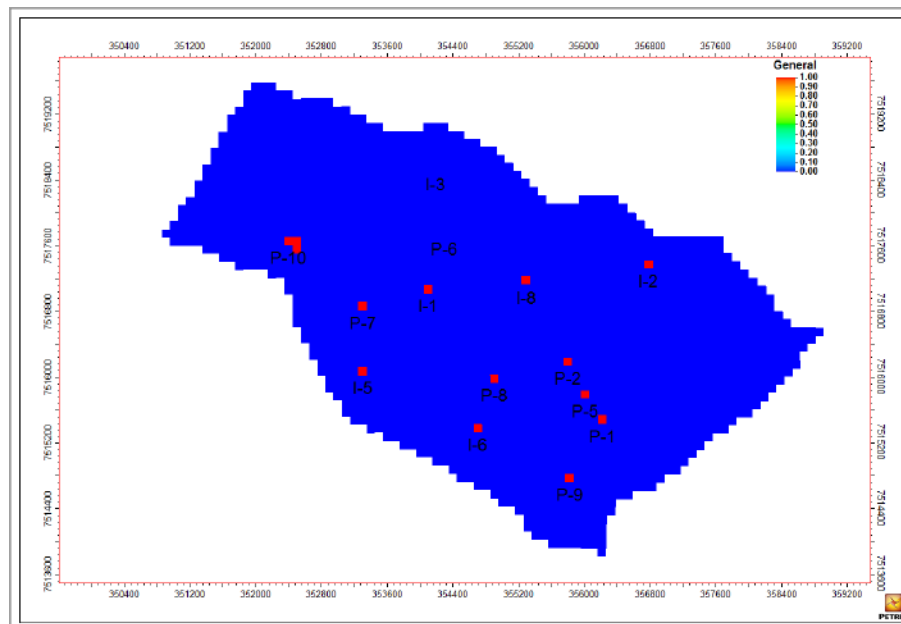


Figura 3.5: Primeira camada de um dos modelos durante o Ciclo 6. As células em vermelho correspondem àquelas em que foi considerada conhecida a porosidade.

3.2 Seleção de Modelos Representativos

Neste trabalho foi utilizada uma implementação disponível na Petrobras para o método desenvolvido por ARMSTRONG *et al.* (2012) que recebeu uma matriz de distância previamente calculada e resolveu o problema da minimização de $D(J)$ (Equação 2.21) utilizando o algoritmo genético.

Para a seleção dos modelos representativos foi necessário inicialmente definir quais os parâmetros para sua caracterização. Seria possível diferenciar dois modelos analisando suas propriedades de malha (como porosidade, permeabilidade, NTG etc)

ou pelos parâmetros escalares (valores de compressibilidade, de contato óleo-água, de fluido etc). Além disso, esse conjunto de propriedades resulta em um determinado volume de óleo que também é único para cada modelo. Devido a essas diferenças, a mesma estratégia de produção quando aplicada em dois modelos leva a resultados particulares de produção de óleo, água, gás e, por fim, a valores distintos de VPL. Pode-se entender que se tem, então, quatro categorias de parâmetros que caracterizam um modelo: parâmetros de malha, escalares, volumétricos e de produção. Eles é que compõe o vetor coluna \mathbf{w} apresentado na Equação 2.16. Convém ressaltar que no caso das propriedades de malha, devido ao fato de cada célula possuir um valor, optou-se por representar essa variabilidade pela sua média e o desvio padrão.

Foi adotada a distância Euclidiana dada pela Equação 2.17 para medir a dissimilaridade entre modelos. Entretanto, antes de realizar esse cálculo foi necessário realizar uma normalização pois a ordem de grandeza dos parâmetros era distinta (por exemplo, porosidade variava entre 0,00 e 0,35 ao passo que o VPL variava entre 9×10^8 e 2×10^9). Em adição, foi conveniente dar pesos aos parâmetros já que se desejou dar maior ou menor importância dependendo de seu impacto na seleção. Para a normalização e a ponderação dos parâmetros foi implementado o algoritmo apresentado por SILVA (2016), cujos pesos estão apresentados a seguir.

As Tabelas 3.7, 3.8, 3.9 e 3.10 elencam todos os parâmetros e pesos utilizados para realizar a seleção dos modelos representativos.

Tabela 3.7: Parâmetros de malha e seus pesos utilizados para caracterizar os modelos e selecionar os representativos

Tipo de Parâmetro	Parâmetro	Peso
Malha	Porosidade Média	1
	Desvio Padrão da Porosidade	1
	Permeabilidade em I	1
	Desvio Padrão da Permeabilidade em I	1
	Permeabilidade em J	1
	Desvio Padrão da Permeabilidade em J	1
	Permeabilidade em K	1
	Desvio Padrão da Permeabilidade em K	1
	<i>Net to Gross</i>	1
	Desvio Padrão do <i>Net to Gross</i>	1
Total Peso Malha	\sum Pesos = 10	

Pode-se notar que se procurou a busca por um equilíbrio para que o somatório dos valores referentes à produção se equivalessem ao somatório referente ao volume, malha e escalares.

Uma vez calculada a matriz de distâncias \mathbf{D} , dada pela equação 2.19, ainda foi necessário resolver o problema da seleção de cenários propriamente dito. Utilizando

Tabela 3.8: Parâmetros escalares e seus pesos utilizados para caracterizar os modelos e selecionar os representativos

Tipo de Parâmetro	Parâmetro	Peso
Escalar	Cpor	1
	Woc	1
	Krw	1
	Swr	1
	PVT	1
Total Peso Escalar	\sum Pesos = 5	

Tabela 3.9: Parâmetro volumétrico e seu peso utilizados para caracterizar os modelos e selecionar os representativos

Tipo de Parâmetro	Parâmetro	Peso
Volumétrico	VOIP	5
Total Peso Volumétrico	\sum Pesos = 5	

a implementação do método proposto por ARMSTRONG *et al.* (2012), a cada ciclo foram escolhidos 5 modelos representativos. Esse número de modelos foi objeto de algumas análises que serão apresentadas na Seção 4. Para o algoritmo genético, foi considerada uma população inicial de 1000 indivíduos e uma evolução durante 100 gerações.

3.3 Otimização do Plano de Desenvolvimento

O presente trabalho utilizou a proposta de EMERICK *et al.* (2009) apresentada na Seção 2.4, baseada em algoritmo genético, para realizar a otimização do plano de desenvolvimento. A implementação estava disponível por meio do software OCTOPUS, desenvolvido pela Petrobras em parceria com a PUC-Rio. No entanto, houve a necessidade de desenvolver especificamente algumas adaptações para a realização deste trabalho.

Ao longo de todos os ciclos, sempre foi fornecido um plano de drenagem inicial (a semente inicial) como dado de entrada para realizar as otimizações. Isso foi motivado pelos melhores resultados obtidos na literatura quando comparados com a opção de deixar planos de drenagem gerados aleatoriamente.

Para o Ciclo Zero, a semente inicial foi elaborada a partir de uma estimativa de poços tipos em conjunto com a análise de locação baseada em colunas de óleo. Esse processo será detalhado a seguir. Já para os demais, a semente inicial consistia no plano de drenagem otimizado do ciclo anterior.

No Ciclo Zero, inicialmente se fez necessário obter o número de poços produtores

Tabela 3.10: Parâmetros de produção e seus pesos utilizados para caracterizar os modelos e selecionar os representativos

Tipo de Parâmetro	Parâmetro	Peso
Produção	VPL	8
	Fator de Recuperação	4
	Produção Acumulada de Óleo	4
	Produção Acumulada de Água	4
Total Peso Produção		\sum Pesos = 20

e injetores. Partindo de um VOIP estimado de 130 milhões de m^3 e de um fator de recuperação também estimado de 40% chegou-se a um valor de produção acumulada de óleo (N_p) de 52 Milhões de m^3 .

$$N_p = VOIP.Fr = 130.0,4 \rightarrow N_p = 52MM \text{ de } m^3$$

Com uma produção por poço de cerca de 2 milhões de m^3 chegou-se ao valor de 13 poços produtores. Se cada poço produtor produzir cerca de $2.000 m^3/d$ de óleo tem-se uma vazão total de óleo de $26.000 m^3/d$. Sabendo que o fator volume de formação do óleo é de 1,4 tem-se que essa produção em condições de reservatório foi de $36.400 m^3/d$.

$$n_{produtores} = \frac{N_p}{N_{poco}} = \frac{52}{2} \rightarrow n_{produtores} = 13 \text{ poços produtores}$$

$$Q_o = n.q_{poco} = 13.2000 \rightarrow Q_{oleo} = 26000 m^3/d$$

$$Q_{o,r} = Q_o.B_o = 26000.1,4 \rightarrow Q_{o,r} = 36400 m^3/d$$

Assumindo que a água é incompressível e sabendo que é desejável uma reposição do volume produzido, a cota total de injeção de água também deve ser da ordem de $36.400 m^3/d$. Supondo que cada poço seja capaz de injetar $5.000 m^3/d$ de água tem-se um total de 7,2 poços injetores. Como o campo já está um déficit de injeção de 4 anos (período de produção), convém aumentar esse número de poços injetores para 8.

$$Q_{w,r} = Q_w = Q_{o,r} = 36400 m^3/d$$

$$n_{injetores} = \frac{Q_w}{q_{inj,poco}} = \frac{36400}{5000} = 7,2 \rightarrow n_{injetores} = 8 \text{ poços injetores}$$

Por já contar com 4 poços no campo que seriam aproveitados, o total de poços

a ser perfurados consistiu em 7 poços produtores e 8 poços injetores.

Inicialmente, os poços foram considerados verticais e distribuídos espacialmente com base na coluna de óleo (produto da altura do reservatório, porosidade e saturação de óleo). Foi realizada uma otimização manual da locação dos poços baseada na resposta do modelo que teve o melhor ajuste aos dados de produção. Com isso, o plano de desenvolvimento inicial para o Ciclo Zero é dado pela Figura 3.6.

Conforme dito anteriormente, para os demais ciclos a semente inicial correspondeu ao plano de drenagem otimizado do ciclo anterior.




Figura 3.6: Plano de drenagem correspondente à semente inicial do Ciclo 0 em um mapa de porosidade. Poços em vermelho são produtores e em azul são injetores.

Para todos os ciclos foram adotados os mesmos parâmetros da evolução e dos operadores genéticos, apresentados na Tabela 3.11. As taxas dos operadores genéticos variaram linearmente ao longo das gerações passando do valor inicial até o valor final. Em relação ao tamanho da população e ao número de gerações, procurou-se utilizar valores próximos daqueles empregados em outros casos de aplicação da indústria do conhecimento do autor. Um maior número de indivíduos e mais gerações poderiam trazer melhores resultados, entretanto, poderiam se mostrar distantes daquilo exequível em um caso real devido ao maior custo computacional associado. Também se faz necessário comentar os valores da taxa de mutação que podem ser considerados elevados quando comparados com outras aplicações do algoritmo genético. No caso específico deste estudo, é importante lembrar que metade da população ini-

cial era composta pela semente inicial de forma que valores maiores de mutação se mostraram necessários para trazer variabilidade genética para as populações.

Tabela 3.11: Parâmetros da evolução e dos operadores genéticos da otimização

Tamanho da População	30	
Número de Gerações	50	
	Inicial	Final
Taxa de <i>Steady State</i>	20%	20 %
Taxa de Cruzamento	80%	10%
Taxa de Mutação	50 %	90 %
Taxa de Mutação Controlada	10 %	80 %
Taxa de Mutação do Tipo de Poço	0 %	50 %
Taxa de Mutação da Ativação do Poço	0 %	20 %

A função objetivo que serviu para medir a aptidão dos indivíduos foi o VPL cujo cálculo será detalhado na Seção 3.4. Entretanto, ao invés de apenas trabalhar com o VPL de cada um dos modelos optou-se por realizar uma otimização sob incertezas, ou seja, buscar majorar o VPL quando se levavam em consideração os modelos representativos selecionados. Dado um ciclo qualquer, com os 5 modelos representativos e suas respectivas probabilidades associadas p_i , com $i = \{1, 2, 3, 4, 5\}$, a função objetivo avaliada na otimização do plano de drenagem foi dada pelo Valor Monetário Esperado dos VPLs, ou seja:

$$VME = \sum_{i=1}^5 p_i \cdot VPL_i \text{ com } i = \{1, 2, 3, 4, 5\}. \quad (3.1)$$

Após otimizar o plano de desenvolvimento, este foi aplicado ao conjunto de 500 realizações para auferir os ganhos obtidos no VPL para cada um dos modelos. A otimização levou em conta todos os possíveis poços do PD. Em outras palavras, ao invés de somente otimizar a locação dos dois poços seguintes a serem perfurados, foi otimizada a locação de todos os que ainda poderiam ser perfurados. Também foi parâmetro da otimização a quantidade de poços que o otimizador estaria livre para incluir ou remover. Foi adotada ainda uma distância mínima de 100 m entre poços e cada um podia ter um máximo de 850 m abertos para produção/injeção. As coordenadas do início e final do poço também estavam livres para serem otimizadas pelo OCTOPUS.

Conforme apresentado na Seção 2.5, não há otimização do cronograma de entrada dos poços, ou seja, durante a etapa de otimização do plano de desenvolvimento foi considerado que todos os poços iniciaram sua produção/injeção ao mesmo tempo. Entretanto, para ser capaz de realizar comparações realistas, os VPLs apresentados neste trabalho consideraram a sequência de entrada dos poços espaçada, conforme

a Tabela 3.1.

Também foi realizada uma otimização do plano de desenvolvimento do modelo UNISIM-I-R com o objetivo de traçar um valor limite de VPL e permitir comparar a metodologia com o máximo resultado que poderia ser obtido. Os parâmetros utilizados foram os mesmos da Tabela 3.11 com exceção do tamanho da população e do número de gerações. Os valores utilizados foram, respectivamente, 100 e 430. A utilização desses valores significativamente mais elevados do que os utilizados durante a otimização nos ciclos teve como objetivo explorar melhor o espaço de busca existente e chegar a um PD que gerasse um valor de VPL próximo ao máximo possível. O modelo de fluxo utilizado consistiu no UNISIM-I-D após passar por uma transferência de escala já que o número de simulações exigidas inviabilizaria o uso do modelo refinado devido ao seu elevado tempo de simulação. Entretanto, uma vez obtido o PD otimizado, este foi aplicado no modelo refinado para gerar os valores apresentados na Seção 4.

3.4 Modelagem do Valor Presente Líquido

Para a avaliação do desempenho do DCMF foi utilizado o VPL como métrica capaz de auferir os potenciais ganhos de sua utilização. A modelagem do VPL foi dada pelo valor presente do poço ao qual se subtraiu seu custo de desenvolvimento além do custo da plataforma.

$$VPL = \sum_{m=1}^m VP_{poço,m} - \sum_{m=1}^m D_{poço,m} - C_{plat} \quad (3.2)$$

com VPL sendo o valor presente líquido do modelo, m o número de poços, $VP_{poço}$ o valor presente do poço, $D_{poço}$ o custo de desenvolvimento do poço e C_{plat} o custo da plataforma.

Iniciando pelo último fator, tem-se:

$$C_{plat} = C_f + Cp_o C_o + Cp_w C_w + Cp_{iw} C_{iw} + C_s C_p_s \quad (3.3)$$

onde C_{plat} é o custo da plataforma; C_f o custo fixo da plataforma; Cp_o a capacidade de produção de óleo; C_o o custo da capacidade de produção de óleo; Cp_w a capacidade de produção de água; C_w o custo da capacidade de produção de água; Cp_{iw} a capacidade de injeção de água; C_{iw} o custo da capacidade de injeção de água; C_s o custo por slots disponíveis para interligação de poços e C_p_s o número de slots disponíveis na plataforma.

O segundo termo, $D_{poço}$ foi composto por:

$$D_{poço} = Cpcli_{poço} + CA_{poço} \quad (3.4)$$

com $D_{poço}$ sendo o custo final do poço; $Cpcli_{poço}$ o custo de perfuração, completação, linhas e interligação do poço; $CA_{poço}$ o custo de abandono do poço.

O primeiro termo, $VP_{poço}$ é composto pelo valor presente das receitas, VP_r , menos o valor presente dos custos operacionais, VP_{cop} :

$$VP_{poço} = VP_r - VP_{cop} \quad (3.5)$$

O primeiro termo é dado por:

$$VP_r = \sum_{n=1}^n \frac{N_o [P_o (1 - R_{oy}) - C_{po}] (1 - t_x)}{(1 + tma)^n} \quad (3.6)$$

onde se tem: N_o produção mensal de óleo do poço, P_o preço do óleo, R_{oy} royalties pagos sobre a receita bruta, C_{po} custo de produção do óleo, t_x imposto, tma taxa mínima de atratividade transformada na sua forma mensal, n número de meses decorridos em relação a data de cálculo do VPL.

O segundo termo da Equação 3.5 é composto por:

$$VP_{cop} = \sum_{n=1}^n \frac{N_w Cp_w}{(1 + tma)^n} \quad (3.7)$$

onde N_w é a produção mensal de água e Cp_w é o custo de produção de água. No caso dos poços injetores não se tinha receita, somente despesas operacionais e VP_{cop} é dado pela equação:

$$VP_{cop} = \sum_{n=1}^n \frac{N_{winj} Cp_{winj}}{(1 + tma)^n} \quad (3.8)$$

com N_{winj} sendo a injeção mensal de água e Cp_{winj} o custo de injeção de água.

Neste estudo o VPL foi calculado para a data do final do histórico disponível inicialmente, ou seja, 31/5/2017. A taxa mínima de atratividade foi de 10% ao ano. Os demais parâmetros podem ser consultados na Tabela 3.12 e foram estimados a partir dos dados apresentados por AVANSI e SCHIOZER (2015).

3.5 Recursos Computacionais

Para a realização deste trabalho foi utilizado um *cluster* de computadores com as configurações dadas pelas Tabelas 3.13 e 3.14.

As simulações de fluxo utilizaram o software IMEX versão 2015.10 da *Computer Modeling Group* (CMG). Para o ajuste de histórico foi empregado o software

Tabela 3.12: Parâmetros utilizados para o cálculo do VPL

Parâmetro	Descrição	Valor	Unidade
C_f	Custo fixo da plataforma	417,00	MM de \$
C_{p_o}	Capacidade de produção de óleo	15,5	1000 m^3/d
C_o	Custo da capacidade de produção de óleo	16,4	MM de \$ por 1000 m^3/d
C_{p_w}	Capacidade de produção de água	13,95	1000 m^3/d
C_w	Custo da capacidade de produção de água	3,15	MM de \$ por 1000 m^3/d
$C_{p_{iw}}$	Capacidade de injeção de água	21,7	1000 m^3/d
C_{iw}	Custo da capacidade de injeção de água	3,15	MM de \$ por 1000 m^3/d
C_s	Custo por <i>slots</i> disponíveis	0,1	MM de \$ por slot
C_{p_s}	Número de <i>slots</i> disponíveis	25	-
$C_{pcli_{poço}}$	Custo de perfuração, completação, interligação	45	MM de \$
$CA_{poço}$	Custo de abandono do poço	8,2	% do valor de $C_{pcli_{poço}}$
P_o	Preço do óleo	314,5	\$ por m^3
C_{p_o}	Custo de produção do óleo	62,9	\$ por m^3
R_{oy}	<i>Royalties</i> pagos sobre a receita bruta	20	%
t_x	Imposto	30	%
C_{p_w}	Custo de produção de água	6,29	\$ por m^3
$C_{p_{winj}}$	Custo de injeção de água	6,29	\$ por m^3

Tabela 3.13: Configuração por CPU do *cluster* utilizado para a realização dos estudos.

CPU		
Modelo (Intel)	Cores/CPU	Clock MHz
Cluster X5690	6	3,466

Tabela 3.14: Configuração de cada nó e total de nós do *cluster* utilizado para a realização dos estudos.

Configuração de cada nó							Total Nós
CPUs	CPUs	Cores	RAM	Discos	Ethernet	IB	
2	12	96 Gb	2 x HD 1 TB	1 GbE	QDR	20	

Petrel versão 2015 em conjunto com o *Plug-in* BR-Kalman versão 21.116, com algumas alterações desenvolvidas especificamente para este trabalho. Para a seleção de cenários foi usado o método desenvolvido por ARMSTRONG *et al.* (2012) em uma implementação desenvolvida pela Petrobras e cujo cálculo da matriz de distâncias foi implementado em Python pelo autor. Já para a otimização do plano de desenvolvimento, o software utilizado foi o OCTOPUS versão 2.1.117.3 Beta 2 desenvolvido pela Petrobras em parceria com Laboratório de Inteligência Computacional (ICA) da PUC-Rio, com algumas alterações implementadas especialmente para este estudo.

Capítulo 4

Resultados e Discussões

No presente capítulo são apresentados e discutidos os resultados da aplicação da otimização em malha fechada do desenvolvimento de campos de petróleo sob incertezas geológicas. Inicialmente, seguindo a sequência apresentada no Capítulo 3, são destacados pontos relevantes de cada uma das etapas. A seguir, é analisado o desempenho geral da metodologia e, ao final, são feitas ponderações a respeito do custo computacional envolvido no estudo.

4.1 Ajuste de Histórico

Neste trabalho, o primeiro passo do DCMF consistiu no ajuste de histórico. Cada ciclo esse processo envolveu a inclusão de todos os dados disponíveis no momento. É evidente que a quantidade de informação aumentou com o passar do tempo, já que foram perfurados novos poços e dados de produção foram obtidos. Nesta seção é apresentada uma análise mais detalhada do Ciclo 3, intermediário em relação ao desenvolvimento do campo e, portanto, um bom parâmetro para observar o comportamento da etapa.

Ajuste de histórico do Ciclo 3

Conforme anteriormente exposto na Tabela 3.1 o ajuste de histórico do Ciclo 3 englobou os dados de produção e poços perfurados até 30/11/2018. Além dos 4 poços iniciais foram perfurados os Produtores 2, 7 e 9 e os Injetores 1, 6 e 8, cuja localização é apresentada na Figura 4.1.

A função objetivo que quantificou a diferença entre dados observados e dados simulados já foi apresentada na Equação 2.15. Pode-se dividir a função objetivo em duas partes: uma referente aos dados de produção e outra referente aos dados de perfil. O valor total que quantificou a qualidade do ajuste de histórico como um todo foi dado pela média ponderada dessas duas partes tendo como peso o número

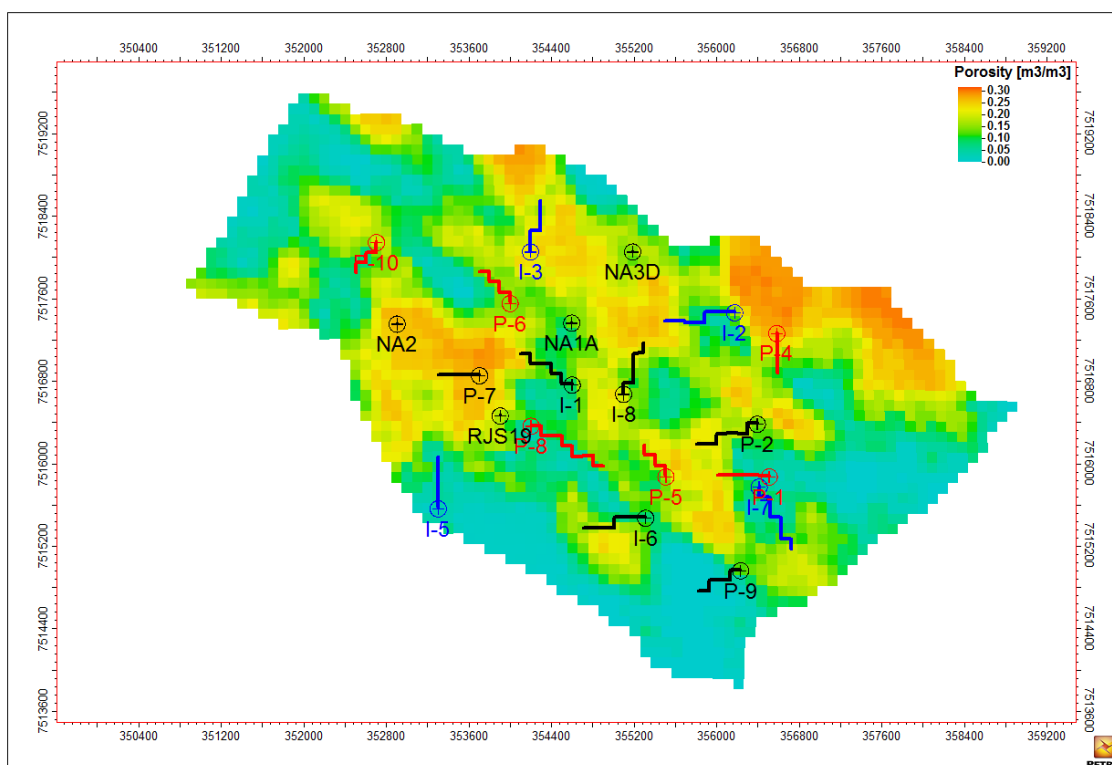


Figura 4.1: Em preto, os poços perfurados até 30/11/2018 que foram fonte dos dados observados do Ciclo 3, em um mapa de porosidade de um dos modelos.

de observações.

A Tabela 4.1 apresenta os resultados de cada uma dessas parcelas ao final das 4 iterações do ES-MDA. Neste ciclo em questão os valores das médias das funções objetivo de produção e de perfil sofreram reduções de 79,4% e 98,3% respectivamente. Para o total, valor que engloba os dois fatores, a redução foi de 88,1%.

Tabela 4.1: Valores das funções objetivo que quantificaram o ajuste de histórico para o Ciclo 3 - produção, perfil e total.

Conjunto antes do ajuste			
Valores	Dados Produção	Dados de Perfil	Total
Mínimo	0,42	18,18	1,59
Máximo	6,15	48,70	7,42
Média	1,89	31,86	3,35
Conjunto depois do ajuste			
Valores	Dados Produção	Dados de Perfil	Total
Mínimo	0,14	0,35	0,16
Máximo	1,16	1,05	1,13
Média	0,39	0,55	0,40

Ainda que esses dados indiquem uma boa qualidade do ajuste de histórico é interessante realizar uma verificação visual para confirmar os resultados. No caso

dos dados de perfil, uma boa maneira de comprovar a consistência dos resultados apresentados consiste em comparar os valores obtidos com o do modelo de referência. Para cada poço são apresentados três perfis: o primeiro corresponde ao perfil da porosidade do poço antes do ajuste de histórico; o segundo, após o ajuste e o terceiro traz os dados do modelo de referência. Os resultados apresentados são do modelo com melhor ajuste (ou seja, o modelo 308 que correspondente à função objetivo 0, 35 da Tabela 4.1).

Os poços Produtor 9 e Produtor 2 são os mais afastados dos 4 poços originais e, portanto, é de se esperar que apresentassem as maiores diferenças. Isso foi confirmado ao analisar as Figuras 4.2 e 4.3. Pode-se dividir o Produtor 9 em três principais trechos: de 3.000 a 3.300 m, de 3.300 a 3.525 m e de 3.525 até o final. Antes do ajuste, o primeiro trecho possuía a porosidade superestimada, o segundo subestimada e o terceiro novamente superestimada quando comparado com o modelo de referência. O ajuste de histórico conseguiu trazer a porosidade dos três trechos para valores mais próximos dos dados observados. No Produtor 2, também se verificou, após o ajuste, um perfil de porosidade muito próximo do modelo de referência e, sobretudo no segundo terço do poço, porosidades subestimadas são corrigidas para maiores valores.

O Produtor 7 não necessitou de tantos ajustes. Isso se deve, em parte, ao fato de estar localizado entre dois poços sobre os quais já se tinha informação (NA2 e RJS19). O mesmo raciocínio é válido para o Injetor 1 que se localiza entre o RJS19 e o NA1A. Entretanto, é importante observar que, ainda assim, os perfis ajustados se mostram mais aderentes ao modelo de referência com alterações no trecho final do poço Produtor 7 e no trecho inicial do poço Injetor 1.

Como os 4 poços iniciais foram utilizados para condicionar os modelos antes do ajuste de histórico, era de se esperar que suas porosidades já estivessem muito próximas dos valores do modelo de referência. Isso de fato aconteceu e o resultado dos poços NA1A e NA3D podem ser vistos nas Figuras 4.6 e 4.7. Os perfis dos demais poços do ciclo podem ser consultados no Apêndice A.

As Figuras 4.2 a 4.7 utilizaram o modelo que apresentou o melhor ajuste de histórico em relação aos dados de perfil. Fica a dúvida de qual seria o comportamento do modelo com o pior ajuste (ou seja, com valor igual a 1,05 da Tabela 4.1). Caso este pior ajuste ainda fosse satisfatório, pode-se concluir que independentemente do modelo escolhido, os dados e perfil terão sido honrados dentro de uma tolerância. Para examinar essa diferença, foram analisados mais uma vez os poços Produtor 9 e Produtor 2 que apresentaram as diferenças mais significativas entre os resultados antes e depois do ajuste de histórico.

As Figuras 4.8 e 4.9 compararam três perfis: melhor ajuste, pior ajuste e o modelo de referência. Nota-se que ainda existiam diferenças, mas sua magnitude não era




Figura 4.2: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Produtor 9.




Figura 4.3: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Produtor 2.




Figura 4.4: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Produtor 7.




Figura 4.5: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Injetor 1.




Figura 4.6: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço NA1A.




Figura 4.7: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço NA2.

significativa, de maneira que o comportamento do perfil do modelo de referência foi reproduzido no pior ajuste. Assim, pode-se afirmar que mesmo os modelos que apresentaram os piores valores da função objetivo para o ajuste de histórico de dados de perfil ainda os honraram de maneira satisfatória. Esses resultados indicam que o método ES-MDA foi bem sucedido no ajuste de histórico de dados de perfis de porosidade. De fato, isso era esperado uma vez que a assimilação de dados de perfis de porosidade corresponde a um problema inverso linear. Neste caso, o ES-MDA, assim como a maioria dos métodos baseados em Filtro de Kalman, convergem para a solução correta (analítica) do problema a medida que o número de realizações do conjunto tende ao infinito ((EMERICK e REYNOLDS (2013)).

Feita a análise do ajuste de histórico dos dados de perfil, passou-se a tratar dos dados de produção. Entretanto, convém ressaltar que apesar de analisadas de maneira separada, no ES-MDA, o processo foi feito em conjunto, não em etapas distintas.

Para avaliar o comportamento do ajuste de histórico dos dados de produção são apresentados os gráficos antes e depois da etapa para os parâmetros: vazão de óleo, vazão de gás, vazão de água (produzida ou injetada) e pressão de fundo. Os gráficos referem-se ao NA2, Injetor 8 e Produtor 7, que foram escolhidos para analisar a diversidade de poços existentes: um representante dos poços originais, um produtor e um injetor perfurados no desenvolvimento do campo. Os resultados dos demais poços desse ciclo podem ser consultados no Apêndice A.

Iniciando pelo poço NA2, na Figura 4.10 nota-se que houve pouca diferença entre o resultado antes e depois do ajuste de histórico. Para a produção de óleo isso acontece pois, conforme mencionado na Seção 3.1.1, as vazões de produção de óleo foram impostas como controle da simulação. Pelo fato do reservatório possuir a capacidade de produzir nas vazões especificadas, neste caso, os dados são honrados. A produção de gás foi basicamente devido ao gás em solução, uma vez que a região em torno do poço praticamente se mantém com pressões acima da pressão de saturação. Assim, pelo fato da vazão de gás ser função da vazão de óleo (que é imposta), esta também apresentou uma boa aderência aos dados observados antes mesmo do ajuste de histórico. Os gráficos que realmente mostram o efeito do ajuste são dados pela Figura 4.11. O poço NA2 teve o início da produção de água em meados de 2015 sendo que a dispersão dos resultados dos 500 modelos antes do ajuste de histórico foi significativa e passa a ser bem menor após o ajuste. Para a pressão de fundo o resultado foi ainda melhor.

Para poço Produtor 7 uma análise semelhante pode ser feita, o que explica os resultados mostrados nas Figuras 4.12 e 4.13. É interessante notar que neste poço ainda não havia a produção de água e que o ajuste da pressão de fundo se mostrou satisfatório diminuindo consideravelmente a dispersão que era observada




Figura 4.8: Perfis para o poço Produtor 9: modelo com melhor ajuste, pior ajuste e UNISIM-I-R.






Figura 4.9: Perfis para o poço Produtor 2: modelo com melhor ajuste, pior ajuste e UNISIM-I-R.

Poço NA2



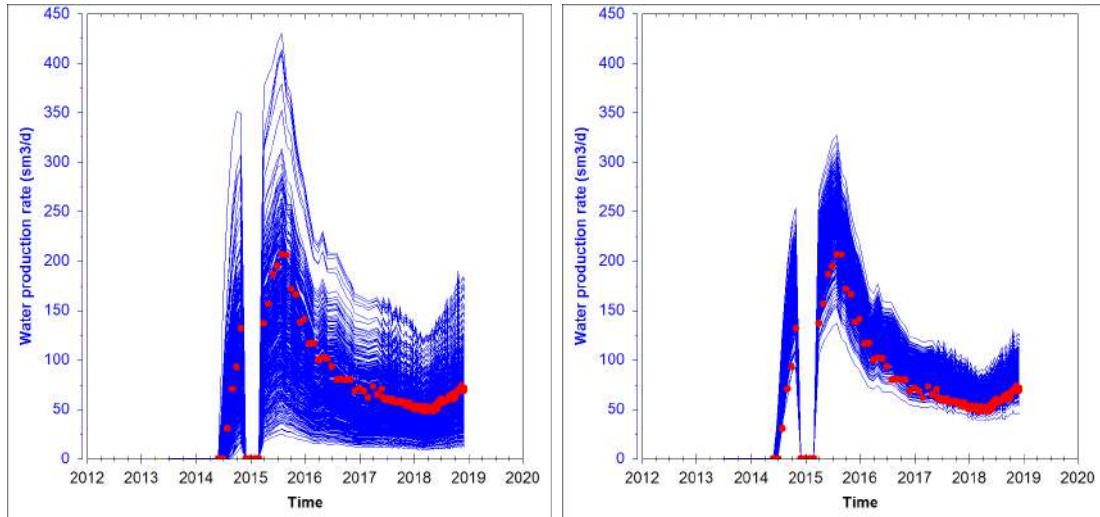
(a) Vazão de óleo antes do ajuste de histórico. (b) Vazão de óleo depois do ajuste de histórico.



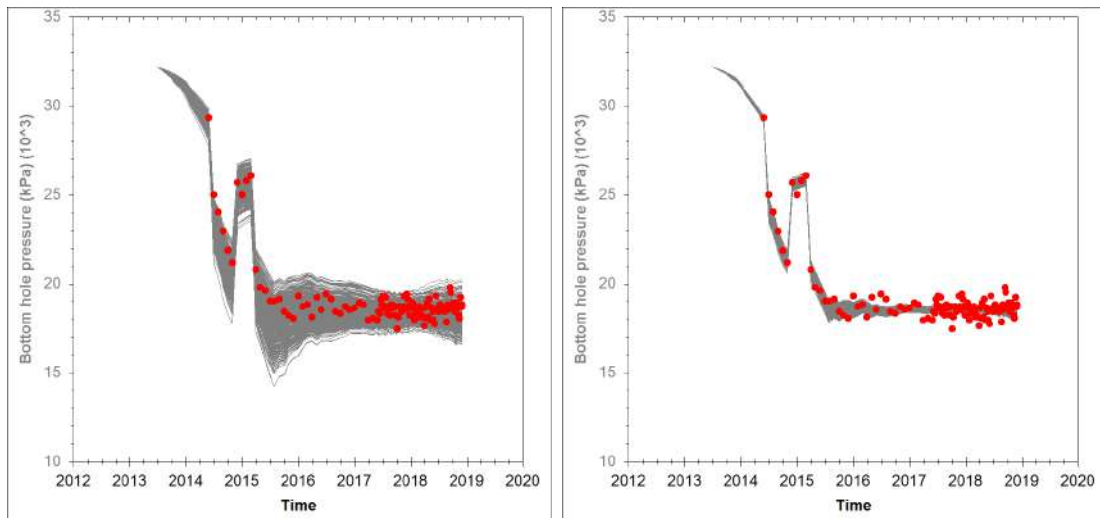
(c) Vazão de gás antes do ajuste de histórico. (d) Vazão de gás depois do ajuste de histórico.

Figura 4.10: Resultado do ajuste de histórico no poço NA2. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.

Poço NA2




(a) Vazão de água antes do ajuste de histórico. (b) Vazão de água depois do ajuste de histórico.



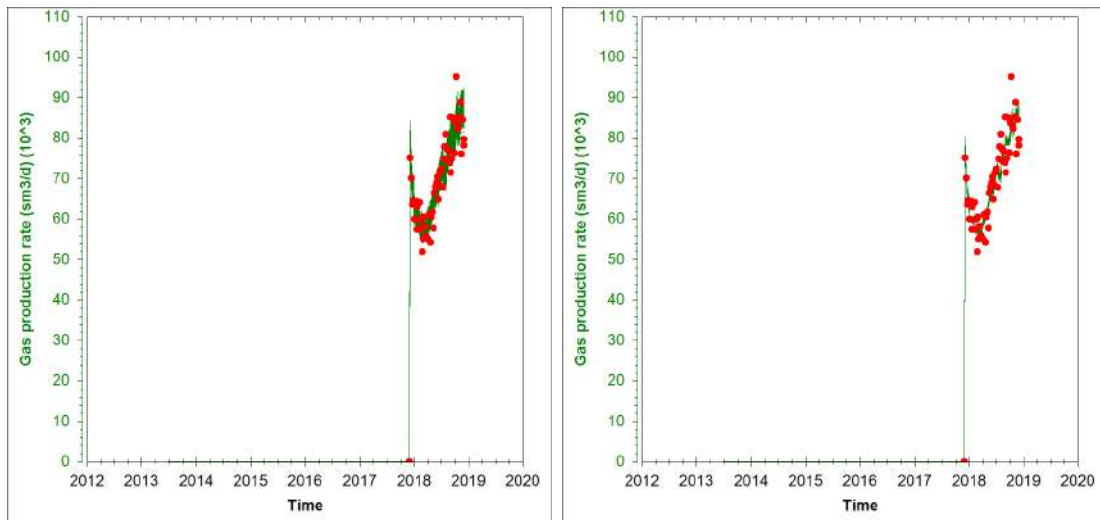
(c) Pressão de fundo antes do ajuste de histórico. (d) Pressão de fundo depois do ajuste de histórico.

Figura 4.11: Resultado do ajuste de histórico no poço NA2. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

Poço Produtor 7




(a) Vazão de óleo antes do ajuste de histórico. (b) Vazão de óleo depois do ajuste de histórico.




(c) Vazão de gás antes do ajuste de histórico. (d) Vazão de gás depois do ajuste de histórico.

Figura 4.12: Resultado do ajuste de histórico no poço Produtor 7. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.

Poço Produtor 7




(a) Vazão de água antes do ajuste de histórico. (b) Vazão de água depois do ajuste de histórico.




(c) Pressão de fundo antes do ajuste de histórico. (d) Pressão de fundo depois do ajuste de histórico.

Figura 4.13: Resultado do ajuste de histórico no poço Produtor 7. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

Poço Injetor 8



(a) Vazão de injeção de água antes do ajuste de histórico. (b) Vazão de injeção de água depois do ajuste de histórico.



(c) Pressão de fundo antes do ajuste de histórico. (d) Pressão de fundo depois do ajuste de histórico.

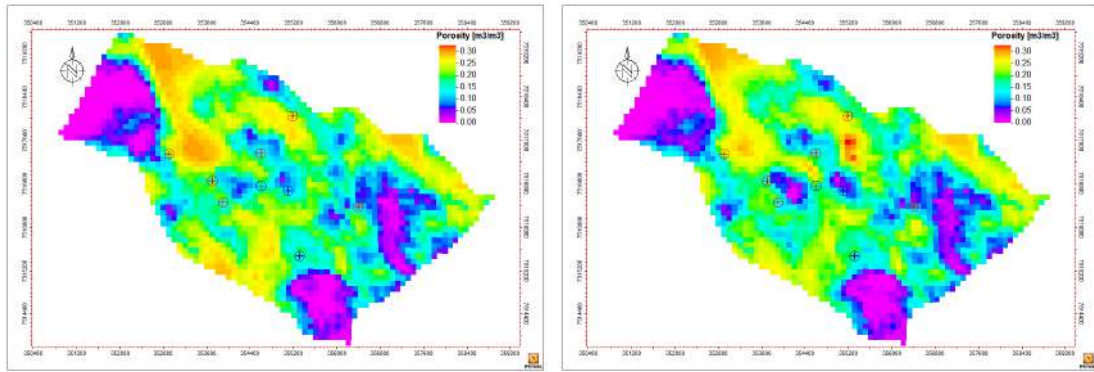
Figura 4.14: Resultado do ajuste de histórico no poço Injetor 8. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água de injeção: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

inicialmente.

O Injetor 8 apresentou um comportamento interessante que pode ser visto na Figura 4.14. Nos poços injetores foi especificada a vazão de água como controle de simulação, mas condicionada a um máximo de pressão de fundo (representando as limitações da bomba de injeção). Vários modelos do conjunto antes do ajuste de histórico se mostraram incapazes de honrar as vazões de injeção de água especificadas mesmo aplicando a maior pressão de fundo possível. Após o ajuste de histórico todos os modelos foram capazes de injetar as vazões impostas honrando os dados de pressão de fundo observados.

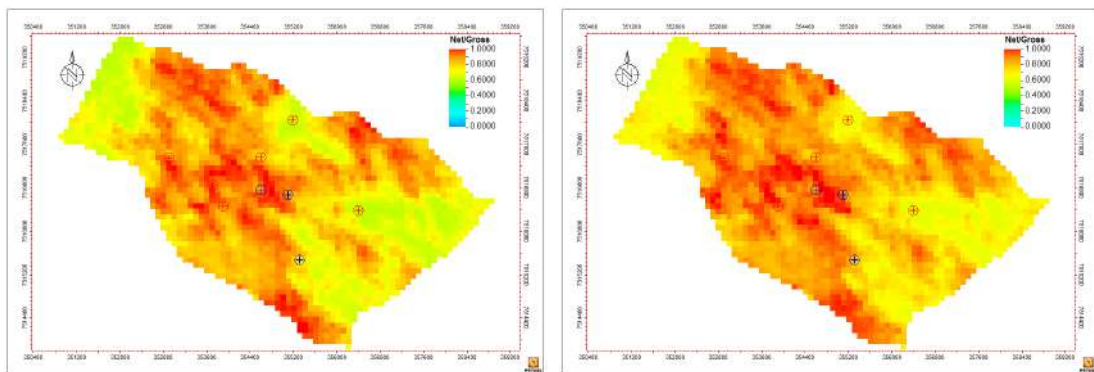
Sabendo que o resultado do ajuste de histórico poço a poço foi satisfatório, foram analisadas as mudanças realizadas nos parâmetros de ajuste para que esse resultado fosse obtido. Nas figuras seguintes são comparados os parâmetros de uma camada da malha para o modelo que apresentou o melhor ajuste de histórico.

Porosidade



(a) Porosidade da primeira camada antes do ajuste de histórico (b) Porosidade da primeira camada depois do ajuste de histórico

NTG



(c) NTG da primeira camada antes do ajuste de histórico (d) NTG da primeira camada depois do ajuste de histórico

Figura 4.15: Resultado do ajuste de histórico. Os mapas da esquerda representam a primeira camada do modelo inicial e o da direita o ajustado. Porosidade: (a) modelo inicial, (b) modelo ajustado. *Net to Gross*: (c) modelo inicial, (d) modelo ajustado.

Na Figura 4.15 pode-se notar que, para a porosidade, ainda que mudanças tivessem ocorrido, o modelo ajustado guardou muitas características do modelo inicial. Além disso, as maiores alterações foram observadas nas regiões próximas aos poços. Isso é evidente, por exemplo, na região de influência do Injetor 8. Portanto, os modelos que foram ajustados são plausíveis e não apresentaram nenhuma distorção ou mudança abrupta que os tornassem não geológicos. Esse tipo de problema é comum quando se trabalha com uma ajuste de histórico manual, em que se multiplica o valor da porosidade (ou permeabilidade) em uma determinada região de maneira a honrar os dados de produção.

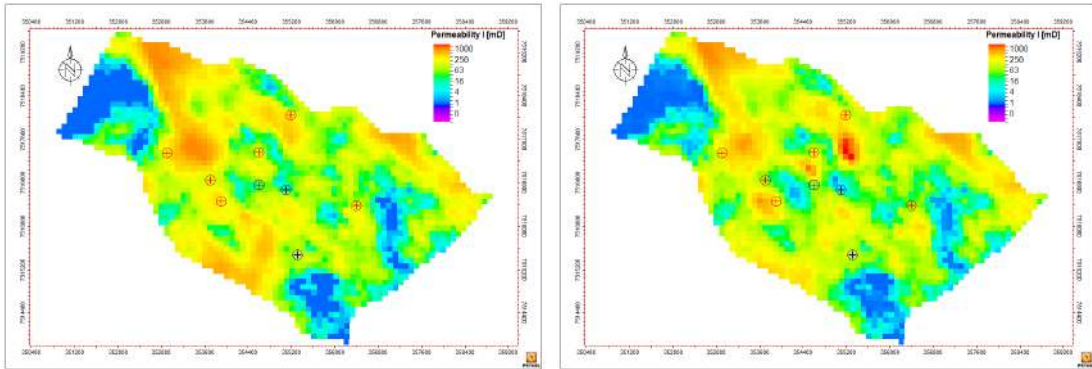
A permeabilidade apresentou uma estreita correlação com a porosidade. Isso já era esperado, uma vez que na geração dos modelos iniciais foi adotada a correlação dada pela Equação 2.27.

Finalmente, restou a comparação entre os modelos ajustados e o modelo de referência, o que pode ser visto na Figura 4.17.

Nota-se que foi grande a diferença entre o modelo ajustado e o modelo de referência. Primeiramente convém lembrar que o modelo ajustado sofreu uma mudança de escala, de forma que sua primeira camada corresponde a 8 camadas do UNISIM-I-R. Da mesma maneira, em I e em J tem-se muito mais células no modelo de referência. Apesar dessa ter sido a situação em um caso prático, já que os modelos de simulação serão sempre muito menos refinados do que a realidade, a comparação foi dificultada. Poder-se-ia realizar a mesma transferência de escala para o UNISIM-I-R de maneira a obter uma malha com o mesmo tamanho. Isso é mostrado na Figura 4.18, na qual se tem a evolução da porosidade ao longo de todos os ciclos e, ao final, também se tem o modelo de referência. Observou-se que, apesar de todos os dados incorporados, o modelo ao final do Ciclo 6 ainda foi significativamente diferente do modelo de referência. Entretanto, convém lembrar a natureza do problema de ajuste de histórico: obter um modelo (ou no caso deste trabalho um conjunto de modelos) que fosse capaz de honrar os dados observados dada uma certa tolerância. Nesse sentido, ao final dos ciclos, o ES-MDA se mostrou uma ferramenta de ajuste de histórico robusta conseguindo resultados mais do que satisfatórios. Outro aspecto evidenciado pela Figura 4.18 é que os modelos ao final do Ciclo 6 preservam muitas características dos modelos iniciais (Ciclo 0). Isso, na realidade, é uma consequência da formulação do método ES-MDA que pode ser interpretado como um processo de otimização que busca as menores alterações nos parâmetros do modelo necessárias para ajustar o histórico (EMERICK (2016)).

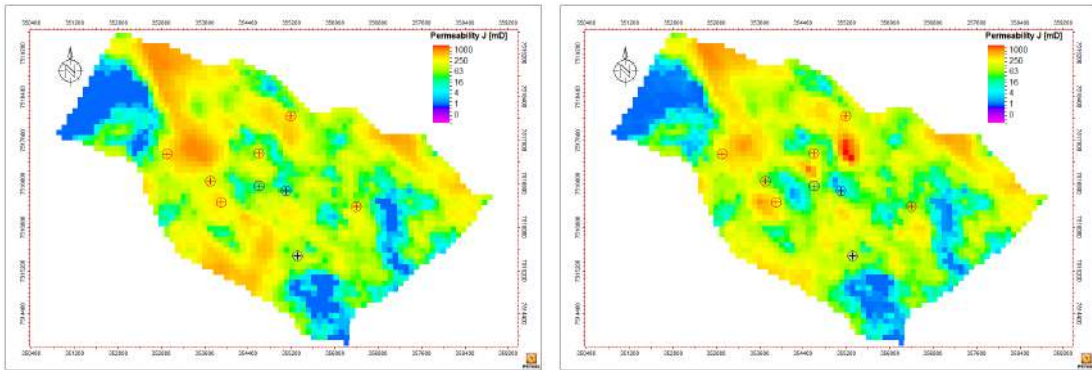
Em todos os ciclos, a análise do comportamento dos dados de produção e de perfil foi realizado em conjunto com uma análise da função objetivo obtendo resultados satisfatórios. A Tabela 4.2 elenca os valores da função objetivo. O Ciclo 5 apresentou valores mais altos da função objetivo (tanto antes quanto depois do ajuste), assim

Permeabilidade em I



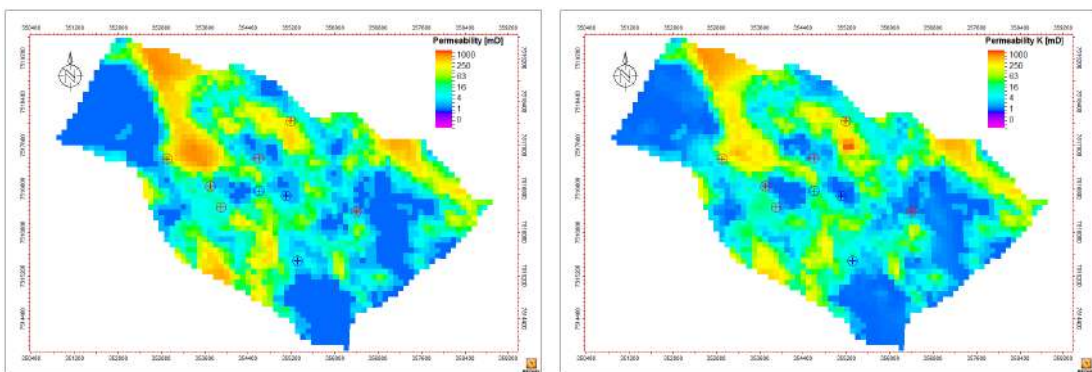
(a) Modelo inicial antes do ajuste de histórico. (b) Modelo ajustado depois do ajuste de histórico.

Permeabilidade em J



(c) Modelo inicial antes do ajuste de histórico. (d) Modelo ajustado depois do ajuste de histórico.

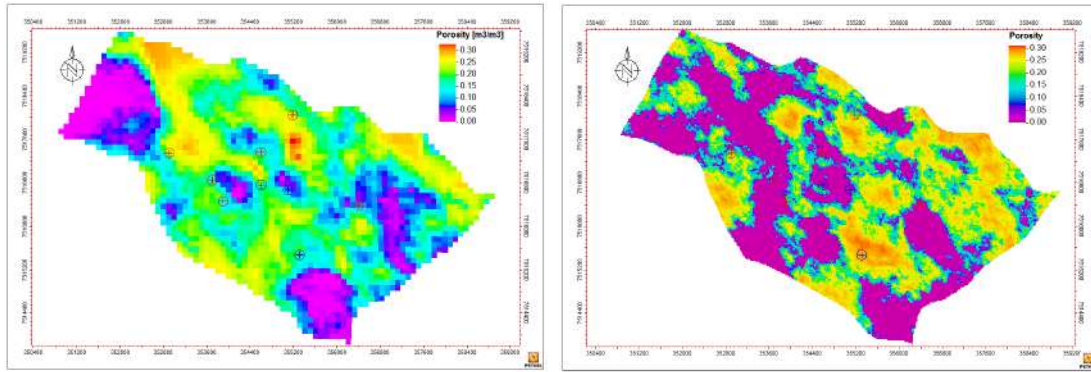
Permeabilidade em K



(e) Modelo inicial antes do ajuste de histórico. (f) Modelo ajustado depois do ajuste de histórico.

Figura 4.16: Resultado do ajuste de histórico. Os mapas da esquerda representam a primeira camada do modelo inicial e o da direita o ajustado. Permeabilidade: (a), (c), (e) modelos iniciais; (b), (d), (f) modelos ajustados.

Porosidade



(a) Modelo de melhor ajuste.

(b) UNISIM-I-R.

Figura 4.17: Comparação entre a porosidade da primeira camada do modelo que apresentou o melhor ajuste de histórico e o UNISIM-I-R, modelo de referência.

como uma menor redução da evolução da média da função objetivo ao longo dos ciclos, quando comparado com os demais ciclos. Uma possível causa seria o fato dos poços adicionados não terem sido capazes de honrar os dados observados. Tal efeito foi minimizado no Ciclo 6 com a adição de mais dados que facilitaram o ajuste. Com mais poços que foram capazes de honrar os dados o valor da função objetivo caiu.

Tabela 4.2: Evolução da média da função objetivo ao longo dos ciclos.

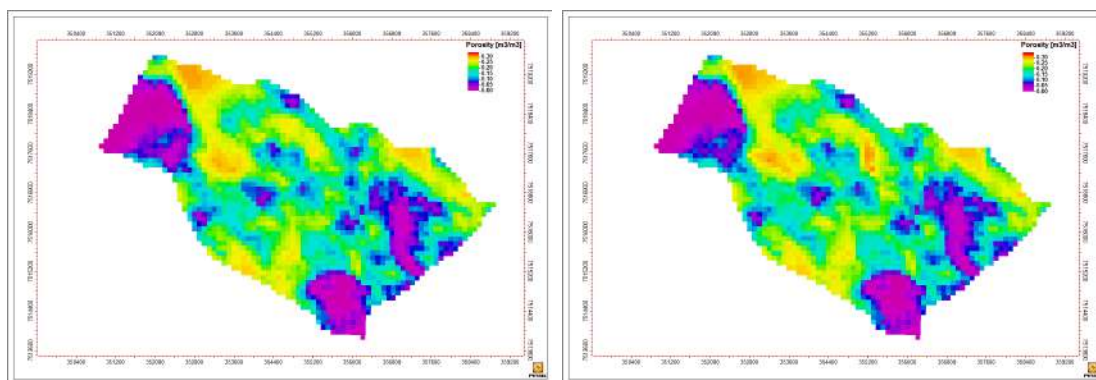
Ciclo	Antes do Ajuste	Após o Ajuste	Redução
0	1,44	0,25	83 %
1	3,11	0,20	93 %
2	4,22	1,42	66 %
3	3,35	0,40	88 %
4	3,62	0,42	88 %
5	8,76	4,92	44 %
6	4,04	0,68	83 %

Os resultados obtidos na etapa de ajuste de histórico mostraram que a escolha do ES-MDA se mostrou acertada. Foi possível obter modelos ajustados que foram capaz de honrar os dados observados dentro de uma certa tolerância. Com isso, os modelos condicionados tornaram-se capazes de fazer previsões mais acuradas.

4.2 Seleção de Modelos Representativos


A segunda etapa do DCMF consistiu na seleção de modelos representativos. Conforme apresentado na Seção 2.3, o número de MR é um parâmetro que deve ser definido *a priori* quando se trabalha com uma seleção baseada em *clusters*. Nesta Seção são apresentados os resultados que levaram à escolha de se trabalhar com 5

Porosidade




(a) Porosidade Ciclo 0.


(b) Porosidade Ciclo 1.




(c) Porosidade Ciclo 2.




(d) Porosidade Ciclo 3.




(e) Porosidade Ciclo 4.



(f) Porosidade Ciclo 5.



(g) Porosidade Ciclo 6.



(h) Porosidade UNISIM-I-R (upscaled).

Figura 4.18: Evolução do mapa de porosidade da primeira camada após o ajuste de histórico para um dos modelos ao longo dos ciclos e para o modelo de referência.

modelos representativos. Em seguida são analisados os resultados do Ciclo 1 assim como é utilizado o *Multidimensional Scaling* para melhor visualizar os resultados. No Apêndice B, os resultados dos demais ciclos estão disponíveis para consulta.

A seleção de MR sempre deve levar em conta dois fatores principais. Por um lado, sabe-se que quanto maior o número de modelos selecionados menor será a perda de informação gerada pela seleção mas, por outro, mais modelos selecionados equivalem a um maior custo computacional associado à otimização do plano de desenvolvimento. Dessa forma, foi necessário uma solução de compromisso que fosse capaz de conjugar um tempo de simulação aceitável com a capacidade de representar o conjunto do qual os modelos selecionados foram extraídos.

A função que quantifica a perda de informação decorrente da seleção de modelos já foi apresentada anteriormente na Equação 2.20, sendo que são desejáveis os menores valores possíveis de $D(J)$. Para o Ciclo Zero foi plotado o gráfico que relaciona os valores de $D(J)$ com o número de modelos representativos selecionados.




Figura 4.19: Valores da função objetivo variando o número de modelos selecionados, realizado no Ciclo 0.

Apresentando o comportamento esperado, quanto maior o número de modelos selecionados, menor a quantidade de informação que se perde, de tal forma que a curva se vai se aproximando de zero à medida que o tamanho do conjunto de modelos selecionados se aproxima do tamanho do conjunto inicial. Entretanto, sabe-se que um número elevado de modelos representativos seria inviável, devido ao custo computacional elevado. Utilizando a otimização do plano de desenvolvimento com os parâmetros apresentados na Seção 3.3, cada modelo a mais selecionado corresponderia a um potencial acréscimo de 1500 simulações (famílias com 30 indivíduos e um total de 50 gerações). Assim, fez-se necessário restringir o número máximo de

modelos representativos para um valor significativamente mais baixo. Realizando um aumento de escala na Figura 4.19 foi possível observar que passando de 1 modelo representativo para 5, a função objetivo diminuía 37%. Já passando de 5 para 10 modelos representativo a queda é de apenas 10%. Da mesma forma, analisando a derivada da curva da função objetivo pode ser verificado que após 5 modelos representativos a variação da queda da função objetivo praticamente se estabilizava.




Figura 4.20: Valores da função objetivo variando o número de modelos selecionados para um conjunto de até 10 indivíduos, realizado no Ciclo 0.




Figura 4.21: Derivada dos valores da função objetivo para um conjunto de até 10 indivíduos, realizado no Ciclo 0.

Portanto, optou-se por adotar o número de modelos representativos igual a 5. Ainda que tradicionalmente se trabalhe com 3 (o P10, P50 e P90 apresentados na Seção 2.3) neste estudo foram incluídos mais 2 modelos de maneira a se ter uma maior representatividade do conjunto inicial.

Utilizando a implementação apresentada na Seção 3.2, para o Ciclo 1, foram obtidos os resultados da Tabela 4.3. Nela se tem o número do modelo selecionado dentre os 500 possíveis bem como suas respectivas probabilidades.

Tabela 4.3: Modelos representativos selecionados e suas probabilidades atualizadas para o Ciclo 1.

Número do Modelo	Probabilidade Atualizada
185	16,6%
240	11,0%
380	28,4%
440	22,2%
488	21,8%

Uma boa maneira de verificar a qualidade da seleção dos modelos representativos consistiu em utilizar o *Multidimensional Scaling* para resumir todas as informações da matriz de distâncias (Equação 2.19) em um gráfico 2D e ter uma representação visual. Utilizando a formulação apresentada na Seção 2.3.1, em que cada modelo do conjunto foi representado por um ponto, obtém-se o resultado da Figura 4.22. Quanto menor a distância entre os pontos, maior a similaridade entre os modelos. O gráfico mostra uma boa divisão do conjunto inicial de 500 modelos, dividindo-os em *clusters* relativos ao modelo representativo mais próximo.




Figura 4.22: Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 1. As cinco diferentes cores representam os *clusters* associados a cada um dos modelos representativos selecionados (em vermelho).

Outra forma de analisar a qualidade da seleção dos modelos representativos se baseia na verificação dos pares de parâmetros mais importantes conforme apresen-

tado na Figura 4.23. Esperava-se encontrar uma correlação entre maiores Np e maiores VPLs. Entretanto, o mesmo não foi válido para o VOIP, isto é, existiam modelos com volumes elevados mas VPLs baixos. Isso é compreendido pelo fato de que um maior volume não necessariamente levar a uma melhor resposta em fluxo. De qualquer maneira, verificou-se que se tinha uma boa seleção para os parâmetros apresentados. Os demais pares de parâmetros para o Ciclo 1 podem ser consultados no Apêndice B.

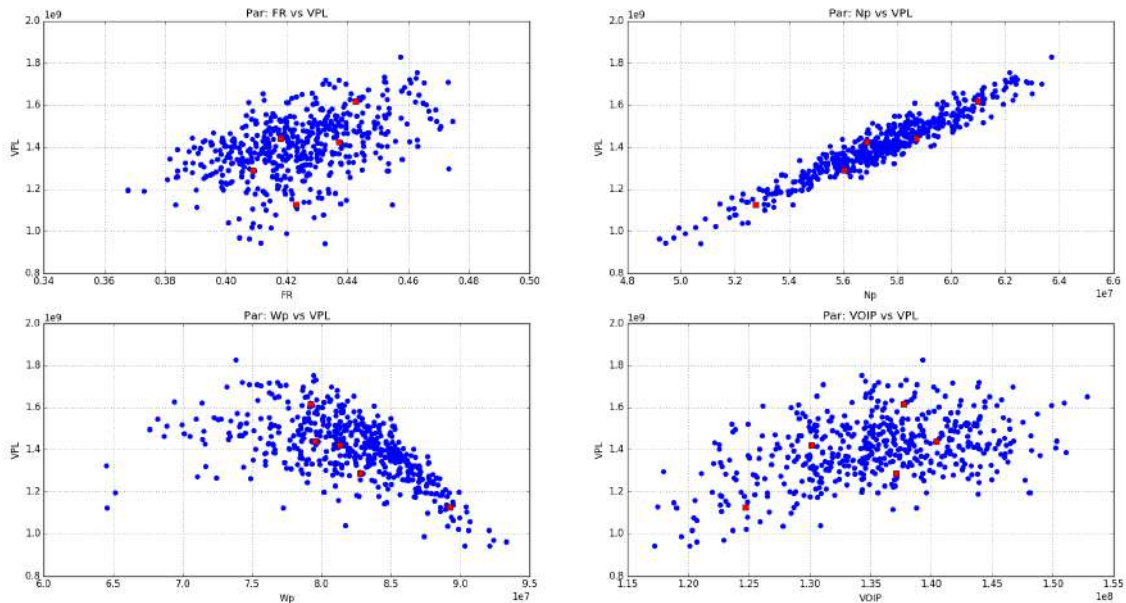


Figura 4.23: Gráficos combinando dois parâmetros da seleção de modelos representativos para o Ciclo 1. Os pontos em vermelho correspondem aos modelos selecionados e os pontos em azul representam os demais modelos.

Uma terceira forma de verificar a consistência da seleção de modelos representativos consistiu na análise da distribuição da frequência acumulada dos parâmetros. Na Figura 4.24 pode-se analisar a frequência acumulada dos parâmetros com maior peso e a posição dos modelos selecionados para o Ciclo 1. Nota-se que, sobretudo para o VPL, obteve-se uma boa distribuição com o método de seleção de modelos representativos sendo capaz de abranger boa parte do intervalo. O modelo representativo com menor VPL apresentou uma frequência acumulada de 0,045 e o de maior VPL 0,925. Para os demais também se obteve uma boa distribuição, sempre tendo em mente o peso que foi atribuído ao parâmetro. Os gráficos dos demais parâmetros podem ser consultados no Apêndice B.

Para o Ciclo 2 continuava-se a ter uma boa consistência na seleção ao analisar o gráfico gerado pelo MDS, como pode ser visto na Figura 4.25. O mesmo ocorreu para os demais ciclos. Os resultados de todos os ciclos estão disponíveis para consulta no Apêndice B.

A etapa da seleção de cenários apresentou resultados satisfatórios ao longo de

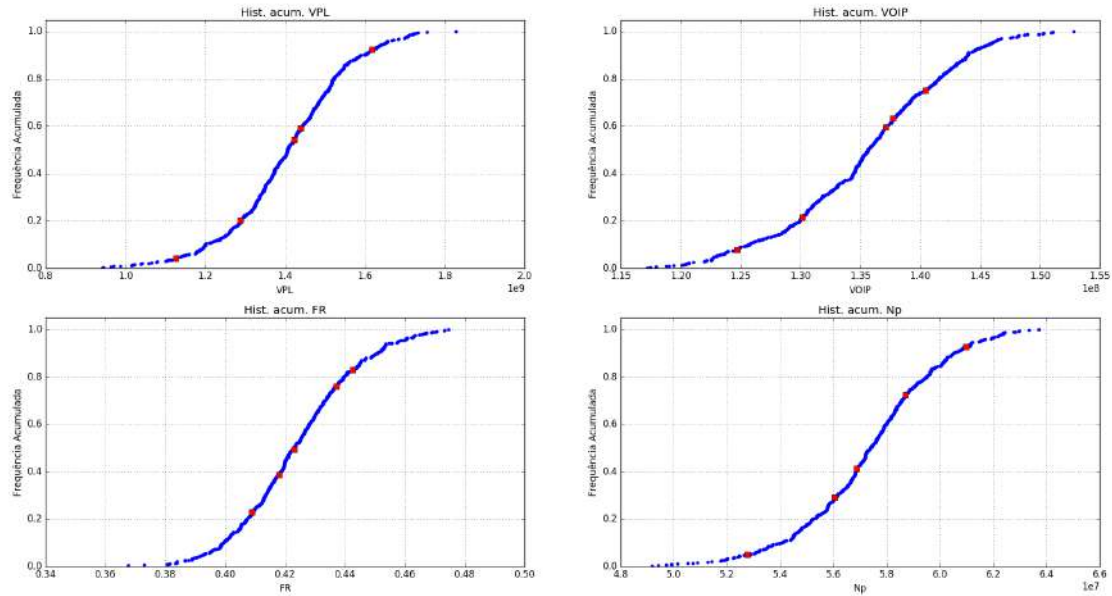


Figura 4.24: Frequência acumulada dos parâmetros com maior peso na seleção para o Ciclo 1. Os pontos em vermelho correspondem aos modelos selecionados e os pontos em azul os demais modelos.




Figura 4.25: Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 2. As cinco diferentes cores representam os *clusters* associados a cada um dos modelos representativos selecionados (em vermelho).

todos os ciclos. O conjunto de pesos atribuídos aos diversos parâmetros foi capaz de proporcionar uma seleção de modelos representativos do conjunto.

4.3 Otimização do Plano de Desenvolvimento

Em relação à otimização do plano de desenvolvimento, foi possível realizar dois tipos distintos de análise. A primeira levou em conta os ganhos ou perdas dentro de cada ciclo, observando as mudanças nas locações e no número de poços bem como a comparação do VPL do conjunto de modelos incertos antes e depois da otimização. Este é o tema da Seção 4.3. A segunda tratou da otimização do plano de drenagem como um todo, avaliando, sobretudo, os ganhos ao longo de todo o processo quando o PD era aplicado ao modelo de referência. Este é o tema da Seção 4.4.

Algumas considerações devem ser feitas à respeito das escolhas apresentadas na Seção 3.3, relativas a metodologia empregada. O primeiro ponto refere-se ao fato de que neste estudo foi otimizado todo o plano de drenagem ao invés disso ser feito somente para os poços a serem perfurados no próximo ciclo. Isso se deve aos resultados obtidos por SHIRANGI e DURLOFSKY (2015) onde a média do VPL foi superior em 16% quando se otimizava todo o plano de drenagem em comparação àquela realizada poço a poço. Isso vem ao encontro da ideia do DCMF no qual se pretende tomar decisões de curto prazo (locação do próximo poço) tendo em vista o desempenho geral do campo ao longo de todo o período de concessão.

O segundo ponto que mereceu destaque foi a otimização do plano de desenvolvimento sob incertezas, ou seja, utilizar como função objetivo do otimizador o VME dos 5 modelos representativos. Essa escolha teve como base os resultados obtidos por SILVA (2016) em que ficava evidente que a melhor estratégia de produção era encontrada ao trabalhar com um conjunto de modelos representativos em detrimento a uma otimização de cada um dos modelos.

Também se destaca aqui a escolha dos parâmetros do algoritmo genético empregados (Tabela 3.11), sobretudo o tamanho da população (30 indivíduos) e a quantidade de gerações (50). Esses valores poderiam ser aumentados resultando em um tempo de otimização maior, que levariam a melhores resultados de VME. Entretanto, foram utilizados valores típicos empregados em outros casos reais, coerentes com estudos de reservatórios em modelos de fluxo com tempo de simulação bem superior ao UNISIM-I. A lógica por trás desta escolha foi a de que os resultados obtidos fossem fruto de parâmetros considerados aplicáveis em casos práticos.

É importante ressaltar ainda que, para todos os ciclos da otimização do plano de desenvolvimento, foi fornecido um plano de drenagem inicial (semente inicial). EMERICK *et al.* (2009) mostraram que essa prática trazia melhores resultados quando comparado com a geração de um plano de drenagem totalmente aleatório.

A seguir serão apresentados resultados de cada ciclo e ao final será feito um balanço do processo de otimização do plano de drenagem como um todo.


Ciclo Zero

A análise mais imediata que pode ser realizada em relação à otimização do plano de desenvolvimento diz respeito à mudança da locação dos poços devido à otimização. Para o Ciclo 0 isso pode ser visto na Figura 4.26. A notação de cores utiliza poços perfurados em preto, poços a serem perfurados em vermelho (produtores) ou em azul (injetores). Nota-se que a configuração inicial de poços verticais foi substituída por poços direcionais. Como esse primeiro ciclo realizava apenas o ajuste dos dados de produção dos 4 anos iniciais, apenas os 4 poços originais foram mantidos, sendo que todos os demais tiveram alterações nas suas trajetórias. Entretanto, nota-se que mesmo com as mudanças, a estratégia manteve muitas características pré-otimização, inclusive o número de produtores e injetores. Esse resultado mostra que, para este desenvolvimento em questão, os poços direcionais possuem uma melhor resposta em termos de produção do que os verticais. Além disso, o próprio posicionamento dos poços foi alterado de maneira a ter uma maior eficiência na drenagem.

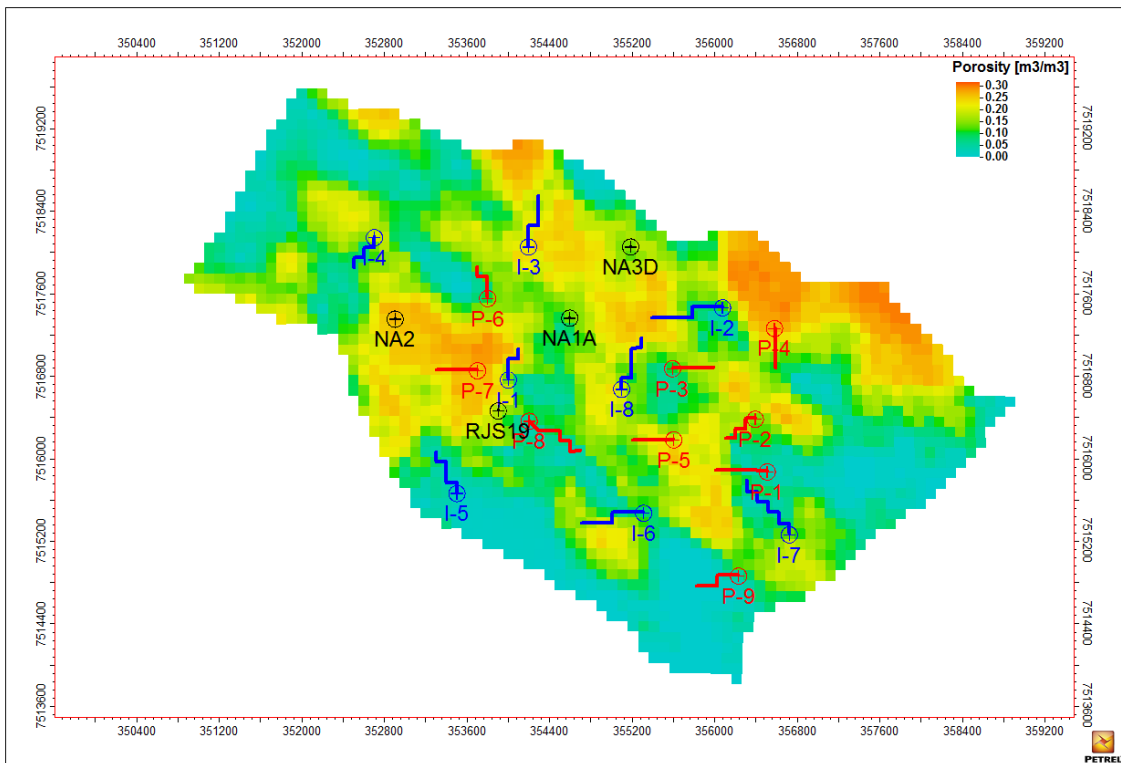
O processo de otimização da malha de drenagem passou por diversas evoluções ao longo do processo do algoritmo genético, que é melhor acompanhado com a Figura 4.27. A semente inicial apresentava um VME adimensional igual a 1 e ao longo das gerações o plano de drenagem foi sendo melhorado. Cada aumento no eixo y dos pontos em laranja significa que foi encontrando um indivíduo entre a população daquela geração cujo VME era maior do que o do melhor indivíduo da geração anterior. Ao longo das 50 gerações teve-se um total de 25 trocas de melhor indivíduo. Pode-se analisar também a média do VME dos indivíduos de cada geração, representada pelos pontos em verde no gráfico. Inicialmente existia uma grande diferença entre a média e o melhor indivíduo mas ao longo das gerações essa diferença foi diminuindo. Isso era o esperado devido à formulação da otimização ter sido realizada pelo algoritmo genético que tende a preservar as características dos melhores indivíduos.

Para quantificar os ganhos do Ciclo 0, a malha de drenagem resultante da otimização do VME dos 5 modelos representativos foi aplicada ao conjunto de 500 modelos. Assim, puderam ser analisados os resultados antes e depois da etapa em relação ao VPL, N_p , W_p , FR e VOIP, como apresentado nas Figuras 4.28 a 4.32.

Na Figura 4.28 é fácil notar o ganho da otimização para o VPL. A curva em vermelho, correspondente à frequência acumulada, desloca-se significativamente para a direita evidenciando resultados melhores. A média dos valores dos 500 modelos teve um aumento de 46,7%. Obviamente esse resultado deve ser compreendido dentro das limitações que suas premissas trazem. É claro que, como o plano de drenagem inicial havia sido melhorado apenas manualmente, o espaço para ganhos era bem



(a) Plano de desenvolvimento do Ciclo 0 antes da otimização.



(b) Plano de desenvolvimento do Ciclo 0 depois da otimização.

Figura 4.26: Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 0. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.




Figura 4.27: Evolução do VME do melhor plano de drenagem (indivíduo) e da média do VME da população ao longo das 50 gerações para o Ciclo 0.




Figura 4.28: Histogramas do VPL para o Ciclo 0, antes e depois da otimização.

maior. Portanto, era natural que nos próximos ciclos o produto da otimização não se apresentasse tão expressivo. Além disso, resta saber se o plano de drenagem resultante da otimização realizada no conjunto se traduzirá em um melhor VPL quando aplicado no modelo de referência. Esse ponto em questão, será detalhado na Seção 4.4. Por hora, ao realizar uma análise do conjunto de modelos incertos, a otimização se mostrou capaz de melhorar o plano de desenvolvimento dadas as condições existentes.

A produção acumulada de óleo acompanhou e justificou o melhor VPL obtido após a otimização. Não somente se obteve um melhor VPL após a otimização como

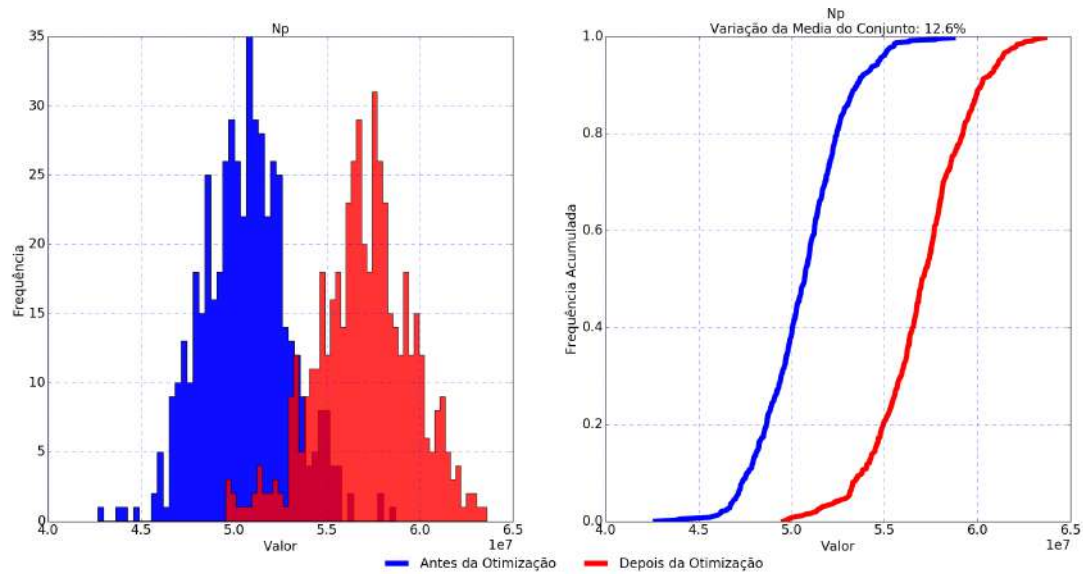


Figura 4.29: Histogramas do N_p para o Ciclo 0, antes e depois da otimização.

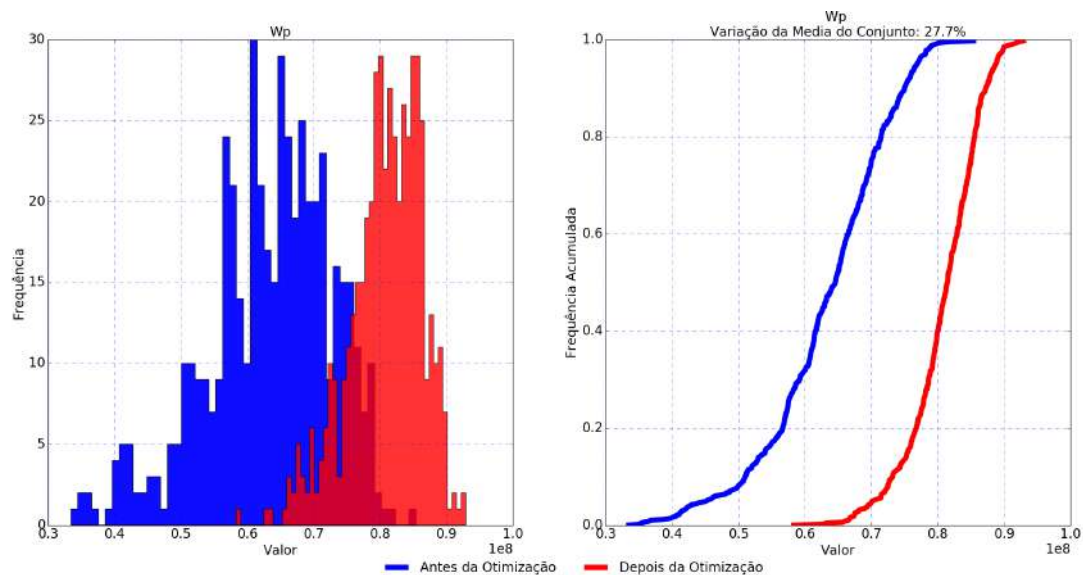


Figura 4.30: Histogramas do W_p para o Ciclo 0, antes e depois da otimização.

também o reservatório foi varrido de uma maneira mais eficiente. Isso é evidenciado pelo aumento de 12,6% no fator de recuperação conforme pode ser visto na Figura 4.31. Em relação ao VOIP, a Figura 4.32 consistia apenas de uma verificação. Era de se esperar que uma mudança na malha de drenagem não alterasse em nada o volume de óleo existente inicialmente já que tal propriedade independe da forma como o reservatório é explorado. Assim, as curvas antes e depois da otimização são coincidentes.




Figura 4.31: Histogramas do FR para o Ciclo 0, antes e depois da otimização.




Figura 4.32: Histogramas do VOIP para o Ciclo 0, antes e depois da otimização.

Ciclo 1

Para o Ciclo 1 a otimização manteve o número de poços produtores e injetores. Como nesse ciclo foram perfurados o Injetor de Água 8 e o Produtor 7, sobraram 15 poços a serem otimizados. A modificação das locações dos poços pode ser vista na Figura 4.33. Nota-se que as mudanças já foram bem mais sutis. Isso se deve, em parte, ao fato de já se iniciar com uma malha que havia sido otimizada. Além disso, ainda era pouca a informação obtida com os novos poços. Nota-se que o Produtor 7 está localizado entre dois poços já perfurados e o Injetor de Água 8, mesmo estando um pouco mais afastado, também se encontra no centro do bloco central. Dessa forma, foram alterados o comprimento de alguns poços assim como a localização de

outros. O comportamento geral, entretanto, foi bem próximo ao da semente inicial. Ainda assim, ocorreram 19 alterações do melhor indivíduo ao longo das gerações. Quando aplicado aos 500 modelos, a malha otimizada obteve um aumento na média do VPL de 7,51%.

Ciclo 2

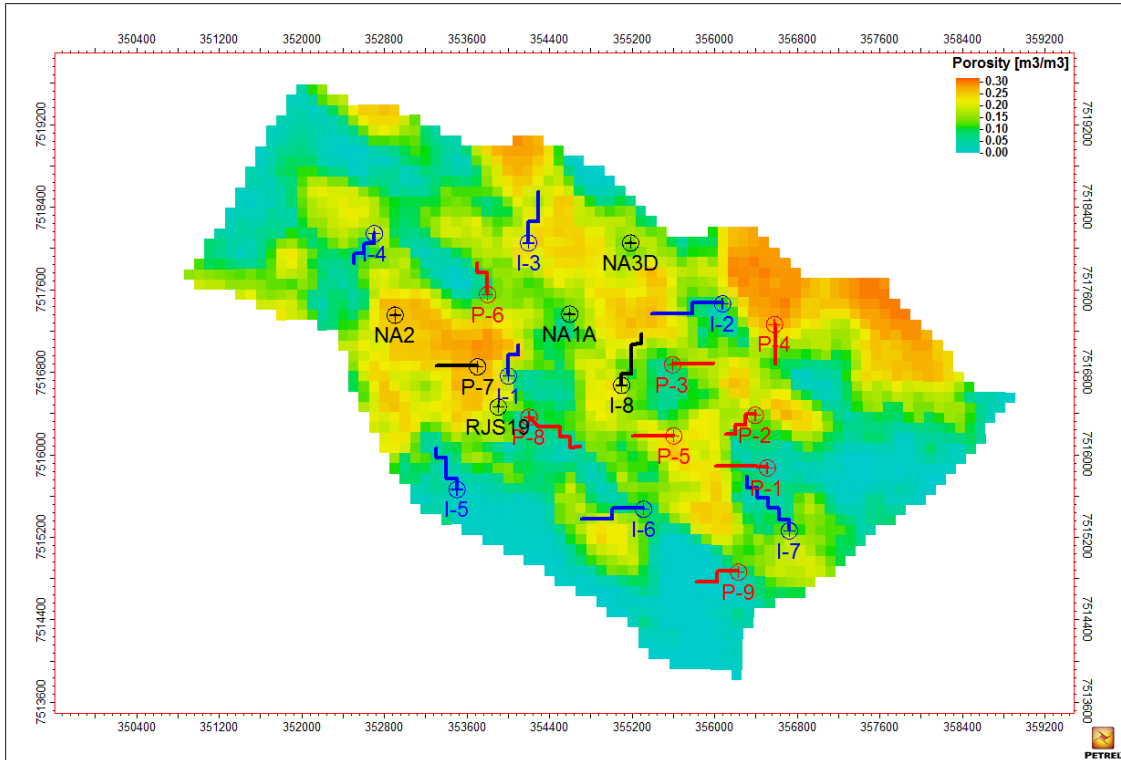
No Ciclo 2 foram perfurados os poços Injetor de Água 1 e Produtor 9 e as alterações no plano de desenvolvimento foram mais significativas. O poço injetor localizado ao Noroeste do reservatório (Injetor 4) foi transformado em produtor (Produtor 10). Também foi suprimido um dos poços produtores (Produtor 3) sendo que os outros dois poços que drenavam a região foram espaçados. O Injetor 5 localizado no Sudoeste do bloco teve sua orientação alterada. Com isso, o novo plano de desenvolvimento passou a contar com 20 poços no total sendo que destes 13 eram produtores e 7 injetores. Para chegar a esta malha ocorreram 12 mudanças do melhor indivíduo e, aplicando-se aos 500 modelos foi obtido um aumento na média do VPL de 7,74%. O plano de desenvolvimento pode ser vistos nas Figuras 4.34.

Ciclo 3

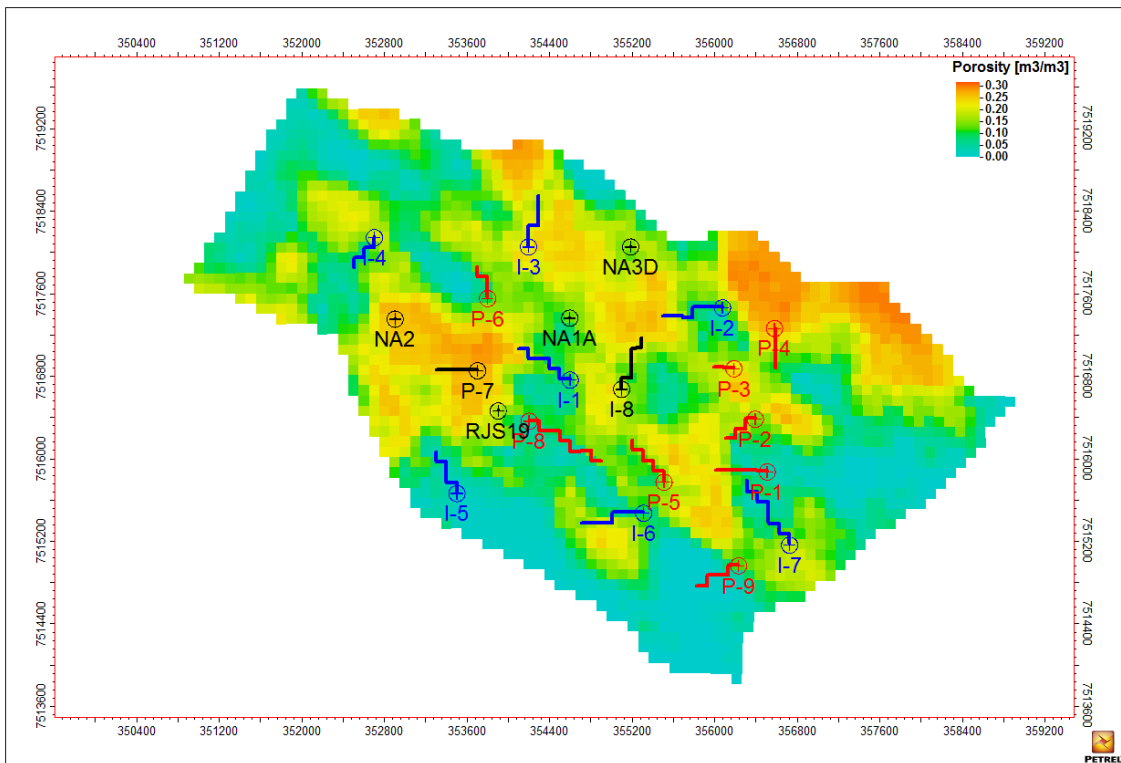
No terceiro ciclo foram perfurados o Injetor de Água 6 e o Produtor 2. Na Figura 4.35, nota-se que a mudança mais significativa após a otimização da malha de drenagem consistiu na remoção do injetor localizado no Sudeste do reservatório (Injetor 7). Além disso, dois produtores (Produtor 5 e Produtor 1) foram aproximados, talvez até mesmo de uma forma que poderia ser considerada excessiva. Ainda que em uma primeira análise tal configuração não seja a melhor (dada a proximidade dos poços), optou-se por não fazer nenhuma alteração. É provável que, em um desenvolvimento real de campo, essa proximidade levasse a maiores estudos com um consequente afastamento dos poços. Entretanto, ao considerar que não se desejava interferir manualmente no resultado da otimização (testando assim a metodologia) e que a locação respeitou a restrição inicial de distância mínima entre poços de 100 m, manteve-se a posição dos poços. Com essa alteração o plano de desenvolvimento passou a ter 19 poços no total divididos em 13 produtores e 6 injetores. O novo plano de desenvolvimento apresentou um aumento na média do VPL dos 500 modelos de 11,49%.

Ciclo 4

No quarto ciclo foram perfurados os poços Injetor 2 e Produtor 8. Conforme se vê na Figura 4.36 não ocorreram alterações substanciais na malha de drenagem. Entretanto, mesmo com poucas alterações, a média do VPL do conjunto aumentou em

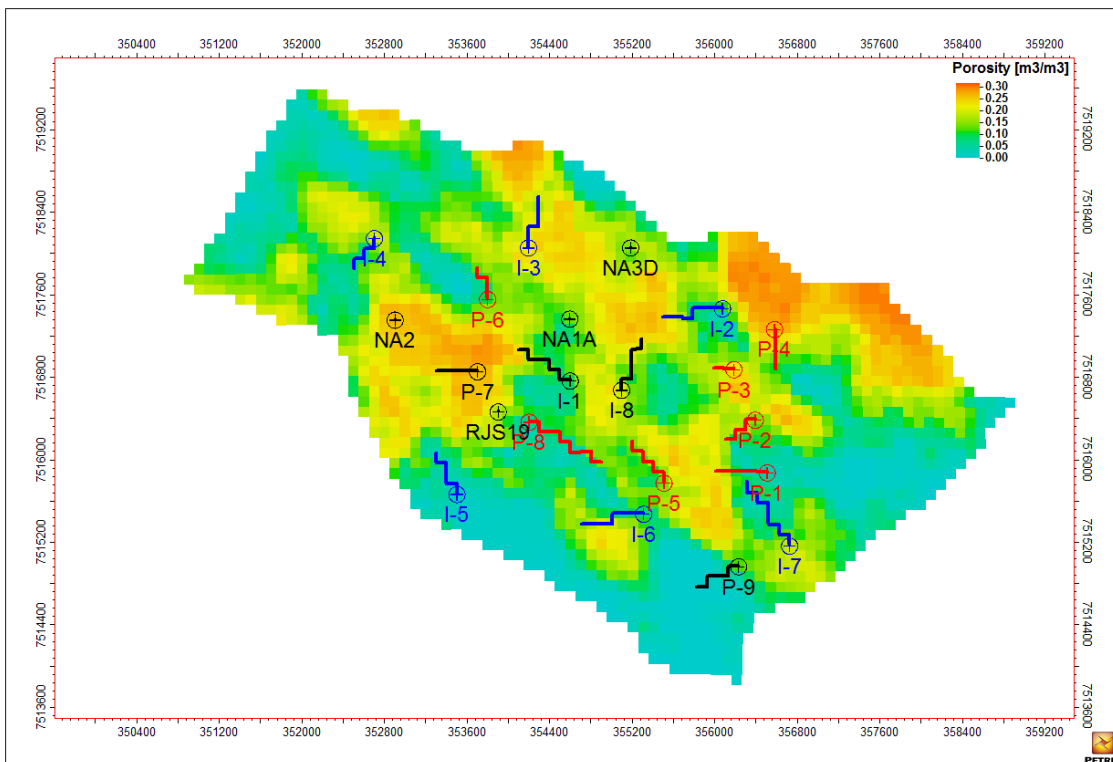


(a) Plano de desenvolvimento do Ciclo 1 antes da otimização.

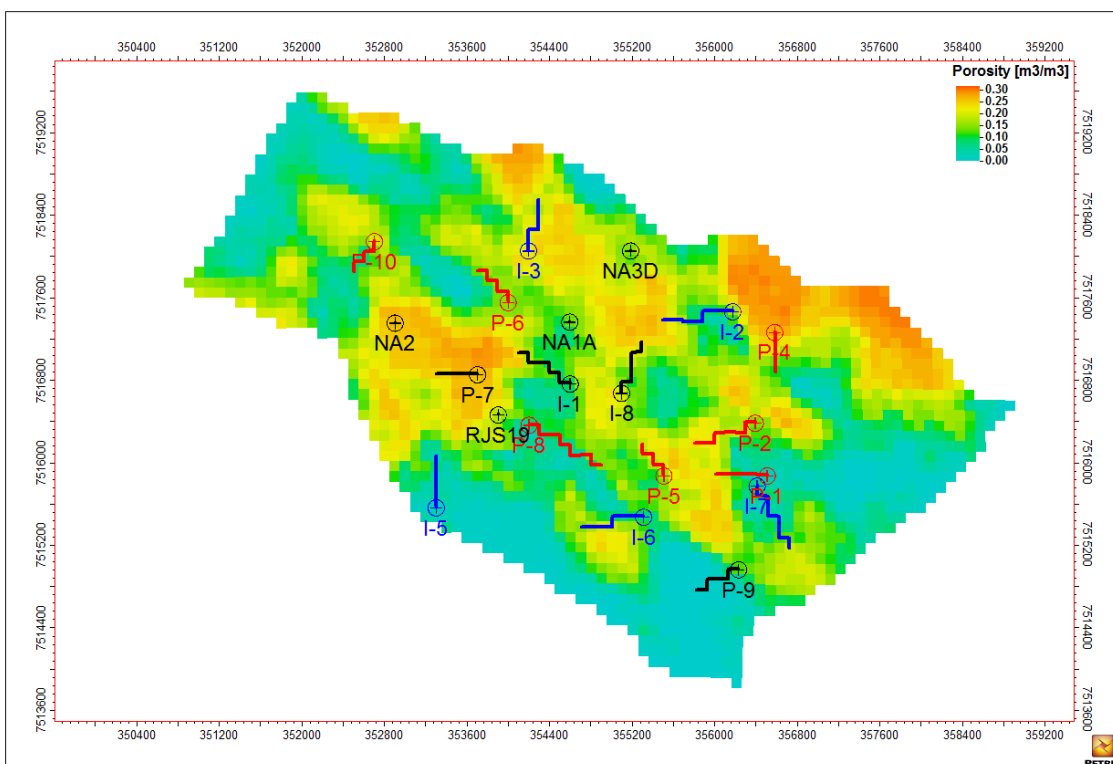


(b) Plano de desenvolvimento do Ciclo 1 depois da otimização.

Figura 4.33: Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 1. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.

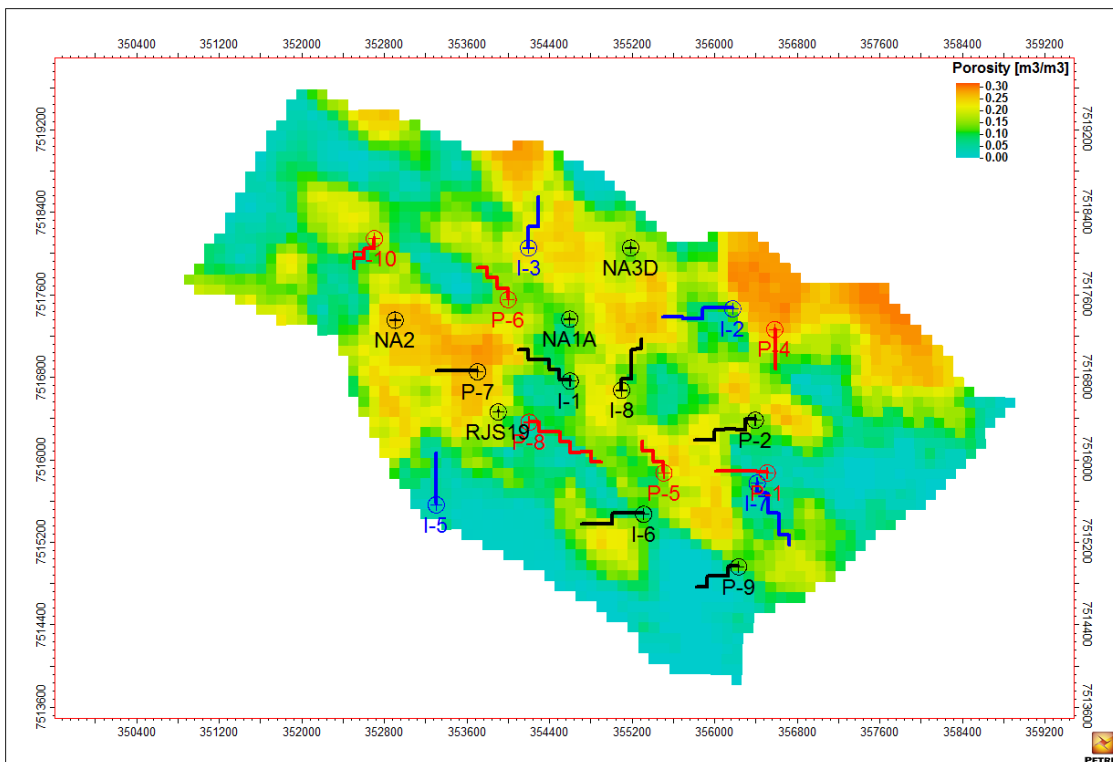


(a) Plano de desenvolvimento do Ciclo 2 antes da otimização.

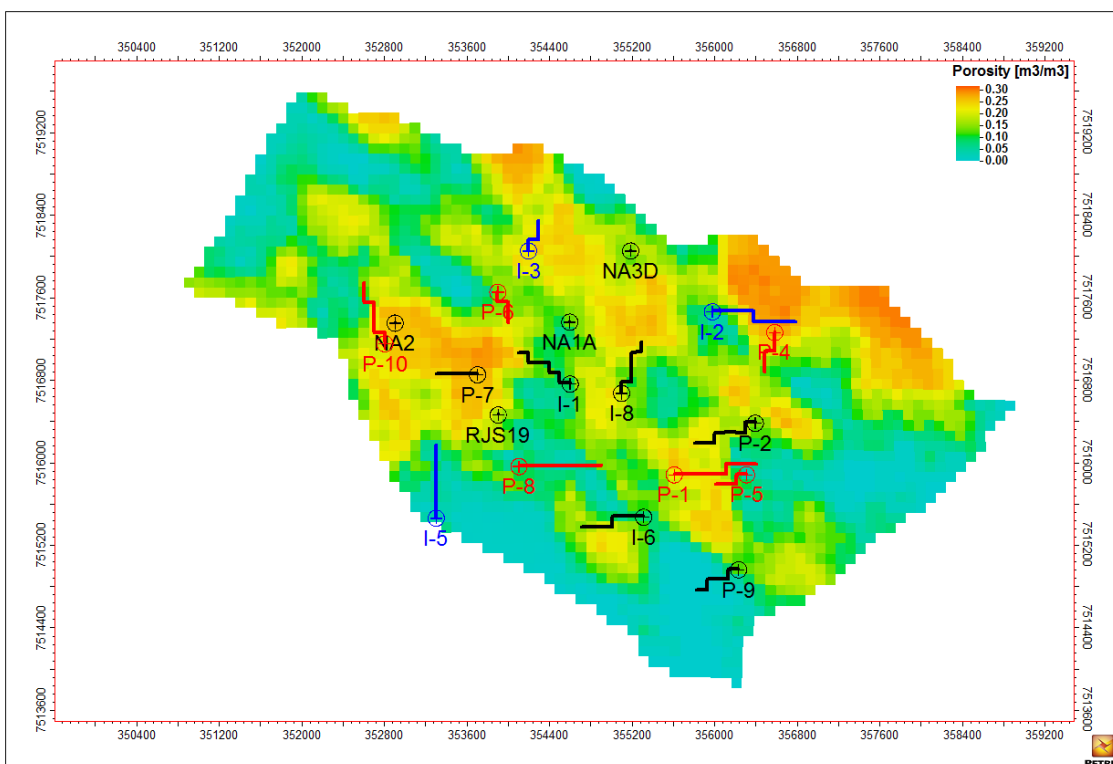


(b) Plano de desenvolvimento do Ciclo 2 depois da otimização.

Figura 4.34: Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 2. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.



(a) Plano de desenvolvimento do Ciclo 3 antes da otimização.



(b) Plano de desenvolvimento do Ciclo 3 depois da otimização.

Figura 4.35: Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 3. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.

4,20%. Aqui pode-se entender que as restrições impostas pelos poços já perfurados estavam gradativamente diminuindo a liberdade em se obter ganhos por meio da otimização.

Ciclo 5

No quinto ciclo os poços perfurados foram o Injetor 5 e o Produtor 5 e observa-se na Figura 4.37 que os poços restantes apresentaram mais uma vez poucas alterações. As mais significativas foram a do Produtor 10 que se afastou do NA2 (possivelmente buscando uma região menos drenada) e o Produtor 1 que passou a ficar entre o Produtor 5 e Produtor 2. Nesta otimização ocorreu um total de 21 trocas de melhor indivíduo e ao final do processo o valor da média do VPL do conjunto aumentou em 3,6%.

Ciclo 6

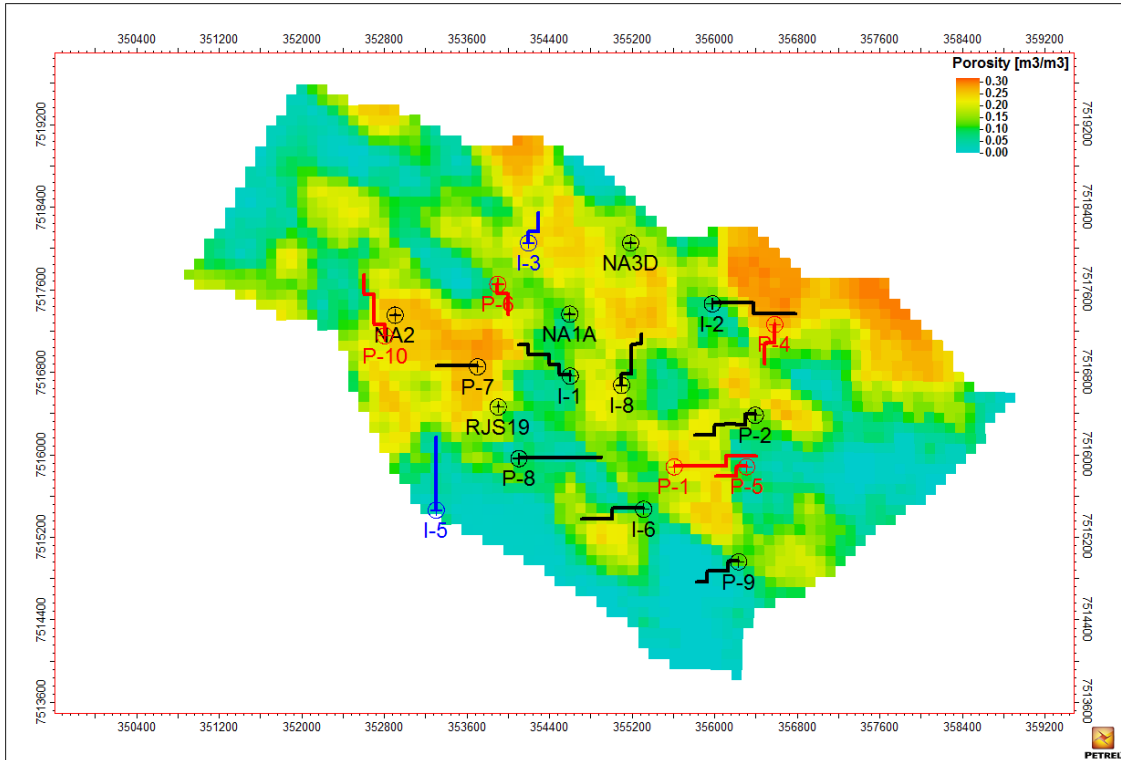
No sexto ciclo foram perfurados os poços Produtor 1 e Produtor 10. É interessante notar a importância da otimização ter sido capaz de diminuir o número de poços. Neste ciclo, inicialmente, haviam ainda 3 poços a serem perfurados. Ainda que o Produtor 6 tenha aumentado de comprimento, boa parte do ganho em VPL foi relacionada a supressão do Produtor 4 que já não apresentava uma boa curva de produção e, portanto, não justificava a sua perfuração.

Ciclo 7

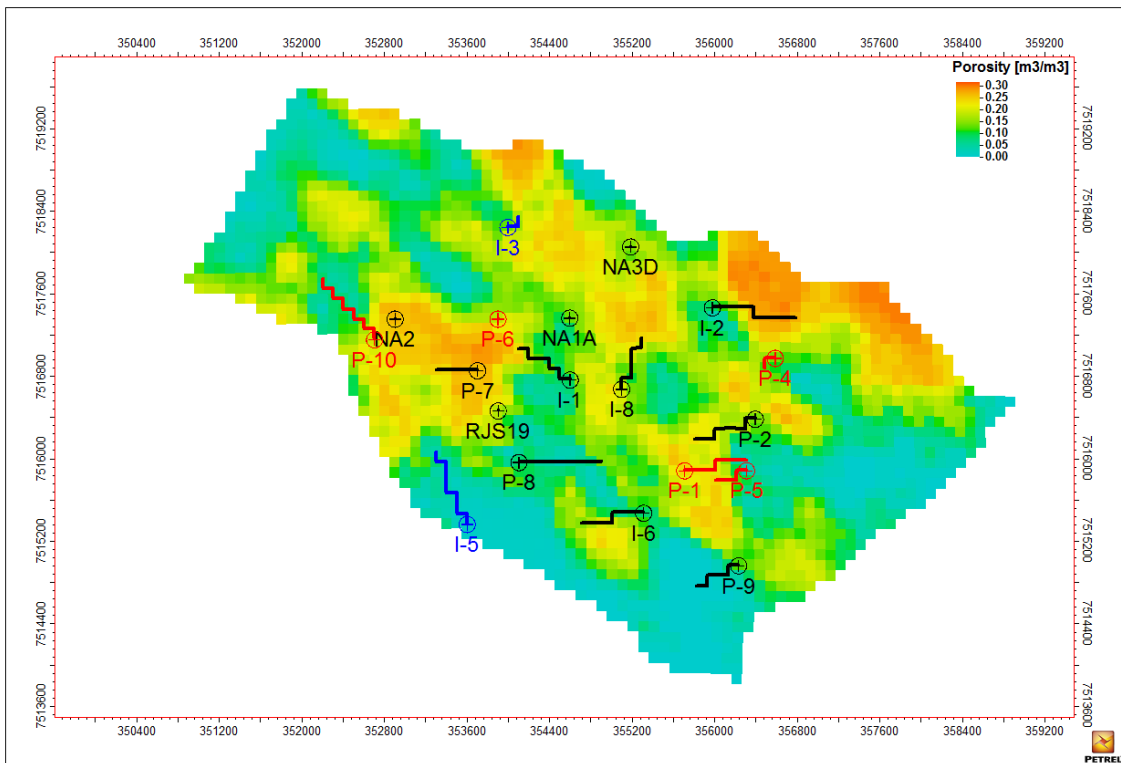
No Ciclo 7 foram perfurados os dois últimos poços, o Produtor 6 e o Injetor 3. O plano de desenvolvimento estava completo e não restou nenhum poço para ter sua localização otimizada.

Evolução da Otimização do Plano de Desenvolvimento

Pode-se analisar a evolução da otimização do plano de desenvolvimento observando, além da localização dos poços, a quantidade de produtores e injetores existentes. Inicialmente partiu-se com uma malha de drenagem composta por 13 produtores e 8 injetores, totalizando 21 poços. Isso foi mantido até o Ciclo 2 quando houve a redução de 1 injetor. Finalmente, no último ciclo, foi retirado mais um poço produtor de maneira que a malha de drenagem final ficou composta por 12 produtores e 6 injetores, totalizando 18 poços. Verifica-se que a evolução da malha de drenagem demonstrou que o plano inicial contava com um excesso de poços e que a solução de poços verticais não era adequada para o problema. Os ganhos consistentes obtidos ao longo da otimização evidenciam que o método proposto foi capaz de atender satisfatoriamente o problema.

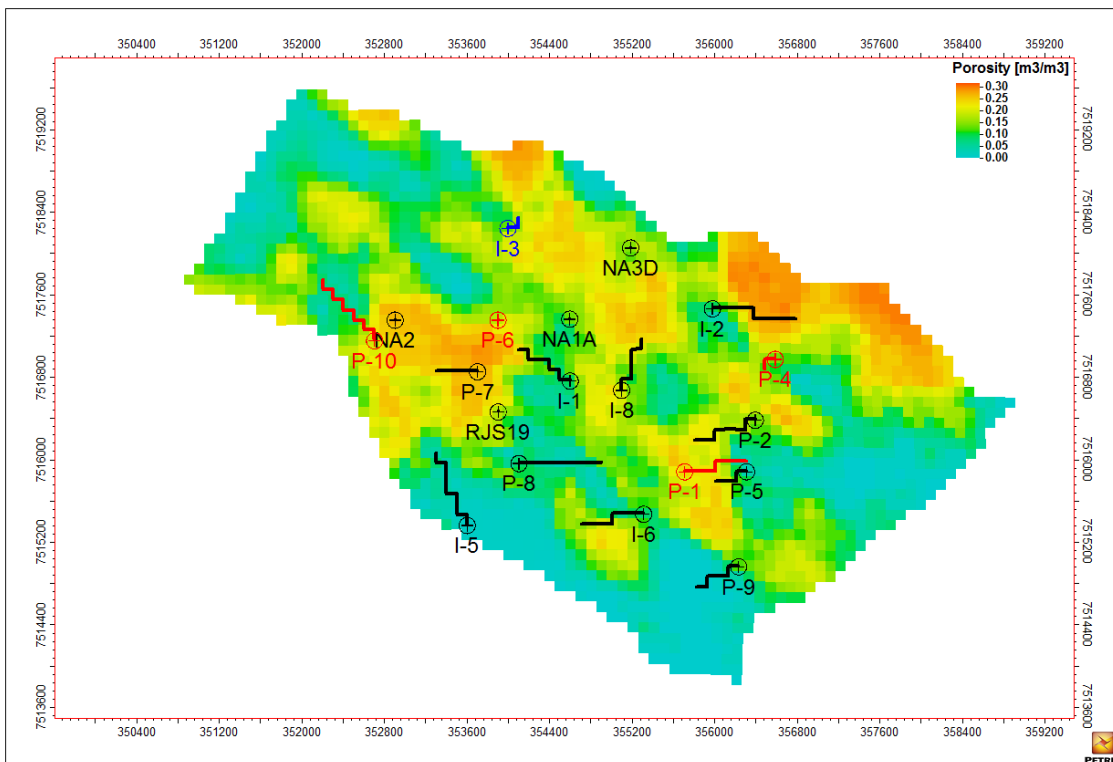


(a) Plano de desenvolvimento do Ciclo 4 antes da otimização.

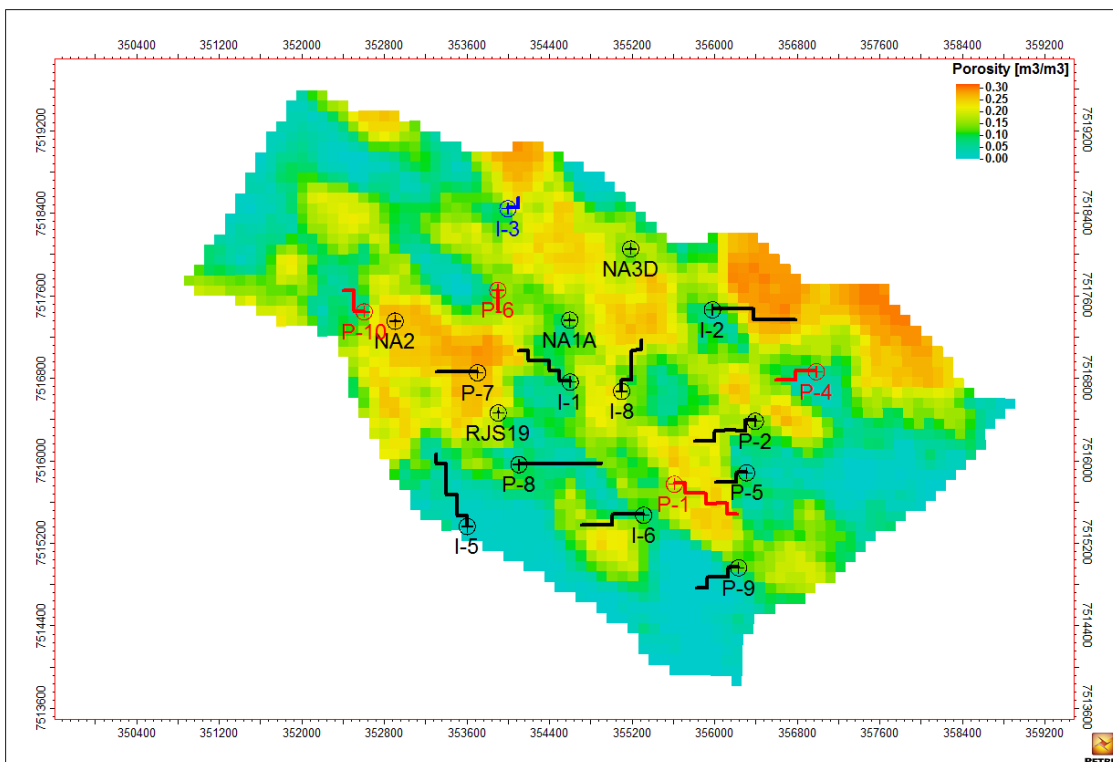


(b) Plano de desenvolvimento do Ciclo 4 depois da otimização.

Figura 4.36: Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 4. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.

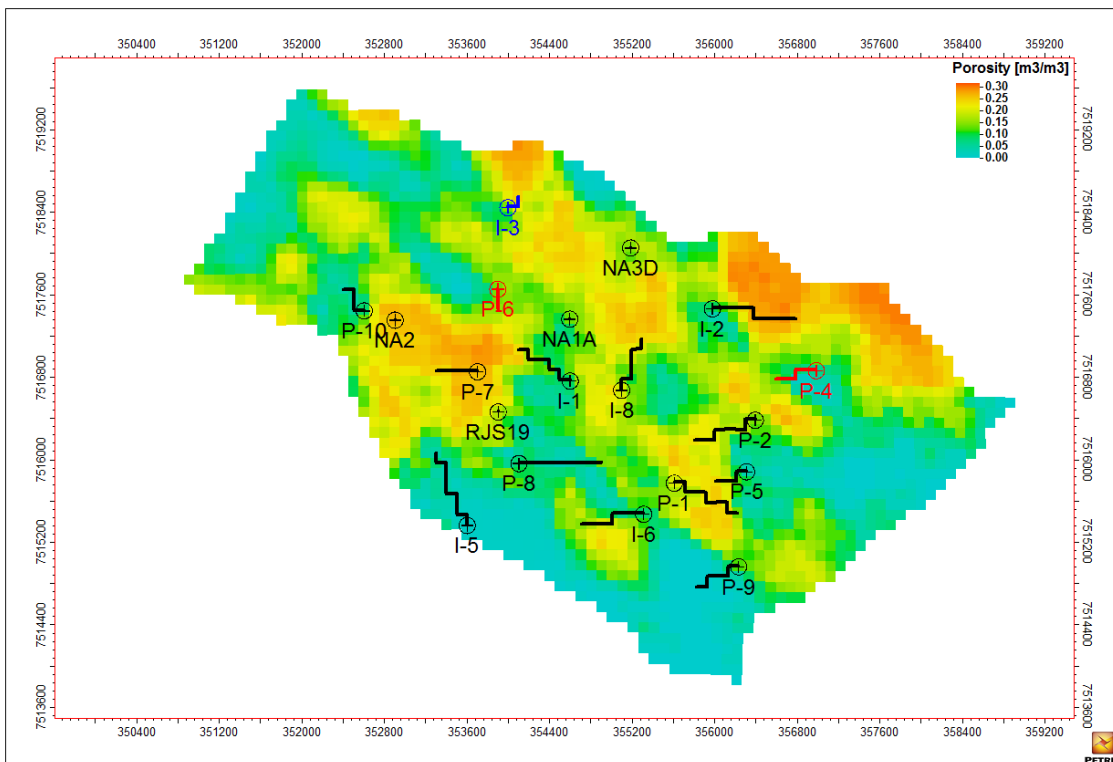


(a) Plano de desenvolvimento do Ciclo 5 antes da otimização.

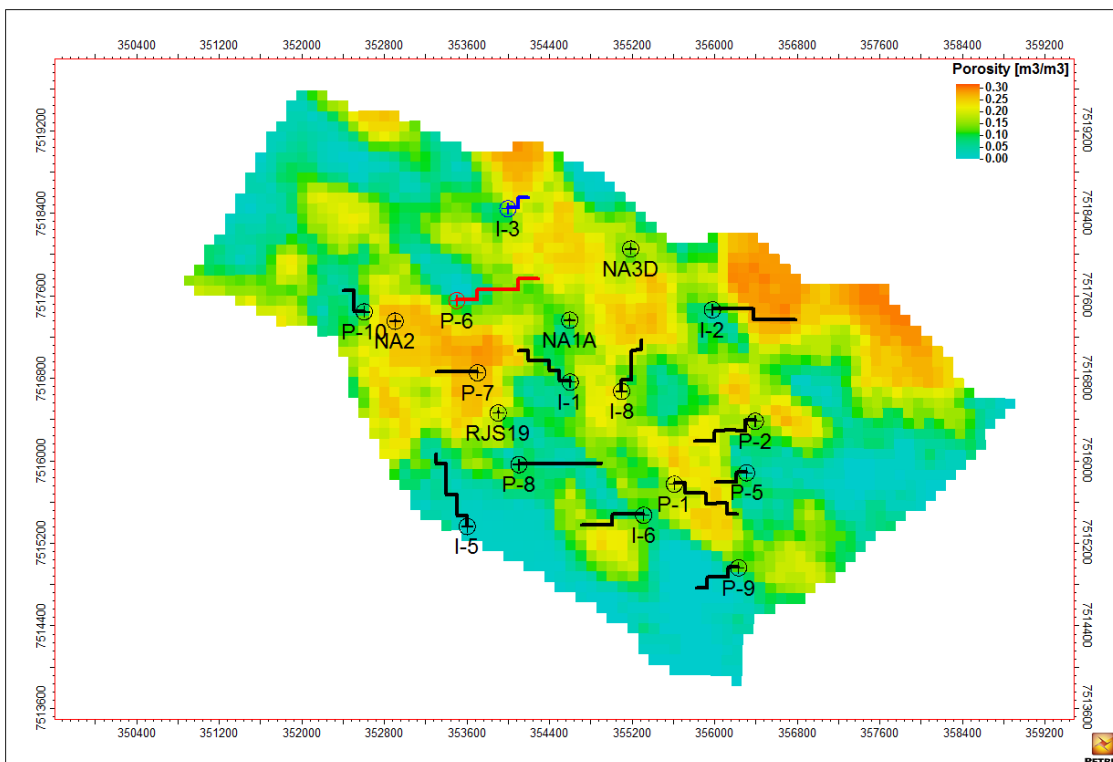


(b) Plano de desenvolvimento do Ciclo 5 depois da otimização.

Figura 4.37: Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 5. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.



(a) Plano de desenvolvimento do Ciclo 6 antes da otimização.



(b) Plano de desenvolvimento do Ciclo 6 depois da otimização.

Figura 4.38: Alteração do plano de desenvolvimento devido à otimização durante o Ciclo 6. Poços já perfurados: em preto. Poços a serem perfurados: em vermelho produtores e em azul injetores.

Tabela 4.4: Número de poços durante cada ciclo.

Ciclo	Poços Antes da Otimização			Poços Depois da Otimização		
	Produtores	Injetores	Total	Produtores	Injetores	Total
0	13	8	21	13	8	21
1	13	8	21	13	8	21
2	13	8	21	13	7	20
3	13	7	20	13	6	19
4	13	6	19	13	6	19
5	13	6	19	13	6	19
6	13	6	19	12	6	18
7	13	6	19	12	6	18

4.4 Desenvolvimento de Campo em Malha Fechada

Foi aplicada a otimização em malha fechada do desenvolvimento de campos de petróleo sob incertezas geológicas, DCMF, seguindo a metodologia apresentada na Seção 3. Conforme dito anteriormente, o objeto de estudo foi o campo UNISIM-I para o qual se possuía um conjunto de modelos incertos (UNISIM-I-D) e o modelo de referência UNISIM-I-R.

Uma primeira análise pode ser feita a respeito do DCMF ser capaz ou não de aumentar a média do VPL do conjunto conforme novos ciclos de aquisição de informações e otimização iam sendo realizados. A Tabela 4.5 sumariza a variação do VPL antes e depois da otimização para cada um dos 7 Ciclos realizados.

Tabela 4.5: Valores da média do VPL para os 500 modelos em cada ciclo, antes e depois da otimização.

Ciclo	VPL Antes (Milhões de \$)	VPL Depois (Milhões de \$)	Variação
0	946,38	1388,00	46,6%
1	1403,90	1509,30	7,5%
2	1384,72	1491,96	7,7%
3	1483,32	1653,71	11,5%
4	1653,67	1722,31	4,2%
5	1723,75	1785,10	3,6%
6	1718,74	1822,34	6,0%

Convém ressaltar que, apesar do plano de desenvolvimento após a otimização do Ciclo n ser o mesmo do plano pré-otimização do Ciclo $n + 1$, seus VPLs foram diferentes. Isso era esperado, já que entre os ciclos os modelos passaram pela etapa de ajuste de histórico, tendo alteradas a suas propriedades e, conseqüentemente, seus dados de produção. Ao final da perfuração de todos os poços, o ganho em aplicar a metodologia foi de 92,5% se for considerada a malha de drenagem sem otimização do

ciclo zero, ou então de 31,3% se for levada em conta a primeira otimização. A Figura 4.39 traz os mesmos resultados de forma gráfica. Naturalmente, o Ciclo Zero trouxe um ganho bem superior devido ao fato da semente inicial ter sido proposta manualmente. Ainda que nos ciclos seguintes os ganhos tenham sido menores, o DCMF foi capaz de aumentar a média do VPL do conjunto de uma maneira consistente, mesmo partindo de planos de drenagem previamente otimizados.




Figura 4.39: Evolução da média do VPL para o conjunto de 500 modelos.

Outro resultado obtido foi o melhor varrido do reservatório. Ao observar a Figura 4.40, nota-se que a média do fator de recuperação passou de um valor inicial 37,8% para 46,4%. Ainda que se considerasse que um projeto não seria executado apenas com uma otimização manual, o ganho ainda foi expressivo: de 42,6% após a otimização do Ciclo Zero para os mesmos 46,4% ao final do plano de desenvolvimento constituindo um delta de 3,8%. A evolução da produção acumulada de óleo e de água pode ser consultada no Apêndice C.

Esses resultados comprovam que o DCMF foi capaz de sistematicamente melhorar o resultado esperado do projeto por meio do aumento do VPL além de incrementar o fator de recuperação do campo. Ainda que o objetivo deste trabalho fosse comparar os resultados quando aplicados ao modelo de referência, é importante ressaltar que tal situação jamais existirá em um caso de aplicação real. O reservatório nunca será completamente conhecido e suas respostas somente serão obtidas se o projeto for executado. Dessa forma, todas as decisões são baseadas nas respostas oriundas do conjunto de modelos incertos. Assim, uma metodologia que seja capaz de entregar um aumento de VPL de 31,3% no conjunto de modelos que são a base da tomada de decisão é, sem dúvida, promissora. Feita essa ressalva, pode-se passar à análise do que se obtém quando os planos de desenvolvimento otimizados foram aplicados ao modelo de referência.




Figura 4.40: Evolução da média do fator de recuperação para o conjunto de 500 modelos.

Uma das formas de visualização dos dados de uma distribuição consiste no diagrama de caixa, ou *boxplot*. Neste trabalho, foi adotada a convenção dada pela Figura 4.41. A base da caixa, ou P25, representa o quartil inferior; a linha central, ou P50, a mediana; o topo da caixa, ou P75, o quartil superior. Acima e abaixo tem-se os valores mínimos e máximo da distribuição. Adicionalmente foi incluído o valor da média do conjunto e o valor da propriedade analisada no modelo de referência.




Figura 4.41: Descrição dos elementos do *boxplot* para as propriedades apresentadas no estudo.

A Figura 4.42 traz a evolução do VPL ao longo dos ciclos e suas mudanças decorrentes da aplicação do DCMF. O primeiro ponto destacado consiste em comparar o VPL do modelo de referência do Ciclo Zero com o do Ciclo 6. O VPL




Figura 4.42: Boxplot do VPL ao longo dos ciclos.

passou de \$1.112,4 para \$1.566,0 Milhões, constituindo um aumento de 29,0%. Isso evidencia a vantagem da utilização da metodologia: caso ela não fosse adotada, a malha de drenagem executada seria a proposta no Ciclo Zero. Em adição, pode-se notar o efeito dos dois fatores atuantes no desempenho do VPL. Por um lado tem-se a flexibilidade do plano de desenvolvimento. Nos primeiros ciclos, como ainda existiam muitos poços a serem perfurados, ela foi alta e com o passar do tempo foi diminuindo. Por outro lado, a informação sobre o reservatório começou pequena e foi aumentando a medida que novos dados de produção e perfil se tornavam disponíveis. O balanço desses dois fatores foi mudando ao longo dos ciclos. Nos Ciclos Zero a 2, a falta de informação foi preponderante de maneira que mesmo com uma maior flexibilidade na locação dos poços, o VPL do modelo de referência aumentou pouco. No Ciclo 3 teve-se a melhor condição: informações suficientes e liberdade para alterar a malha de drenagem de maneira significativa. Assim, teve-se um salto em comparação com o Ciclo 2. Entre os Ciclos 4 a 6, ainda que se tivesse um maior volume de dados, as alterações que podiam ser feitas nos poços já não produziram tantos ganhos. Isso ainda foi potencializado pelo efeito do tempo no VPL de maneira que as receitas oriundas dos poços perfurados ao final da campanha tiveram um impacto menor. A tabela com os valores de VPL do modelo de referência pode ser consultada no Apêndice C. Quanto à distribuição do conjunto de modelos, pode-se notar que em todos os ciclos o modelo de referência se situou dentro da faixa de incerteza representada pelo *boxplot* mostrando que essa variabilidade foi capturada. Faz-se, entretanto, a ressalva de que não foi observada uma redução significativa da faixa de incerteza. Finalmente, pode-se atentar ao fato de que ao longo do DCMF a média do conjunto de modelos sistematicamente previu valores de VPL superiores aos realizados no modelo de referência. Uma possível causa consiste no viés otimista

(os 4 poços iniciais foram perfurados em boas regiões do reservatório) existente no conjunto de modelos iniciais e que persistiu mesmo com a incorporação dos dados. Mas mesmo que esse viés não existisse, dado que a escolha dos PDs foi realizada em cada ciclo levando em uma otimização do VME, era de se esperar que o VPL do modelo de referência fosse, na média, pior do que as estimativas feitas com os modelos incertos. Isso acontece pois segundo SMITH e WINKLER (2006), ao se basear a tomada de decisão em escolhas de maior valor esperado tem-se, na média, uma decepção, ou seja, valores realizados mais baixos. Os autores denominam esse fenômeno de *optimizer's curse* ou em uma tradução livre, maldição do otimizador. Outro ponto relevando ao analisar a Figura 4.42 é que a previsibilidade do VPL não foi melhorada com a utilização do DCMF. Ainda que esta fosse desejável, pode-se entender que neste estudo as melhores escolhas possíveis em relação ao plano de desenvolvimento são tomadas já que a alteração da malha de drenagem levou a maiores VPLs.

A diferença entre os valores de VPL obtidos pelo conjunto e o valor do modelo de referência pode ser melhor analisada por meio da Figura 4.43. No eixo das abscissas tem-se o valor da média do conjunto, o eixo das ordenadas expressa o valor do UNISIM-I-R e cada um dos ciclos é identificado. Pelo fato dos ciclos estarem todos abaixo da linha de 45 graus entende-se que neste estudo todas as previsões de VPL se mostraram otimistas quando comparadas com o resultado real. Entretanto, é possível observar que mesmo assim existe uma correlação entre os ganhos obtidos no conjunto e os obtidos no modelo de referência. A existência dessa correlação é importante por ir de encontro aos resultados de MOROSOV (2016) que não obteve tal tipo de comportamento em seus estudos. Em adição, observa-se tanto na Figura 4.42 quanto na Figura 4.43 que o Ciclo 3 foi um divisor de comportamento. Apesar de seu ajuste de histórico já ter sido detalhado na Seção 4.1 assim como a otimização do plano de desenvolvimento na Seção 4.3 persistiu a questão de qual foi o fator preponderante. O mais provável é que nesse ciclo o conjunto de todos esses parâmetros possibilitou um ponto ótimo para a obtenção de maiores VPLs.

Sabendo que o DCMF trouxe ganhos, uma questão que naturalmente surge diz respeito à sua magnitude. Na Figura 4.44 tem-se o VPL máximo que seria possível obter em uma otimização determinística do modelo de referência em comparação com o resultado obtido por meio do DCMF. A linha horizontal representa o plano de desenvolvimento resultante da otimização do UNISIM-I-R. Isso foi feito conforme apresentado na Seção 3.3 e levando em conta o elevado número de indivíduos e de gerações utilizados no Algoritmo Genético, podendo-se considerar que o valor obtido era o maior VPL possível para esse reservatório. Os pontos em amarelo, consistem nos mesmos pontos da Figura 4.42, ou seja, os planos de desenvolvimento resultantes do DCMF quando aplicados ao modelo de referência. Fica patente que apesar de




Figura 4.43: Comparação entre o VPL do conjunto e o VPL do modelo de referência.

ainda existir espaço para ganhos, a aplicação do DCMF traz o VPL muito mais próximo do máximo possível. A diferença caiu de \$593,1 Milhões no Ciclo Zero para \$139,1 Milhões no Ciclo 6, o que representou uma redução de 67,4%.




Figura 4.44: Comparação entre o resultado do VPL do plano de desenvolvimento obtido com o DCMF e a otimização determinística, ambos aplicados no modelo de referência.

Para a produção acumulada de óleo, os resultados obtidos são apresentados na Figura 4.45. Neste caso, além de ser capaz de aumentar o valor de óleo produzido, as previsões se tornaram mais precisas com o passar dos ciclos. A diferença entre a média do conjunto e o modelo de referência foi menor ao comparar o Ciclo 6 com o Ciclo Zero.




Figura 4.45: Boxplot do Np ao longo dos ciclos.

Um comportamento diferente foi obtido para o VOIP, fato que pode ser visto na Figura 4.46. Ocorreu uma diminuição da variabilidade, sobretudo a partir do Ciclo 3, entretanto, isso não aconteceu da forma desejada. Em outras palavras, o VOIP do modelo de referência passou a ficar fora da faixa do *boxplot*. Uma das possíveis explicações se refere aos ajustes na porosidade, necessários para honrar os dados de perfil e de produção que foram obtidos. Outro fator e talvez o mais determinante refere-se ao contato óleo-água. Nesse ciclo foi perfurado o poço Produtor 2 de forma que a incerteza que existia em relação a esse parâmetro foi resolvida. Com isso, ao invés de se trabalhar com valores de contato entre 3.024 e 3.324 m, todos os modelos passaram a utilizar o valor de 3.174 m. Em adição, é importante ressaltar que diferentemente MOROSOV (2016), neste trabalho não se considerou a incerteza associada a existência do bloco leste. Com isso a redução da incerteza associada ao VOIP não apresentou a mesma redução no primeiro ciclo observada naquele trabalho.

É interessante notar ainda que apesar dos modelos iniciais serem pessimistas em relação ao VOIP quando comparados com o modelo de referência, ao analisar o comportamento do reservatório em fluxo se tem o comportamento contrário, ou seja, o conjunto de modelos é otimista tanto em relação a produção acumulada de óleo quanto ao VPL.

No Apêndice C podem ser consultados os *boxplots* para o fator de recuperação e produção acumulada de água.




Figura 4.46: Boxplot do VOIP ao longo dos ciclos.

4.5 Custo Computacional

Para a obtenção dos dados deste trabalho foram utilizados os recursos computacionais elencados na Seção 3.5. Na média, cada ciclo demandou um total 8.492 simulações de fluxo. Um detalhamento do número de simulações por etapa pode ser visto na Tabela 4.6. As colunas se referem ao ciclo em questão, ao ajuste de histórico, à previsão da produção antes da otimização, à otimização do plano de desenvolvimento, à previsão da produção depois da otimização e à simulação do modelo de referência, UNISIM-I-D. Os dois valores na coluna do ajuste de histórico referem-se ao número de simulações e ao número de simulações equivalentes. Uma simulação completa realiza seus cálculos até o final da concessão (30 anos). Nessa etapa, somente foi simulado o período considerado, desde o início do campo (31/5/13) até o ciclo em questão. Dessa forma, o número de simulações equivalentes consistiu nas 2.500 simulações ponderadas multiplicando-se pela fração de tempo da concessão que foi simulado.

Já o tempo de simulação gasto em cada ciclo foi, na média, de 48,9 horas. A divisão por etapas encontra-se na Tabela 4.7. Ressalta-se que as horas indicadas referem-se tão somente àquelas gastas na simulação, não incluindo outras tarefas como montagem dos modelos e preparação dos arquivos.

A quebra em percentual das médias da Tabela 4.7 pode ser vista na Figura 4.47. A etapa mais onerosa computacionalmente foi, sem dúvida, a da otimização do plano de drenagem. Por trabalhar com o algoritmo genético, demandou um elevado número de simulações para obter um resultado satisfatório.

A utilização de um *cluster* de computadores no qual fosse possível a submissão de simulações em paralelo se mostrou indispensável para a realização deste traba-

Tabela 4.6: Número de simulações realizadas em cada etapa, por ciclo.

Ciclo	Aj. Histórico	Extrap. Pré	Otim. PD	Extrap. Pós	UNISIM-I-R	Total Ciclo
0	2500/333	500	5250	500	2	8752
1	2500/375	500	4890	500	1	8391
2	2500/417	500	4935	500	1	8436
3	2500/458	500	4655	500	1	8156
4	2500/500	500	4775	500	1	8276
5	2500/542	500	5250	500	1	8751
6	2500/583	500	5180	500	1	8681
Total Estudo						59.443

Tabela 4.7: Tempo (em horas) para execução das simulações de fluxo em cada etapa, por ciclo.

Ciclo	Aj. Histórico	Extrap. Pré	Otim. Pd	Extrap. Pós	UNISIM-I-R	Total Ciclo
0	9,0	1,1	22,3	1,0	12,1	45,5
1	10,0	0,9	24,0	1,0	12,1	48,0
2	10,5	1,1	22,1	1,0	12,3	46,9
3	11,0	0,8	23,0	1,1	12,4	48,2
4	16,0	0,8	21,1	1,0	11,7	50,6
5	10,0	0,8	24,0	1,5	10,4	46,8
6	21,4	0,8	23,3	0,8	10,1	56,3
Total DCMF						342,3




Figura 4.47: Divisão da média de tempos gastos em cada uma das etapas do DCMF.

lho. Entretanto, convém mencionar que ainda que o DCMF demandasse muitas simulações e estivesse atrelado a um elevado tempo de simulação, em uma aplicação prática da metodologia teria como benefício a maior disponibilidade de tempo para a sua realização. Cada ciclo teria duração de vários meses e seria equivalente ao tempo realmente gasto na perfuração dos poços. Em adição, a etapa da simulação do modelo de referência seria suprimida já que os resultados seriam obtidos diretamente da resposta do reservatório. Pode-se afirmar que a metodologia pode ser replicada em casos reais e que o tempo necessário para o estudo, ainda que elevado, não impõe uma restrição à sua aplicabilidade.

A otimização do plano de desenvolvimento do modelo de referência utilizou um total de 41.173 simulações de fluxo ao longo de 259,5 horas. A Tabela 4.8 consolida a quantidade de simulações realizadas.

Tabela 4.8: Consolidação do tempo e número de simulações realizadas no estudo.

Etapa	Tempo (horas)	Número de Simulações
DCMF	342,3	59.433
Otimização Determinística	259,5	41.173
Estudo	601,8	100.606

Capítulo 5

Conclusões

Neste capítulo são apresentadas as conclusões referentes ao trabalho de otimização em malha fechada do desenvolvimento de campos de petróleo sob incertezas geológicas. Em adição, são feitas sugestões de temas e caminhos para trabalhos futuros.

5.1 Conclusões do Trabalho

O objetivo desta dissertação foi avaliar os ganhos, em termos de VPL, de se realizar atualizações do plano de desenvolvimento de um campo de petróleo à medida que novas informações eram disponibilizadas pela perfuração e produção dos poços. O processo cíclico foi aplicado ao UNISIM-I, utilizando a metodologia da otimização em malha fechada do desenvolvimento de campos de petróleo sob incertezas geológicas. Para sua aplicação, foi necessário optar por um conjunto específico de soluções para cada uma das etapas.

Em relação ao ajuste de histórico, convém ressaltar que, ao contrário de resultados obtidos no GRMF (SILVA (2016)), a incorporação de dados de produção não foi capaz de remover o viés otimista do conjunto de modelos incertos. Devido ao curto período de histórico do DCMF, a principal contribuição na etapa do ajuste de histórico vem dos perfis dos poços perfurados. Ainda assim, o ES-MDA se mostrou capaz de condicionar os modelos aos novos dados de perfil e de produção obtidos ao longo do desenvolvimento do campo. Atuando nos parâmetros incertos, foi capaz de obter, em cada ciclo, 500 modelos que honrassem os dados disponíveis até o momento. Com todo o conjunto ajustado, foi necessário selecionar um subconjunto de modelos representativos de maneira a diminuir o tempo gasto na etapa da otimização. Nesse sentido, o método empregado para fazer a seleção também se mostrou adequado de forma que os 5 modelos selecionados em cada ciclo representaram bem as respostas do conjunto.

O algoritmo genético utilizado na otimização do plano de desenvolvimento foi

eficiente pois foi capaz de aumentar sistematicamente o VPL do conjunto de modelos incertos. Além da locação propriamente dita, a possibilidade de alterar o tipo de poço bem como a não perfuração de poços se mostrou fundamental para a obtenção dessa melhora contínua.

O DCMF como um todo se mostrou uma boa forma de tomar as melhores decisões possíveis frente às informações existentes em um determinado momento. Como em uma caso prático não existe o modelo de referência para comparações, essas decisões são realizadas com base no conjunto de modelos incertos. A utilização do DCMF trouxe um ganho na média do VPL do conjunto de 31,3% ao final dos ciclos quando comparado com o Ciclo Zero. Além disso, foi capaz de manter o VPL de referência entre o mínimo e o máximo do conjunto, ainda que não se tenha observado uma diminuição significativa da incerteza.

A metodologia do DCMF trouxe ganhos quando o plano de desenvolvimento resultante de sua aplicação foi utilizado no modelo de referência. Isso equivale a dizer que se obteve uma correlação entre os ganhos obtidos no conjunto de modelos incertos e o UNISIM-I-R. Ao final dos ciclos, houve um aumento de 29,0% em relação ao que seria obtido com o plano de desenvolvimento do Ciclo Zero. Esse resultado difere dos resultados obtidos por MOROSOV (2016) no qual não se observou uma correlação entre os ganhos obtidos nos modelos incertos e o modelo de referência, evidenciando a importância das escolhas soluções específicas para cada uma das etapas do DCMF. Dessa forma, pode-se concluir que as técnicas específicas utilizadas neste trabalho se mostraram efetivas. O custo computacional associado, apesar de significativo, pode ser minimizado com a utilização de *clusters* de computadores.

Durante o DCMF, foi possível notar que existe um balanço entre dois fatores principais: a quantidade de informação disponível e a flexibilidade em alterar o restante do plano de desenvolvimento. Inicialmente, apesar de ter flexibilidade, não havia informação suficiente. Ao final, a informação existia mas os poços já haviam sido perfurados. Por isso, o ponto em que se obteve maiores ganhos foi em um ciclo intermediário que equilibrava esses dois fatores.

A otimização determinística realizada no UNISIM-I-R traçou um valor limite para o VPL do campo (no caso em que o reservatório fosse conhecido). Com esse dado, foi possível observar que o DCMF melhorou significativamente o VPL do projeto ao longo dos ciclos ficando, ao final do processo, muito mais próximo desse máximo teórico.

5.2 Sugestões para Trabalhos Futuros

Existem diversos caminhos que podem ser seguidos para dar prosseguimento ao estudo do tema de DCMF. As propostas aqui apresentadas surgiram da observação

dos resultados e das discussões realizadas durante o período de pesquisa e constituem oportunidades a serem exploradas em trabalhos vindouros.

Em relação ao ajuste de histórico, um ponto de análise consiste na inclusão de diferenças de topo e base do reservatório no conjunto de modelos. No presente trabalho uma premissa adotada foi a suposição de um modelo estrutural conhecido e trabalhou-se com as incertezas relacionadas às propriedades. Entretanto, sabe-se que incertezas relacionadas ao topo e à base do reservatório existem, sobretudo nas fases iniciais dos projetos. Essa inclusão obviamente apresenta inúmeros obstáculos a serem solucionados, mas traria o benefício de incorporar uma situação que é recorrente no desenvolvimento de campos de petróleo. Uma extensão dessa ideia seria o uso de cenários geológicos no qual todo o estrutural (e não somente o topo e a base) poderia diferir.

Para a seleção de cenários, formas alternativas do cálculo de similaridade dos modelos podem ser implementados. Este trabalho utilizou a distância Euclidiana de diversos parâmetros na construção da matriz de distâncias. Poderia ser utilizado alguma das opções apresentadas na Seção 2.3 e analisar o impacto no resultado final. Uma outra abordagem, possivelmente até mais interessante, seria a de eliminar a etapa de seleção de modelos representativos. Atualmente, sabe-se que isso ainda é necessário devido ao custo computacional, mas pode-se chegar à situação em que todos os modelos ajustados participem diretamente da etapa da otimização.

Quanto à otimização do plano de desenvolvimento, um ponto que merece destaque é a otimização do cronograma de perfuração e entrada de poços. O estudo desenvolvido utilizou como métrica a alternância de injetores e produtores em conjunto com o valor do VPL para decidir qual o próximo poço a ser perfurado. Entretanto, esse mesmo problema pode ser abordado buscando maximizar uma função objetivo ou então maximizar a informação obtida. Isso se torna particularmente interessante tendo em vista que, neste trabalho, a informação trazida nos primeiros ciclos não resultou em um aumento significativo de VPL no modelo de referência. Poderia ter-se optado pela perfuração de poços que, mesmo que tivessem uma produção menor, trouxessem mais informação em um momento em que ainda havia flexibilidade para alterar o plano de desenvolvimento de maneira significativa. Outro ponto diz respeito à adoção de uma função objetivo que considere não somente características econômicas, mas também outras respostas do reservatório. É o equivalente a trabalhar com uma otimização de uma função multiobjetivo.

Ao pensar no DCMF como um todo, um ponto interessante de estudo consistiria em como quantificar os ganhos referentes a sua utilização sem possuir o modelo de referência. Nessa situação busca-se mostrar aos tomadores de decisão que a aplicação do DCMF é preferível em detrimento a um desenvolvimento em que somente se planeje e se execute o PD inicialmente proposto. Entretanto, esse convencimento

deve ser feito a priori, sem o conhecimento do campo real. O DCMF também poderia ser aplicado em casos com geologia mais complexa, tais como os carbonatos do pré-sal brasileiro. O grupo UNISIM da Unicamp possui um *benchmark* de carbonatos, o UNISIM-II, disponível em <http://www.unisim.cepetro.unicamp.br/benchmarks/br/unisim-ii/overview>. Finalmente, seria interessante um trabalho que pudesse realizar a implementação em um campo real. Ainda que não fossem feitos todos os ciclos ou que se optasse por um maior número de poços por ciclo, os resultados obtidos conduziriam uma melhor compreensão das dificuldades associadas a uma implementação prática.

Referências Bibliográficas

- AANONSEN, S. I., NÆVDAL, G., OLIVER, D. S., et al., 2009, “Review of Ensemble Kalman Filter in Petroleum Engineering”, v. 14, n. 3, pp. 393–412. doi: 10.2118/117274-PA. Disponível em: <<http://dx.doi.org/10.2118/117274-PA>>.
- ARMSTRONG, M., NDIAYE, A., RAZANATSIMBA, R., et al., 2012, “Scenario Reduction Applied to Geostatistical Simulations”, *Mathematical Geosciences*, v. 45, n. 2, pp. 165–182. ISSN: 1874-8953. doi: 10.1007/s11004-012-9420-7. Disponível em: <<http://dx.doi.org/10.1007/s11004-012-9420-7>>.
- AVANSI, G. D., SCHIOZER, D. J., 2015, “UNISIM-I: Synthetic Model for Reservoir Development and Management Applications”, *International Journal of Modeling and Simulation for the Petroleum Industry*, v. 9, n. 1 (April), pp. 21–30. Disponível em: <<http://www.ijmspi.org/ojs/index.php/ijmspi/article/view/152>>.
- BITTENCOURT, A. C., HORNE, R. N., 1997, “Reservoir Development and Design Optimization”, *1997 SPE Annual Technical Conference and Exhibition*, v. SPE 38895. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.34.2982>>.
- BUENO, J. F., DRUMMOND, R. D., VIDAL, A. C., et al., 2011, “Constraining uncertainty in volumetric estimation: A case study from Namorado Field, Brazil”, *Journal of Petroleum Science and Engineering*, v. 77, n. 2, pp. 200–208. ISSN: 0920-4105. Disponível em: <<http://dx.doi.org/10.1016/j.petrol.2011.03.003>>.
- COELLO, C. A. C., LAMONT, G. B., VELDHUIZEN, D. A. V., 2006, *Evolutionary Algorithms for Solving Multi-Objective Problems (Genetic and Evolutionary Computation)*. Secaucus, NJ, USA, Springer-Verlag New York, Inc. ISBN: 0387332545. Disponível em: <<http://www.springer.com/us/book/9780387332543>>.

- COX, T. F., COX, M. A. A., 2000, “Multidimensional Scaling”. In: *Multidimensional Scaling*, cap. 3, pp. 316 – 320, Chapman and Hall. Disponível em: <<https://www.crcpress.com/Multidimensional-Scaling-Second-Edition/Cox-Cox/p/book/9781584880943>>.
- DUPACOVA, J., GROWE-KUSKA, N., ROMISCH, W., 2003, “Scenario reduction in stochastic programming: an approach using probability metrics”, *Math Program*, v. Ser A, n. 95, pp. 493–511. Disponível em: <<http://www.mathematik.hu-berlin.de/~romisch/papers/DGR03-MP.pdf>>.
- EMERICK, A. A., 2016, “Estimating uncertainty bounds in field production using ensemble-based methods”, *Journal of Petroleum Science and Engineering*, v. 145, pp. 648 – 656. ISSN: 0920-4105. doi: <http://dx.doi.org/10.1016/j.petrol.2016.06.037>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0920410516302558>>.
- EMERICK, A. A., REYNOLDS, A. C., 2013, “Ensemble Smoother with Multiple Data Assimilation”, *Computers & Geosciences*, v. 55, pp. 3–15. doi: [10.1016/j.cageo.2012.03.011](http://dx.doi.org/10.1016/j.cageo.2012.03.011). Disponível em: <<http://dx.doi.org/10.1016/j.cageo.2012.03.011>>.
- EMERICK, A. A., SILVA, E., MESSER, B., et al., 2009, “Well Placement Optimization Using a Genetic Algorithm With Nonlinear Constraints”, v. SPE-118808-MS. Disponível em: <<http://dx.doi.org/10.2118/118808-MS>>.
- EVENSEN, G., 1994, “Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics”, *Journal of Geophysical Research: Oceans*, v. 99, n. C5, pp. 10143–10162. ISSN: 2156-2202. doi: [10.1029/94JC00572](http://dx.doi.org/10.1029/94JC00572). Disponível em: <<http://dx.doi.org/10.1029/94JC00572>>.
- FLORIS, F. J. T., BUSH, M. D., CUYPERS, M., et al., 2001, “Methods for quantifying the uncertainty of production forecasts: a comparative study”, *Petroleum Geoscience*, v. 7, n. S, pp. S87–S96. doi: [10.1144/petgeo.7.S.S87](http://dx.doi.org/10.1144/petgeo.7.S.S87). Disponível em: <<http://pg.lyellcollection.org/content/7/S/S87.abstract>>.
- GUARDADO, L. R., SPADINI, A. R., BRANDAO, J. S. L., et al., 2000, “Petroleum System of the Campos Basin, Brazil”. In: *Petroleum Systems of South Atlantic Margins: An Outgrowth of the AAPG/ABGP Hedberg Research Symposium, Rio de Janeiro, Brazil, November 16-19, 1997*, cap. 22,

pp. 317 – 324, American Association of Petroleum Geologists and PETROBRAS. Disponível em: <<http://archives.datapages.com/data/specpubs/memoir73/m73ch22/m73ch22.htm>>.

HEITSCH, HOLGER AND RÖMISCH, W., 2003, “Scenario Reduction Algorithms in Stochastic Programming”, *Computational Optimization and Applications*, v. 24, n. 2, pp. 187–206. ISSN: 1573-2894. doi: 10.1023/A:1021805924152. Disponível em: <<http://dx.doi.org/10.1023/A:1021805924152>>.

HOLLAND, J. H., 1975, *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence*. Cambridge, MA, USA, MIT Press. ISBN: 0262082136. Disponível em: <<https://mitpress.mit.edu/books/adaptation-natural-and-artificial-systems>>.

ISEBOR, O. J., DURLOFSKY, L. J., ECHEVERRÍA CIAURRI, D., 2014, “A derivative-free methodology with local and global search for the constrained joint optimization of well locations and controls”, *Computational Geosciences*, v. 18, n. 3, pp. 463–482. ISSN: 1573-1499. doi: 10.1007/s10596-013-9383-x. Disponível em: <<http://dx.doi.org/10.1007/s10596-013-9383-x>>.

JANSEN, J. D., DOUMA, S. D., BROUWER, R., et al., 2009, “Closed-Loop Reservoir Management”. In: *Proceedings of the SPE Reservoir Simulation Symposium, The Woodlands, Texas, 2–4 February*, n. SPE 119098. doi: 10.2118/119098-MS. Disponível em: <<http://dx.doi.org/10.2118/119098-MS>>.

KALMAN, R. E., 1960, “A new approach to linear filtering and prediction problems”, *Transactions of the ASME, Journal of Basic Engineering*, v. 82, pp. 35–45. doi: 10.1115/1.3662552. Disponível em: <<http://dx.doi.org/10.1115/1.3662552>>.

MEIRA, L. A., COELHO, G. P., SANTOS, A. A. S., et al., 2016, “Selection of Representative Models for Decision Analysis Under Uncertainty”, *Computers & Geosciences*, v. 88, pp. 67 – 82. ISSN: 0098-3004. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0098300415300893>>.

MICHALEWICZ, Z., NAZHIYATH, G., 1995, “Genocop III: a co-evolutionary algorithm for numerical optimization problems with nonlinear constraints”.

In: *Evolutionary Computation, 1995., IEEE International Conference on*, v. 2, pp. 647–651 vol.2, Nov. Disponível em: <<http://dx.doi.org/10.1109/ICEC.1995.487460>>.

MORALES, A. N., NASRABADI, H., ZHU, D., 2005, “A New Modified Genetic Algorithm for Well Placement Optimization under Geological Uncertainties”, v. SPE-143617-MS. Disponível em: <<http://dx.doi.org/10.2118/143617-MS>>.

MOROSOV, A. L., 2016, *Evolução do Risco Durante o Desenvolvimento de Campos de Petróleo*. Tese de M.Sc., UNICAMP - Universidade Estadual de Campinas, Campinas, Brasil.

MOROSOV, A. L., SCHIOZER, D. J., 2016, “Field Development Process Revealing Uncertainty Assessment Pitfalls”, *Society of Petroleum Engineer*, SPE-180094-MS. Disponível em: <<http://dx.doi.org/10.2118/180094-MS>>.

NÆVDAL, G., MANNSETH, T., VEFRING, E. H., 2002, “Near-Well Reservoir Monitoring Through Ensemble Kalman Filter”. In: *Proceedings of the SPE/DOE Improved Oil Recovery Symposium, 13–17 April*, n. SPE 75235. doi: 10.2118/75235-MS. Disponível em: <<http://dx.doi.org/10.2118/75235-MS>>.

OGATA, K., 2011, *Engenharia de Controle Moderno*. 4 ed. São Paulo - BR, Pearson. Disponível em: <<http://loja.pearson.com.br/engenharia-de-controle-moderno-9788576058106/p>>.

OLIVER, D. S., HE, N., REYNOLDS, A. C., 1996, “Conditioning Permeability Fields to Pressure Data”, *5th European Conference on the Mathematics of Oil Recovery*. Disponível em: <<http://dx.doi.org/10.3997/2214-4609.201406884>>.

OLIVER, D. S., CHEN, Y., 2010, “Recent progress on reservoir history matching: a review”, v. 15, n. 1, pp. 185–221. Disponível em: <<http://dx.doi.org/10.1007/s10596-010-9194-2>>.

OLIVER, D. S., REYNOLDS, A. C., BI, Z., et al., 2001, “Integration of production data into reservoir models”, *Petroleum Geoscience*, v. 7, n. S, pp. S65–S73. Disponível em: <<http://pg.lyellcollection.org/content/7/S/S65.abstract>>.

- OLIVER, D. S., REYNOLDS, A. C., LIU, N., 2008, *Inverse Theory for Petroleum Reservoir Characterization and History Matching*. Cambridge, UK, Cambridge University Press. doi: 10.1017/CBO9780511535642. Disponível em: <<http://dx.doi.org/10.1017/CBO9780511535642>>.
- OZDOGAN, U., SAHNI, A., YETEN, B., et al., 2005, “Efficient Assessment and Optimization of a Deepwater Asset Development Using Fixed Pattern Approach”, *2005 SPE Annual Technical Conference and Exhibition*, v. SPE 95792. Disponível em: <<http://dx.doi.org/10.2118/95792-MS>>.
- PETERS, L., ARTS, R., BROUWER, G., et al., 2010a, “Results of the Brugge Benchmark Study for Flooding Optimization and History Matching”, *SPE Reservoir Evaluation and Engineering*, (jun.), pp. 391–405. Disponível em: <<https://www.onepetro.org/journal-paper/SPE-119094-PA>>.
- PETERS, L., ARTS, R., BROUWER, G., et al., 2010b, “Results of the Brugge Benchmark Study for Flooding Optimisation and History Matching”, v. 13, n. 3, pp. 391–405. doi: 10.2118/119094-PA. Disponível em: <<http://dx.doi.org/10.2118/119094-PA>>.
- PETTAN, C., STROMSVIK, J. F., 2013, “The Peregrino Challenge: How to Keep Reliable Models While Drilling Eight Wells per Year”, *Offshore Technology Conference*, , n. OTC-24522-MS. Disponível em: <<http://dx.doi.org/10.4043/24522-MS>>.
- SCHEIDT, C., CAERS, J., 2008, “Representing Spatial Uncertainty Using Distances and Kernels”, *Mathematical Geosciences*, v. 41, n. 4, pp. 397–419. ISSN: 1874-8953. doi: 10.1007/s11004-008-9186-0. Disponível em: <<http://dx.doi.org/10.1007/s11004-008-9186-0>>.
- SCHEIDT, C., CAERS, J., 2009, “Uncertainty Quantification in Reservoir Performance Using Distances and Kernel Methods—Application to a West Africa Deepwater Turbidite Reservoir”, v. 14, n. 4, pp. 680–692. doi: 10.2118/118740-PA. Disponível em: <<http://dx.doi.org/10.2118/118740-PA>>.
- SCHIOZER, D., LIGERO, E., SUSLICK, S., et al., 2004, “Use of representative models in the integration of risk analysis and production strategy definition”, *Journal of Petroleum Science and Engineering*, v. 44, n. 1–2, pp. 131 – 141. Disponível em: <<http://dx.doi.org/10.1016/j.petrol.2004.02.010>>. Risk Analysis Applied to Petroleum Exploration and Production.

- SHIRANGI, M. G., DURLOFSKY, L. J., 2015, “Closed-Loop Field Development Under Uncertainty by Use of Optimization With Sample Validation”, v. Preprint. doi: 10.2118/173219-PA. Disponível em: <<http://dx.doi.org/10.2118/173219-PA>>.
- SHYR, W.-J., 2010, *Parameters Determination for Optimum Design by Evolutionary Algorithm*. Convergence and Hybrid Information Technologies, Marius Crisan (Ed.), InTech. ISBN: 978-953-307-068-1. Disponível em: <<https://doi.org/10.5772/9638>>.
- SILVA, V. L. S., 2016, *Ajuste de Histórico e Otimização da Produção de Petróleo sob Incertezas - Aplicação do Gerenciamento de Reservatórios em Malha Fechada*. Tese de M.Sc., COPPE/UFRJ - Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil.
- SKJERVHEIM, J.-A., EVENSEN, G., AANONSEN, S. I., et al., 2007, “Incorporating 4D seismic data in reservoir simulation models using ensemble Kalman filter”, , n. SPE 95789. Disponível em: <<http://dx.doi.org/10.2118/95789-PA>>.
- SKJERVHEIM, J.-A., EVENSEN, G., HOVE, J., et al., 2011, “An Ensemble Smoother for Assisted History Matching”. In: *Proceedings of the SPE Reservoir Simulation Symposium, The Woodlands, Texas, USA, 21–23 February*, n. SPE 141929. doi: 10.2118/141929-MS. Disponível em: <<http://dx.doi.org/10.2118/141929-MS>>.
- SMITH, J. E., WINKLER, R. L., 2006, “The Optimizer’s Curse: Skepticism and Postdecision Surprise in Decision Analysis”, *Management Science*, v. 52, n. 3, pp. 311–322. doi: 10.1287/mnsc.1050.0451. Disponível em: <<http://dx.doi.org/10.1287/mnsc.1050.0451>>.
- STEAGALL, D., SCHIOZER, D., 2001, “Uncertainty Analysis In Reservoir Production Forecasts During Appraisal And Pilot Production Phases”. In: *Proceedings of the SPE/DOE Improved Oil Recovery Symposium, 11–14 February*, n. SPE 66399. Disponível em: <<http://dx.doi.org/10.2118/66399-MS>>.
- SUZUKI, S., CAERS, J., 2008, “A Distance-based Prior Model Parameterization for Constraining Solutions of Spatial Inverse Problems”, *Mathematical Geosciences*, v. 40, n. 4, pp. 445–469. ISSN: 1874-8953. doi: 10.1007/s11004-008-9154-8. Disponível em: <<http://dx.doi.org/10.1007/s11004-008-9154-8>>.

Apêndice A

Resultados da Etapa de Ajuste de Histórico

A.1 Ajuste de histórico dos dados de produção do Ciclo 3

Produtor 2




Figura A.1: Resultado do ajuste de histórico no poço Produtor 2. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Pressão de fundo: (a) modelos iniciais, (b) modelos ajustados.

NA3D

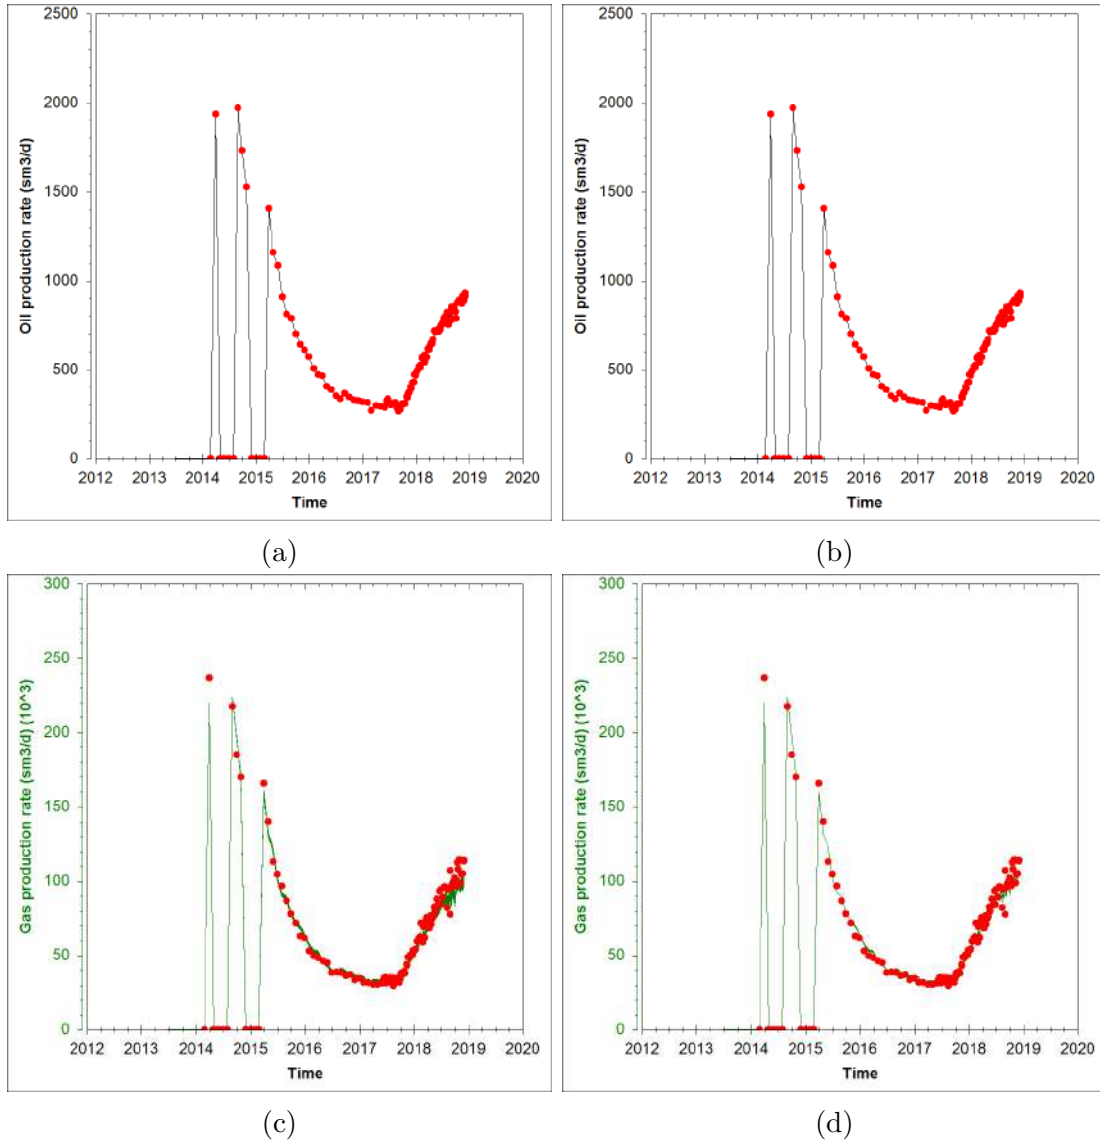


Figura A.2: Resultado do ajuste de histórico no poço NA3D. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.

NA3D

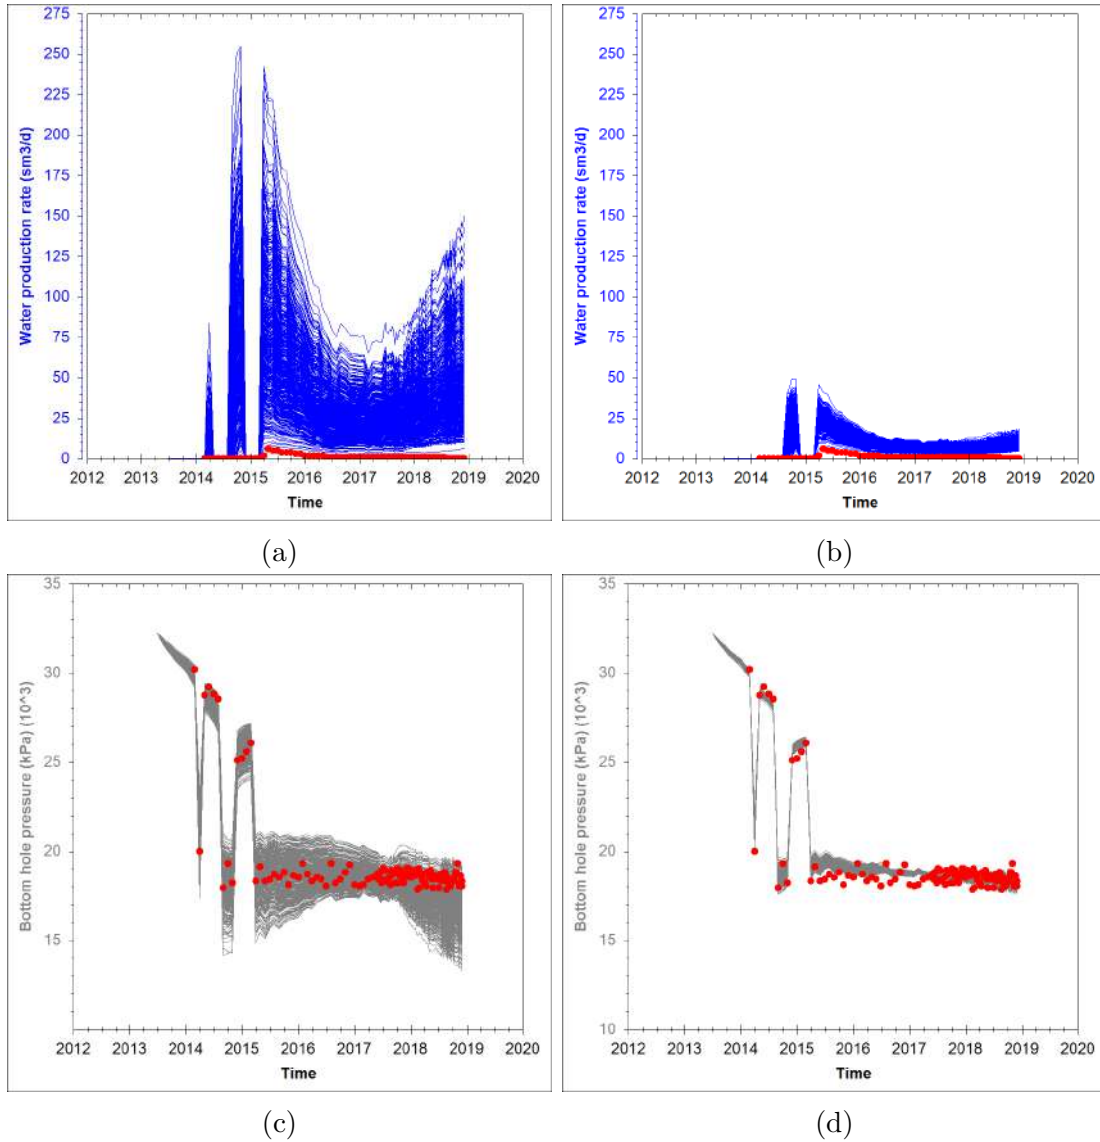


Figura A.3: Resultado do ajuste de histórico no poço NA3D. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

NA1A

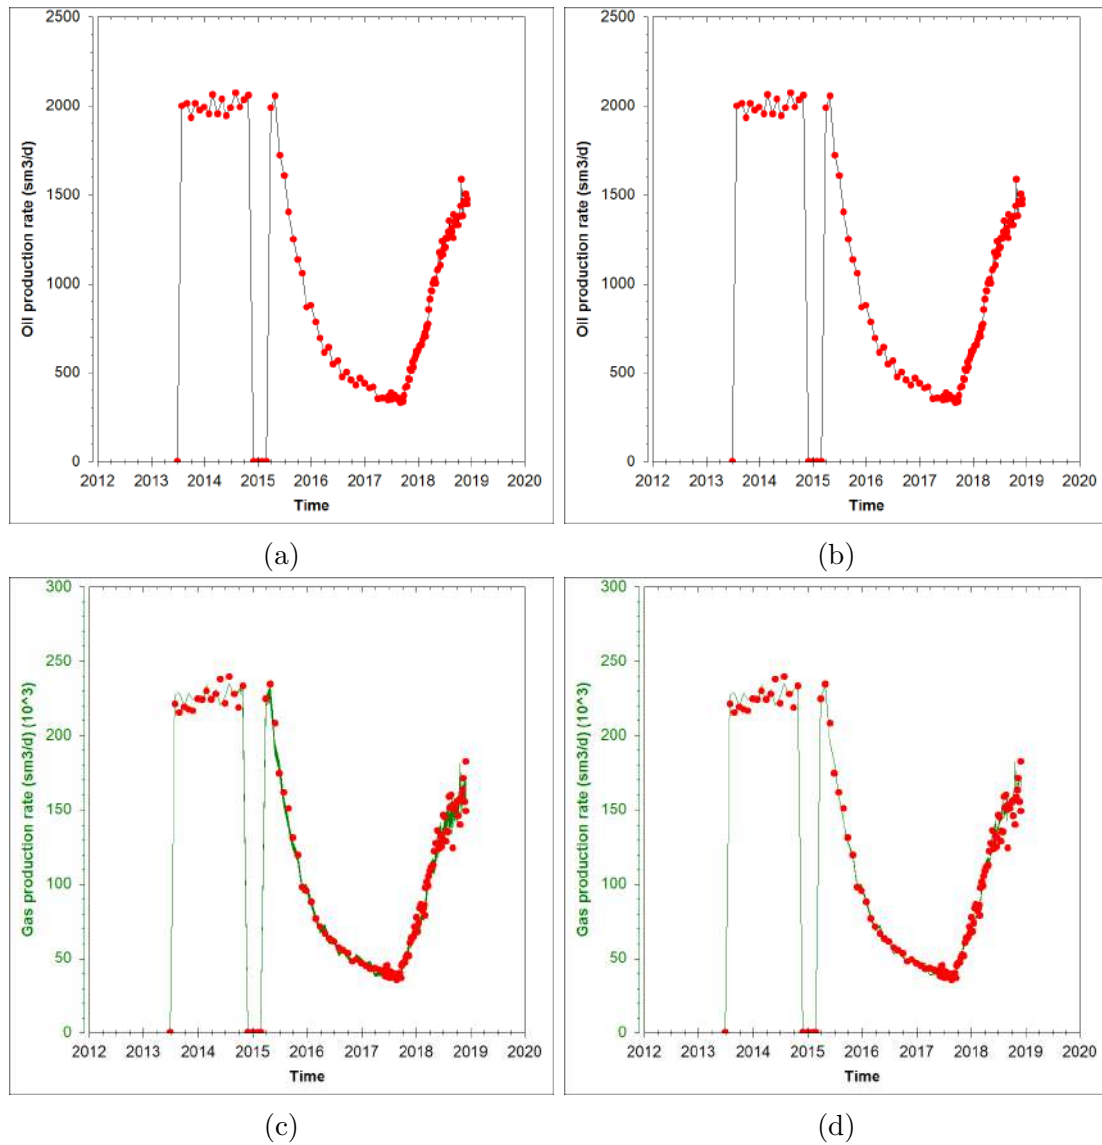


Figura A.4: Resultado do ajuste de histórico no poço NA1A. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.

NA1A

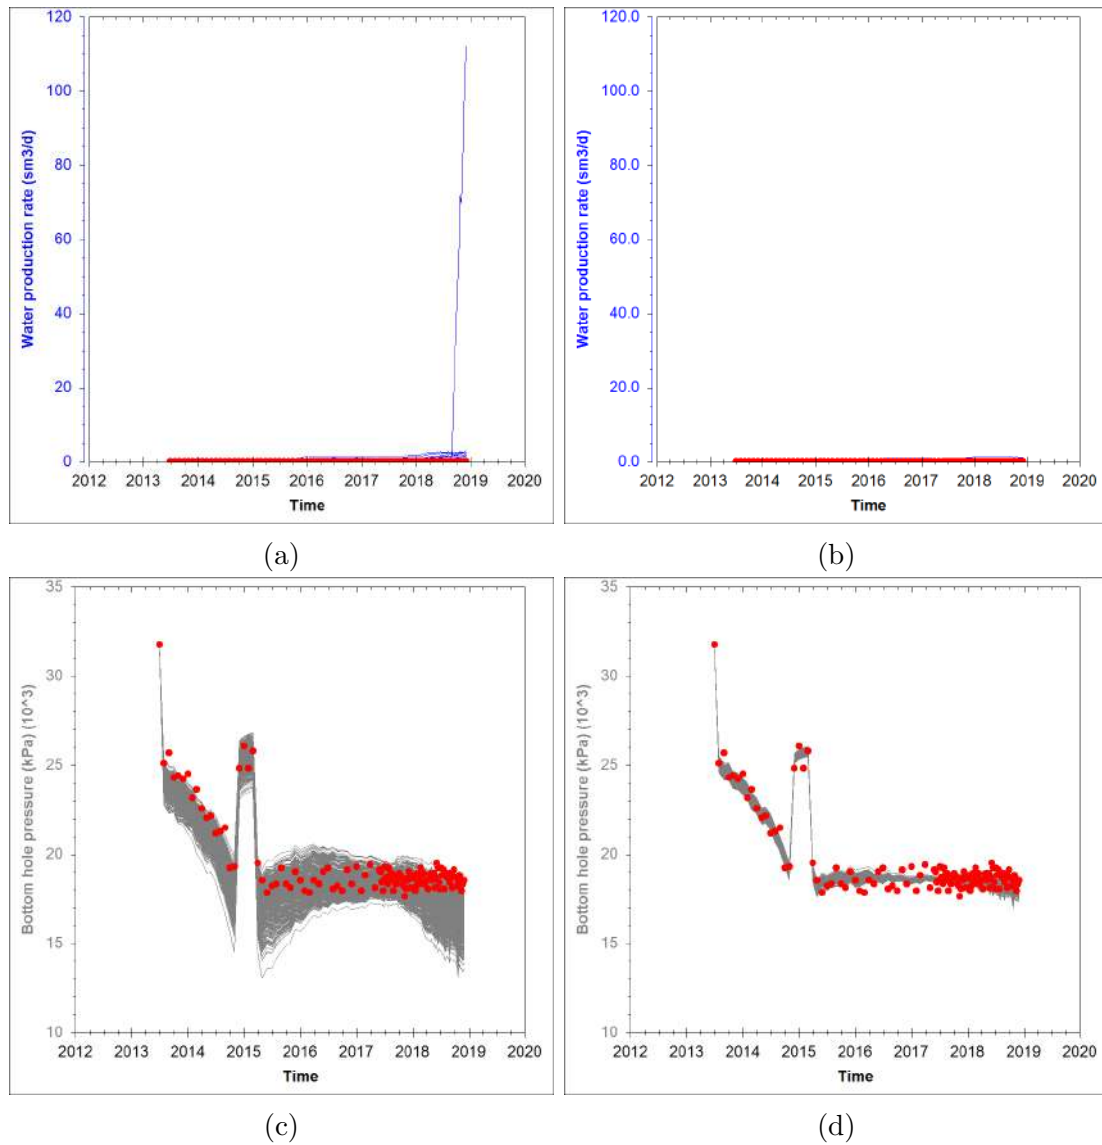


Figura A.5: Resultado do ajuste de histórico no poço NA1A. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

RJS19

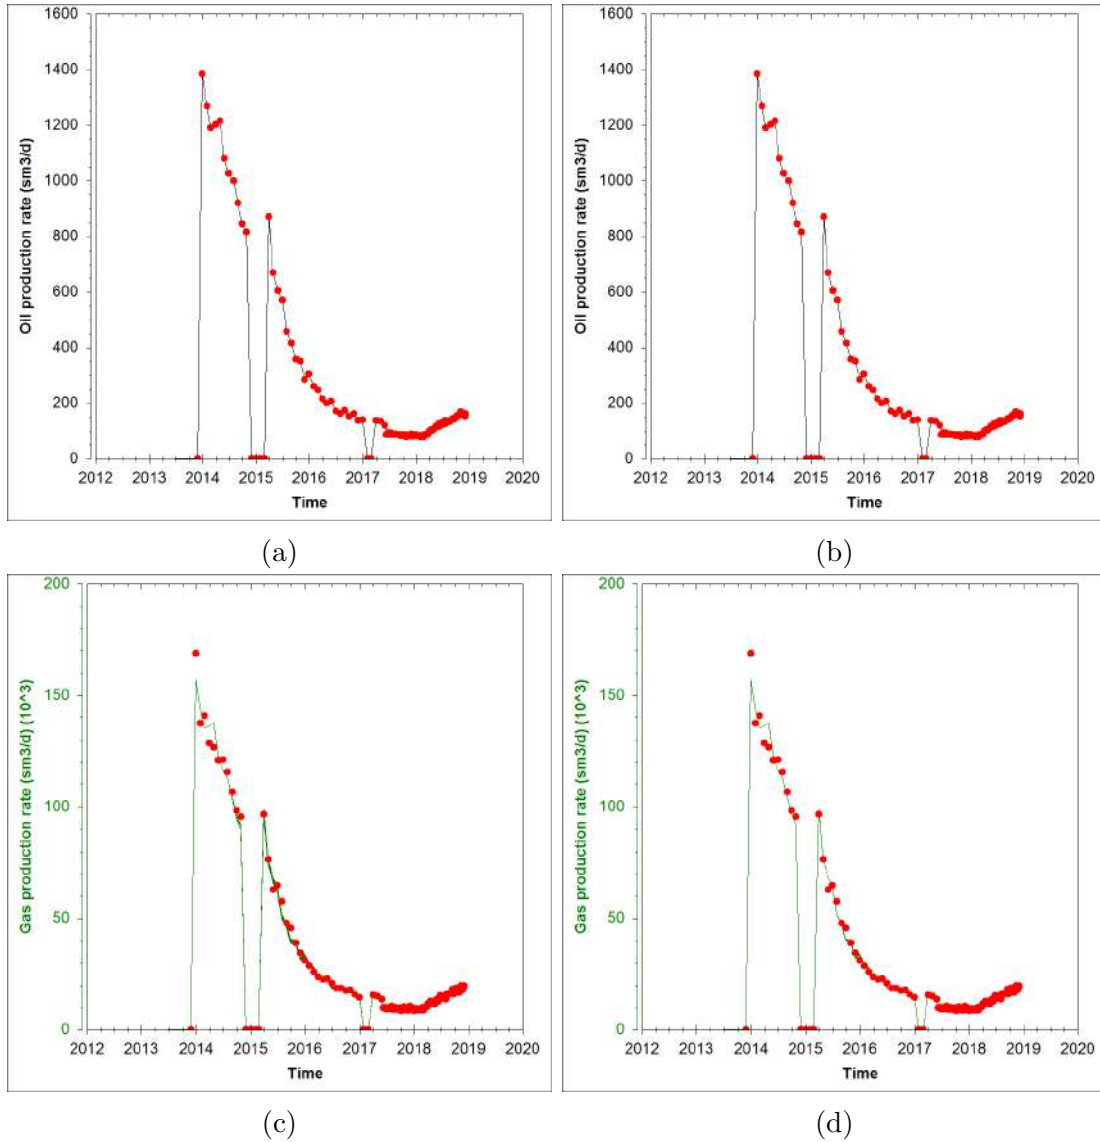


Figura A.6: Resultado do ajuste de histórico no poço RJS19. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.

RJS19

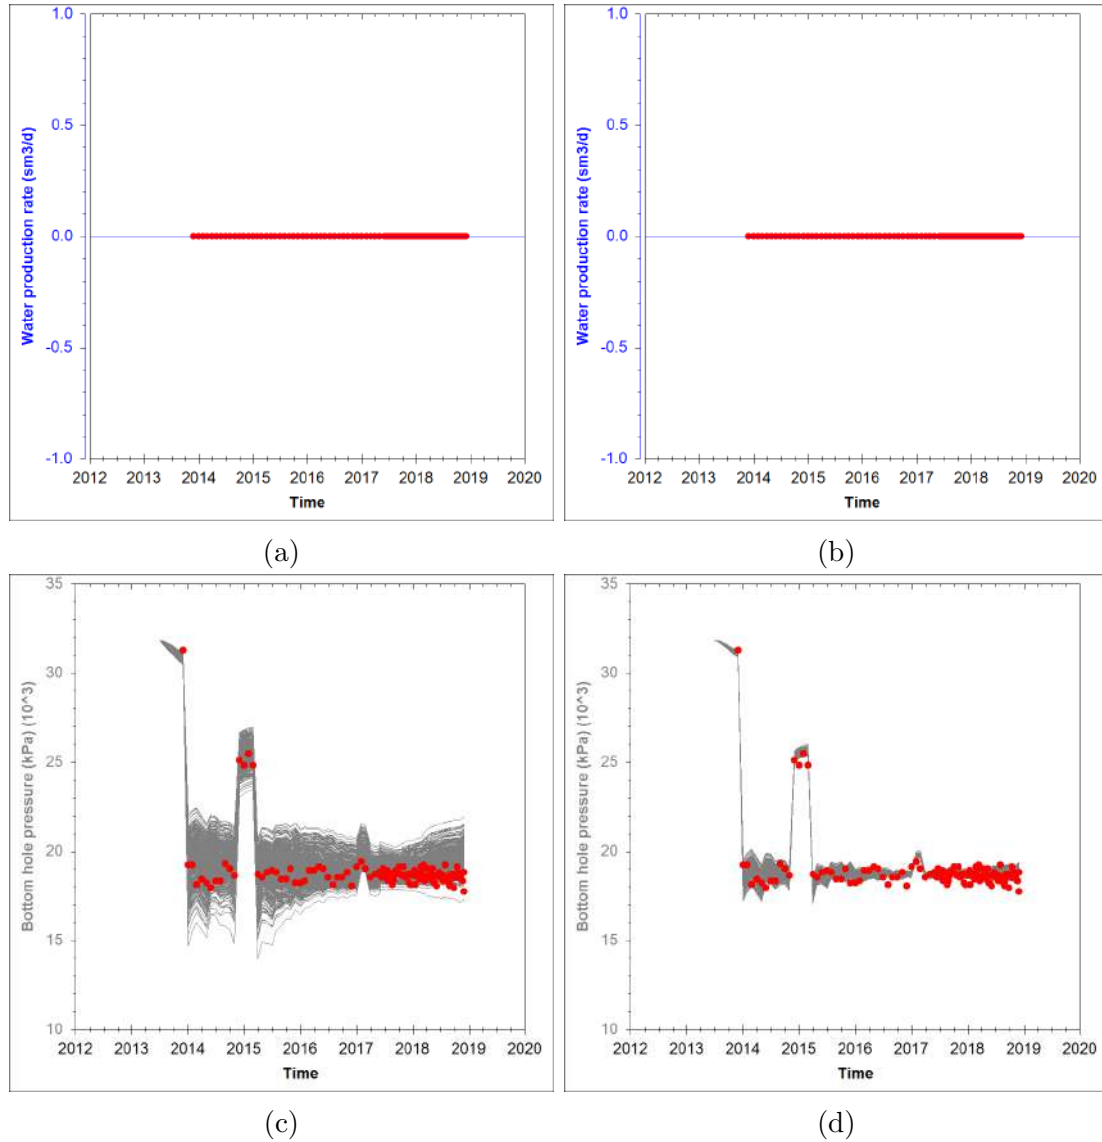


Figura A.7: Resultado do ajuste de histórico no poço RJS19. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

Produtor 9

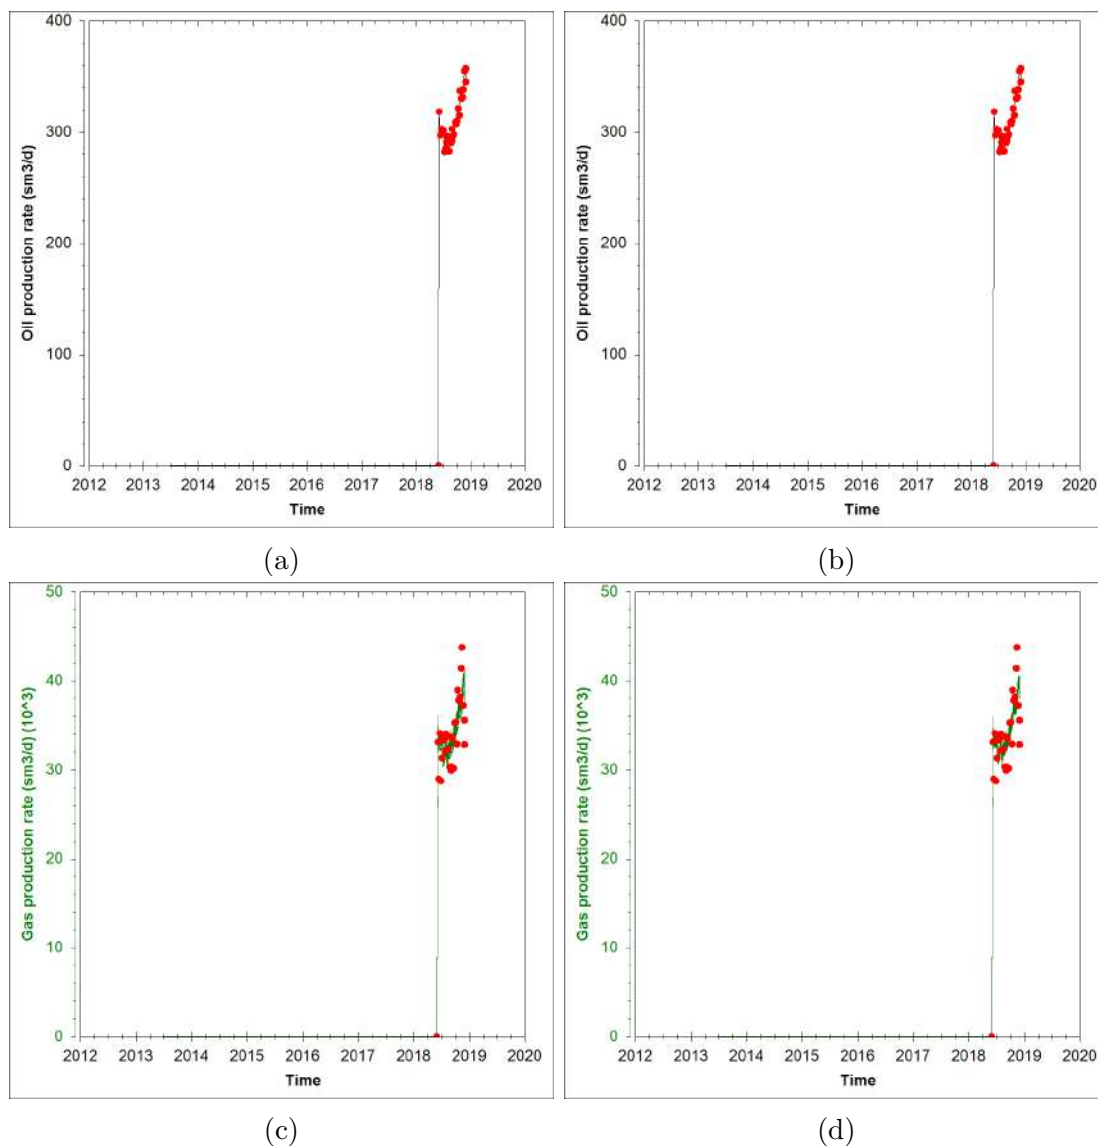


Figura A.8: Resultado do ajuste de histórico no poço P9. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de óleo: (a) modelos iniciais, (b) modelos ajustados. Vazão de gás: (c) modelos iniciais, (d) modelos ajustados.

Produtor 9

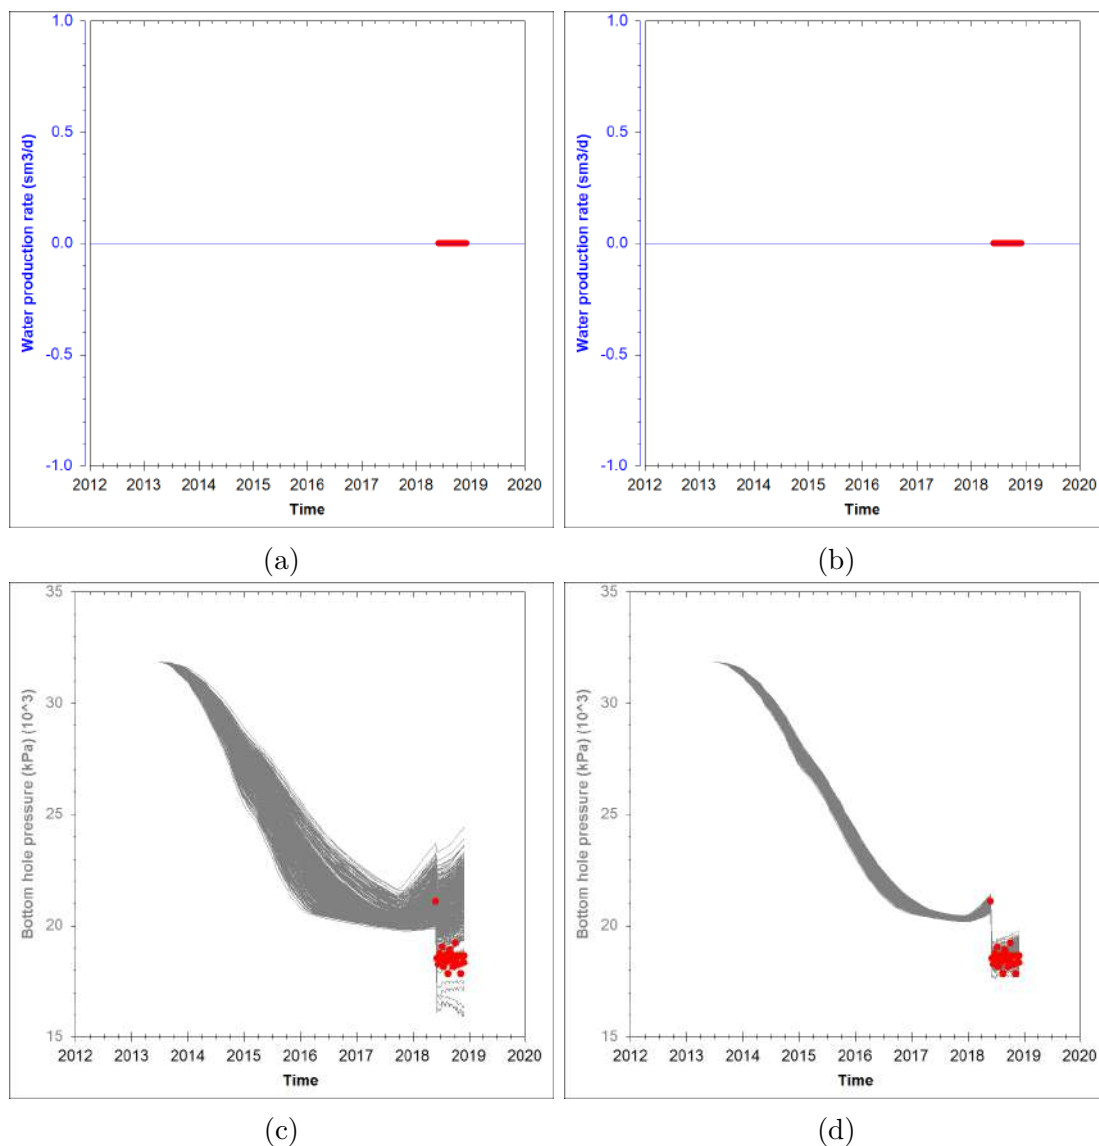


Figura A.9: Resultado do ajuste de histórico no poço P9. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

Injetor 1

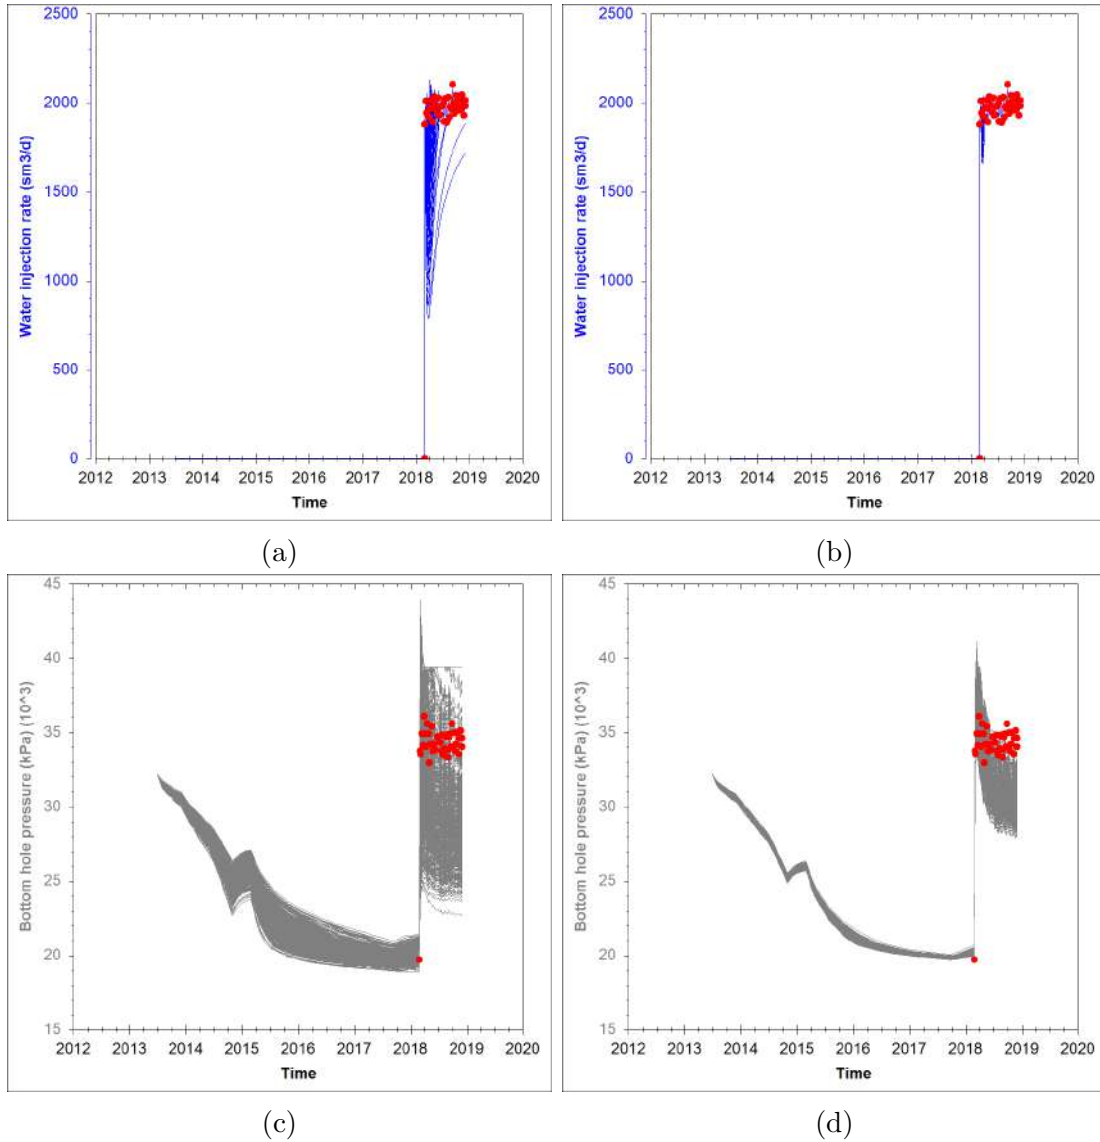


Figura A.10: Resultado do ajuste de histórico no poço Injetor 1. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água de injeção: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

Injetor 6

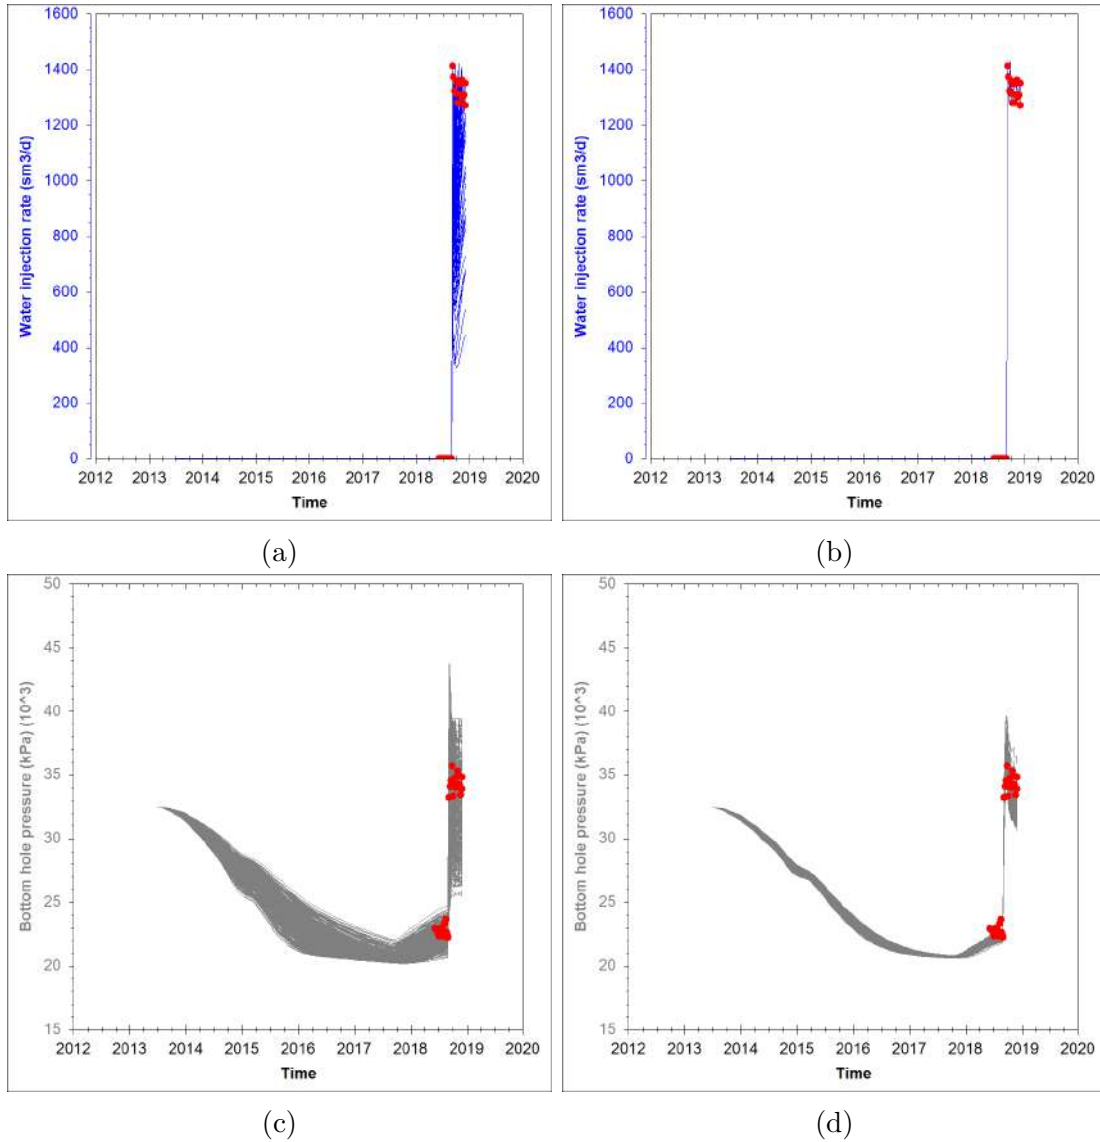


Figura A.11: Resultado do ajuste de histórico no poço Injetor 6. Os pontos vermelhos representam os dados medidos e as linhas contínuas os dados simulados. Os gráficos da esquerda se referem aos 500 modelos antes do ajuste de histórico e os da direita depois do ajuste de histórico. Vazão de água de injeção: (a) modelos iniciais, (b) modelos ajustados. Pressão de fundo: (c) modelos iniciais, (d) modelos ajustados.

A.2 Ajuste de histórico dos dados de perfil do Ciclo 3




Figura A.12: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Injetor 6.




Figura A.13: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço Injetor 8.




Figura A.14: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço RJS19.




Figura A.15: Modelo com melhor ajuste dos dados de perfil. Resultados antes e depois do ajuste além do modelo de referência para o poço NA3D.

Apêndice B

Resultados da Etapa de Seleção de Modelos Representativos




Figura B.1: Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo Zero. Modelos representativos em vermelho.




Figura B.2: Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 3. Modelos representativos em vermelho.




Figura B.3: Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 4. Modelos representativos em vermelho.




Figura B.4: Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 5. Modelos representativos em vermelho.




Figura B.5: Resultado do MDS da matriz de distâncias para os 500 modelos do Ciclo 6. Modelos representativos em vermelho.

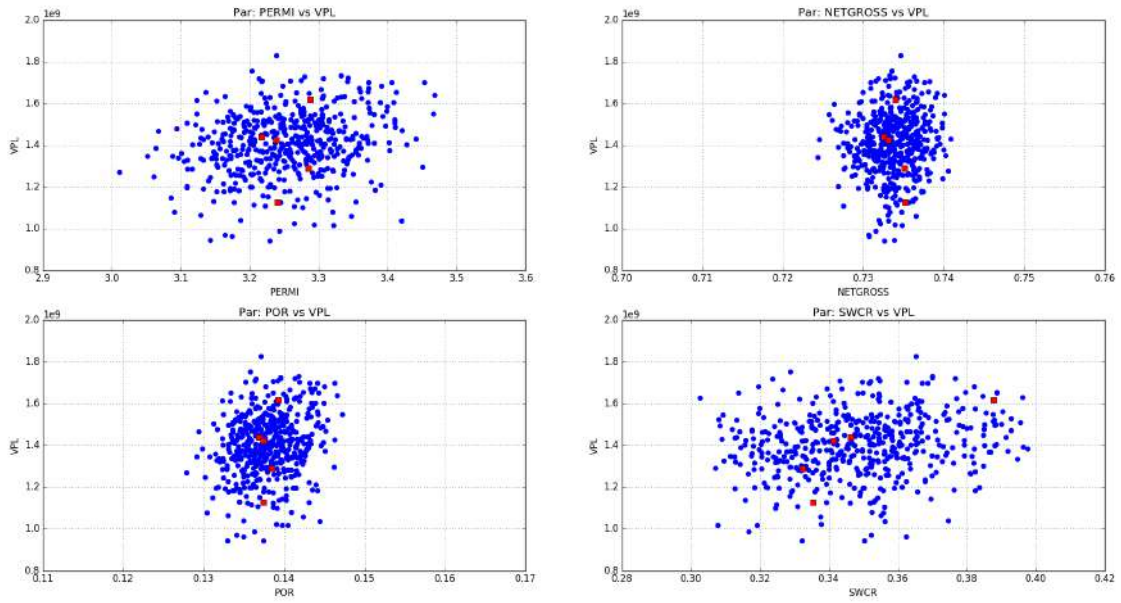


Figura B.6: Conjunto de pares de parâmetros para o Ciclo 1.

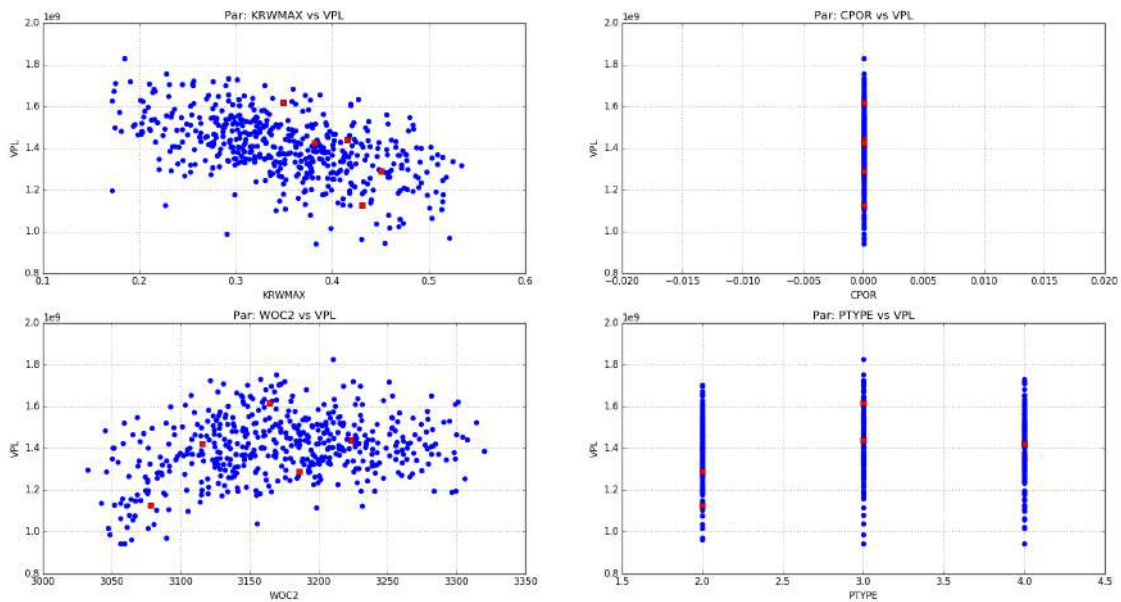


Figura B.7: Conjunto de pares de parâmetros para o Ciclo 1.




Figura B.8: Frequências acumuladas para os parâmetros durante o Ciclo 1.

Apêndice C

Resultados Complementares do DCMF

Tabela C.1: Valores do VPL do modelo de referência em cada ciclo.

Ciclo	VPL (Milhões de \$)	Variação
0	1112,37	—
1	1109,49	-0,26%
2	1237,47	11,54%
3	1580,29	27,70%
4	1606,40	1,65%
5	1543,83	-3,90%
6	1566,02	1,44%




Figura C.1: Evolução da média do N_p para o conjunto de 500 modelos.




Figura C.2: Evolução da média do W_p para o conjunto de 500 modelos.




Figura C.3: Boxplot do FR ao longo dos ciclos.




Figura C.4: Boxplot do WP ao longo dos ciclos.