

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

Metodologia de Otimização Probabilística de Estratégias de Produção Baseada em Algoritmos Genéticos

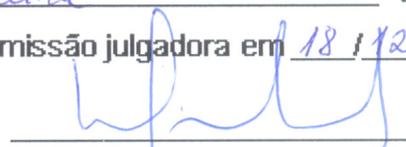
Autor: Pedro de Brito Nogueira

Orientador: Prof. Dr. Denis José Schiozer

12/08

CAMPINAS
2008

Este exemplar corresponde à redação final
da tese defendida por Pedro de Brito
Nogueira aprovada
pela comissão julgadora em 18 / 12 / 2008


Orientador

**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA**

**Metodologia de Otimização Probabilística de
Estratégias de Produção Baseada em Algoritmos
Genéticos**

Autor: **Pedro de Brito Nogueira**
Orientador: **Denis José Schiozer**

Curso: Ciências e Engenharia de Petróleo

Dissertação de mestrado apresentada à Subcomissão de Pós-Graduação Interdisciplinar de Ciências e Engenharia de Petróleo (FEM), como requisito para a obtenção do título de Mestre em Ciências e Engenharia de Petróleo.

Campinas, 2009
SP - Brasil

N689m Nogueira, Pedro de Brito
Metodologia de otimização probabilística de
estratégias de produção baseada em algoritmos genéticos
/ Pedro de Brito Nogueira. --Campinas, SP: [s.n.], 2008.

Orientador: Denis José Schiozer.

Dissertação de Mestrado - Universidade Estadual de
Campinas, Faculdade de Engenharia Mecânica e
Instituto de Geociências.

1. Otimização matemática. 2. Estratégia. 3.
Algoritmos Genéticos. 4. Engenharia de Reservatórios
de óleo. I. Schiozer, Denis José. II. Universidade
Estadual de Campinas. Faculdade de Engenharia
Mecânica e Instituto de Geociências. III. Título.

Título em Inglês: Methodology of production strategy optimization based on genetic algorithms

Palavras-chave em Inglês: Optimization under uncertainties, Production strategies, Genetic algorithms, Petroleum reservoir engineering

Área de concentração: Reservatórios e Gestão

Titulação: Mestre em Ciências e Engenharia de Petróleo

Banca examinadora: Osvaldo Vidal Trevisan, Leandro Costa Reis

Data da defesa: 18/12/2008

Programa de Pós Graduação: Ciências e Engenharia de Petróleo

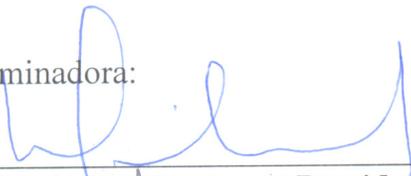
UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

DISSERTAÇÃO DE MESTRADO

Metodologia de Otimização Probabilística de
Estratégias de Produção Baseada em Algoritmos
Genéticos

Autor: **Pedro De Brito Nogueira**
Orientador: **Prof. Dr. Denis José Schiozer**

Banca Examinadora:



Prof. Dr. Denis José Schiozer, Presidente
Faculdade de Engenharia Mecânica - UNICAMP



Prof. Dr. Osvair Vidal Trevisan
Faculdade de Engenharia Mecânica - UNICAMP



Dr. Leandro Costa Reis
Petróleo Brasileiro - Petrobras

Campinas, 18 de dezembro de 2008

Dedicatória

Dedico este trabalho ao meu pai, Enéas, à minha esposa Ana Carolina e aos meus filhos Pedro Henrique, Lucas e Miguel, que me ensinaram tudo, do pouco que sei, a respeito da vida.

Agradecimentos

Ao Prof. Dr. Denis J. Schiozer pelo incrível profissionalismo que conduziu esta pesquisa.

À Eng^a. Christiane de Camargo, pelos ensinamentos e incentivo ao aprimoramento profissional.

Ao amigo Mauro Ida, pelo companheirismo e auxílio no desenvolvimento deste trabalho.

Aos professores do departamento de engenharia de petróleo pelo conhecimento que adquiri nestes últimos anos.

Ao João Paulo, Odair, Carlos, Perin, Avansi, Parker, Ivan, André Francisco, Rafael, Beto, Fernando, Diogo e Philipe pela amizade e companheirismo.

Aos gerentes da Petrobras, Marcelo Marinho e Antônio Carlos Decnop pelo apoio formal para a realização deste mestrado.

À Petrobras pelo suporte financeiro.

Resumo

NOGUEIRA, Pedro de Brito. **Metodologia de Otimização Probabilística de Estratégias de Produção Baseada em Algoritmos Genéticos**, Campinas: Faculdade de Engenharia Mecânica, e Universidade Estadual de Campinas, 2008. 141 pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP, 2008.

Os altos níveis de incerteza e riscos associados a projetos de exploração e produção de alguns campos de petróleo sugerem a utilização de estratégias de produção otimizadas probabilisticamente. Desta forma, uma estratégia de produção adequada deve ser selecionada considerando vários cenários econômicos e geológicos. Neste trabalho, uma nova abordagem para otimização é proposta onde a estratégia de produção é otimizada simultaneamente em todos os cenários econômicos e modelos geológicos representativos (MGR) considerados.

Diferentemente das metodologias convencionais de otimização, onde os valores presentes líquidos das estratégias são otimizados independentemente para cada MGR considerando um único cenário econômico, esta nova abordagem considera todos os MGR e cenários econômicos adotados simultaneamente. Isto permite disponibilizar mais informações a respeito do desempenho da estratégia nos diversos cenários permitindo que se realize uma melhor tomada de decisão. Além disso, a estratégia de produção definida pela abordagem proposta tende a ser mais adaptável às incertezas geológicas e econômicas.

Contudo, geralmente, uma complexa superfície de resposta é gerada no processo de otimização da quantidade e posicionamento dos poços. O elevado potencial de geração de valores extremos locais justifica a utilização de técnicas robustas de busca como os algoritmos genéticos. Neste caso, o espaço solução é mais bem explorado conduzindo a resultados mais confiáveis.

Entretanto, técnicas de busca dispersas tendem a ser mais caras computacionalmente que técnicas baseadas no cálculo dos gradientes da função-objetivo. Neste trabalho é proposta uma metodologia de otimização probabilística de estratégias de produção baseadas em algoritmos genéticos que visa reduzir o número de simulações necessárias para maximizar o valor monetário esperado. A idéia principal é controlar o tamanho do espaço solução através de uma representação cromossômica apropriada e implementar etapas específicas de otimização, otimizando todos os MGR para todos os cenários econômicos considerados simultaneamente através de uma técnica de simulação desenvolvida com este propósito.

O presente trabalho visa dar uma abordagem mais rigorosa às incertezas que as metodologias geralmente utilizadas conduzindo a melhores resultados e permitindo que se realize uma análise completa dos impactos das incertezas geológicas e econômicas. Além disso, este trabalho pretende propiciar um avanço com relação à redução do número de simulações necessárias para se otimizar uma estratégia de produção através de algoritmo genético conduzindo a resultados mais rápidos permitindo dar dinâmica ao processo decisório.

Palavras Chave: Estratégia de Produção, Otimização, Incertezas, Simulação Numérica de Reservatórios.

Abstract

NOGUEIRA, Pedro de Brito. **Probabilistic Methodology of Production Strategies Optimization Based on Genetics Algorithms**, Campinas: Faculdade de Engenharia Mecânica, e Universidade Estadual de Campinas, 2008. 141 pp. Dissertação (Mestrado em Ciências e Engenharia de Petróleo) – Faculdade de Engenharia Mecânica e Instituto de Geociências, Universidade Estadual de Campinas – UNICAMP, 2008.

High levels of uncertainty and associated risks in the exploration and production of some oil fields suggest the use of probabilistic optimized production strategies. Therefore, an appropriate production strategy should be chosen considering various geological and economic scenarios. In this work, a new approach for the optimization is proposed where the production strategy is optimized for selected geological representative models (GRM) and under selected economic scenarios simultaneously.

Differently from conventional optimization methodologies where each representative geological model has a net present value (NPV) optimized under a specific economic model, this new approach considers all alternatives simultaneously, providing more information about the production performance of all scenarios, allowing a better decision-making process. Moreover, production strategy defined by the new approach tends to be more adaptable to geological and economic uncertainties.

However, in the optimization process of wells quantity and placement, a very complex topology is normally produced. The potential of generation of local extreme values is high, therefore, it is appropriate to employ a robust search technique such as genetic algorithms. In this case, the solution space is better explored, yielding more confident results.

However, random based techniques tend to be more expensive computationally than gradient based techniques. In this work, a methodology is proposed for production strategy optimization under uncertainties, based on genetic algorithms, that aims to reduce the number of simulations necessary to maximize the expected monetary value (EMV). The main idea is to control the size of the solution space through an appropriated conception of chromosomes structures and the implementation of specific optimizations stages optimizing every GRM for every economic scenario simultaneously through a simulation technical developed for this purpose.

The present work aims to provide an improvement with respect to uncertainty handling of the conventional optimization methodologies, yielding better results and providing a complete analysis of geological and economic uncertainties. Moreover, its intends to provide an advance with respect to the number of simulations necessary to optimize a production strategy through genetic algorithms, yielding faster results, speeding up the decision-making process.

Key words: Production Strategy, Optimization, Uncertainty, Numerical Reservoir Simulation

Sumário

Capítulo 1 - Introdução	1
1.1 Motivação	2
1.2 Objetivos	3
1.3 Premissas.....	4
Capítulo 2 - Fundamentos Teóricos	5
2.1 Estratégia de Produção.....	5
2.2 Seleção de Estratégia de Produção.....	6
2.3 Otimização de Estratégias de Produção.....	6
2.4 Otimização de Estratégias de Produção sob Incertezas	6
2.5 Técnicas de Otimização	7
2.6 Algoritmos Genéticos.....	8
2.6.1 Aspectos Gerais	8
2.6.2 Descrição do Algoritmo Genético.....	9
2.6.3 Implementação de Algoritmos Genéticos.....	14
2.7 Integração com Avaliação Econômica.....	15
2.7.1 VPL.....	15
2.7.2 VME total.....	20
2.7.3 VME geológico para um cenário econômico	22
2.7.4 VME econômico para um modelo geológico	22
Capítulo 3 - Revisão Bibliográfica	23
3.1 Seleção de Estratégia de Produção Assistida	23
3.2 Metodologias de Otimização de Estratégias de Produção	24
3.3 Metodologias de Otimização Manuais.....	26
3.4 Aplicação de Algoritmos Genéticos em Problemas de Otimização de Estratégias de Produção.....	27
3.5 Otimização de Estratégias de Produção sob Incertezas	28
Capítulo 4 - Metodologia	30
4.1 Metodologia de Trabalho	30
4.2 Metodologia de Otimização de Estratégias de Produção	31
4.2.1 Descrição Geral.....	32
4.2.2 Função-Objetivo	33
4.2.3 Desempenhos dos Poços.....	33
4.2.4 Desempenhos Esperados dos Poços	36
4.2.5 Algoritmo Genético	36
4.2.6 Alternativa para a otimização da quantidade de poços	46
4.3 Técnica para Consideração das Incertezas ao Longo do Processo de Otimização .	46
4.4 Planejamento de Aquisição de Informações do Reservatório	49

4.4.1	Descrição Geral.....	49
4.4.2	Mapas de Diferenças	49
4.4.3	Procedimento Proposto	50
4.5	Rotinas de Cálculo da Função-Objetivo.....	51
4.6	Rotinas de Otimização da Função-Objetivo	53
Capítulo 5 - Aplicações.....		56
5.1	Modelos de Fluxo	56
5.1.1	Geologia.....	56
5.1.2	Petrofísica	61
5.1.3	Fluidos.....	61
5.1.4	Condições Operacionais.....	62
5.1.5	Estratégias Iniciais	63
5.2	Cenários Econômicos.....	64
5.3	Investimentos.....	64
5.4	Resumo das Aplicações	65
Capítulo 6 - Resultados		67
6.1	Etapa 1 – Estudo da Superfície de Resposta de Problema de Otimização de Posicionamento de Poços.....	67
6.1.1	Caso 1	67
6.2	Etapa 2 – Otimização Determinística de Estratégias de Produção	71
6.2.1	Caso 2A - Estratégias com Poços Verticais	71
6.2.2	Caso 2B - Estratégias com Poços Horizontais	77
6.3	Etapa 3 – Otimização Probabilística de Estratégias de Produção.....	82
6.3.1	Caso 3A - Incertezas Geológicas sem Compartimentação do Reservatório .	83
6.3.2	Caso 3B – Incertezas Geológicas com Compartimentação do Reservatório.	89
6.3.3	Caso 3C – Incertezas Econômicas	92
6.3.4	Caso 3D – Incertezas Geológicas com Compartimentação do Reservatório e Incertezas Econômicas	95
6.4	Etapa 4 – Estudo para Indicação da Seqüência de Perfuração de Poços.....	102
6.4.1	Caso 4	102
Capítulo 7 - Conclusões.....		119
Referências		122

Lista de Figuras

Figura 2.1 - Método da Roleta.....	13
Figura 2.2 – Fluxograma para um algoritmo genético simples	1
Figura 3.1 – Etapas do processo de seleção e otimização de estratégias de produção. (Mezzomo, 2005).....	1
Figura 3.3 – Mapa de classificação – caminho de prioridades de alterações (Schiozer <i>et al.</i> , 2002).....	1
Figura 4.1 - Representação cromossômica do problema de otimização do posicionamento dos poços.....	38
Figura 4.2 - Exemplo de população inicial gerada a partir a estratégia inicial (superior).....	1
Figura 4.3 - Algoritmo Genético - Exemplo do Processo de Evolução de uma População	1
Figura 4.4 - representação Cromossômica do problema de otimização da quantidade de poços..	44
Figura 4.5 – Malhas dos Modelos de fluxo	47
Figura 4.6 – Esquema dos arquivos dos modelos de fluxo	48
Figura 4.7 – Procedimento proposto para determinar ordem de perfuração de poços.	51
Figura 4.8 - Fluxograma da rotina TITANIUM – Cálculo do VPL	52
Figura 4.9 – Fluxograma da Rotina AURUM – Cálculo do VME.....	52
Figura 4.10 – Fluxograma rotina OPTIMUS – gerenciamento do processo de otimização de estratégias de produção.....	53
Figura 4.11 – Fluxograma rotina QUANTUM – otimização da quantidade de poços por exclusão seqüencial	54
Figura 4.12 – Fluxograma rotinas DEO e PLUVIA – otimização do posicionamento e da quantidade de poços por algoritmo genético	55
Figura 5.1 – Perspectiva da estrutura do reservatório indicando o topo das células – modelo intermediário – exagero vertical de 15x	58
Figura 5.2 – Corte norte-sul e leste-oeste indicando o topo das células – modelo intermediário - exagero vertical de 15x.....	58
Figura 5.3 – MGR ₁ - mapas de permeabilidade horizontal – modelos pessimista, intermediário e otimista	59
Figura 5.4 – MGR ₁ - mapas de espessura – modelos pessimista, intermediário e otimista	60
Figura 5.5 – MGR ₁ - mapas de porosidades – modelos pessimista, intermediário e otimista	60
Figura 5.6 – MGR ₂ - mapas de permeabilidade indicando a compartimentação do reservatório – modelo pessimista, intermediário e otimista	60
Figura 5.7 – Reservatório “hipotético” - mapas de permeabilidade horizontal, espessura e porosidade.....	61
Figura 5.8 – Curvas de permeabilidades relativas	61
Figura 5.9 – Curvas de PVT do óleo	62
Figura 5.10 – Mapa de permeabilidade do modelo intermediário com as estratégias iniciais.	63
Figura 6.1 – Posicionamentos possíveis para os poços 1 e 2 para obtenção da superfície de resposta de um problema de otimização de estratégia de produção.	1
Figura 6.2 – Superfície de resposta para o problema de otimização dos posicionamentos de dois poços.....	1
Figura 6.3 – Evolução da população no processo de otimização por algoritmo genético.....	1

Figura 6.4 – Evolução do VPL no processo de otimização por algoritmo genético	1
Figura 6.5 – Alterações realizadas pela rotina PLUVIA na estratégia inicial e a estratégia após a realização deste passo.....	72
Figura 6.7 – Alterações realizadas pela rotina DEO na estratégia anterior e a estratégia após a realização deste passo.....	73
Figura 6.6 – Evolução do VPL ao longo da rotina PLUVIA – CASO 2A.....	1
Figura 6.8 – Evolução do VPL ao longo da rotina DEO – 1ª Fase – CASO 2A.....	1
Figura 6.9 – Alterações realizadas pela rotina QUANTUM na estratégia anterior e a estratégia após a realização deste passo.....	75
Figura 6.10 – Alterações realizadas pela rotina DEO na estratégia anterior e a estratégia como ficou após a realização deste passo.....	75
Figura 6.11 – Evolução do VPL ao longo da rotina DEO – 2ª Fase – CASO 2A.....	1
Figura 6.12 – Evolução do VPL com o número de simulações – CASO 2A.....	1
Figura 6.13 – Evolução do VPL ao longo da rotina DEO – 1ª Fase – CASO 2B	1
Figura 6.14 – Estratégia de produção após a execução da rotina DEO – 1ª Fase – CASO 2B	1
Figura 6.15 – Evolução do VPL ao longo da rotina DEO – 2ª Fase – CASO 2B	1
Figura 6.16 – Estratégia de produção após a execução da rotina DEO – 2ª Fase – CASO 2B	1
Figura 6.17 – Evolução do VPL com o número de simulações – CASO 2B	1
Figura 6.18 – Processo de Ramificação – CASO 3A – Otimização pelo VME.....	1
Figura 6.19 – Curvas de Risco Caso 3A.....	1
Figura 6.20 – Curvas de Risco Caso 3B.....	1
Figura 6.21 – Curvas de Risco Caso 3C.....	1
Figura 6.22 – Curvas de Risco Caso 3D.....	1
Figura 6.23 – Estratégia otimizada pelo VME no modelo intermediário.....	1
Figura 6.24 – Curva de risco para a estratégia inicial	1
Figura 6.25 – Mapa de diferença relativa de qualidade.....	1
Figura 6.26 – Mapa de diferença absoluta de qualidade	1
Figura 6.27 – Mapa de diferença de IDC	1
Figura 6.28 – Mapa do valor absoluto da diferença de IDC.....	1
Figura 6.29 – Mapa de diferença de IDF.....	1
Figura 6.30 – Mapa ΔQ x ΔIDC	1
Figura 6.31 – Gráfico ΔQ x ΔIDC	1
Figura 6.32 – Valores de ΔQ x ΔIDC	1
Figura 6.33 – Mapa ΔQ x $ \Delta IDC $	1
Figura 6.34 – Gráfico ΔQ x $ \Delta IDC $	1
Figura 6.35 – Valores de ΔQ x $ \Delta IDC $	1
Figura 6.36 – Mapa ΔQ x ΔIDF	1
Figura 6.37 – Gráfico ΔQ x ΔIDF	1
Figura 6.38 – Valores de ΔQ x ΔIDF	1
Figura 6.39 – Evolução das curvas de risco com o desenvolvimento do campo	1
Figura 6.40 – Evolução do risco com o desenvolvimento do campo.....	1
Figura 6.41 – Evolução do VME com o desenvolvimento do campo.....	1
Figura 6.42 – Evolução do VPL da estratégia otimizada no modelo hipotético com o desenvolvimento do campo	1

Lista de Tabelas

Tabela 5.1 - Propriedades dos modelos geológicos.....	59
Tabela 5.2 - Condições Operacionais dos Poços.....	63
Tabela 5.3 - Cenários econômicos.....	64
Tabela 5.4 - Tabelas de investimentos	64
Tabela 5.5 – Resumo das Aplicações	66
Tabela 6.1 - Parâmetros do algoritmo genético - Caso 2A.....	72
Tabela 6.2 - Processo de Otimização - Caso 2A	77
Tabela 6.3 - Parâmetros do algoritmo genético - Caso 2B.....	78
Tabela 6.4 - Processo de Otimização - Caso 2B.....	81
Tabela 6.5 - Processo de Otimização - Caso 3A - VME.....	84
Tabela 6.6 - Processo de Otimização - Caso 3A – Modelo Geológico Pessimista	85
Tabela 6.7 - Processo de Otimização - Caso 3A – Modelo Geológico Intermediário	85
Tabela 6.8 - Processo de Otimização - Caso 3A – Modelo Geológico Otimista	86
Tabela 6.9 - Resultados Finais - Caso 3A	87
Tabela 6.10 - Processo de Otimização - Caso 3B - VME	89
Tabela 6.11 - Processo de Otimização - Caso 3B – Modelo Geológico Pessimista.....	89
Tabela 6.12 - Processo de Otimização - Caso 3C – Modelo Geológico Intermediário.....	90
Tabela 6.13 - Resultados Finais - Caso 3B.....	91
Tabela 6.14 - Processo de Otimização - Caso 3C - VME	92
Tabela 6.15 - Processo de Otimização - Caso 3C – Cenário Econômico Pessimista.....	93
Tabela 6.16 - Processo de Otimização - Caso 3C – Cenário Econômico Otimista.....	93
Tabela 6.17 - Resultados Finais - Caso 3C.....	94
Tabela 6.18 - Processo de Otimização - Caso 3D – VME	96
Tabela 6.19 - Processo de Otimização - Caso 3D – Modelo Geológico Pessimista e Cenário Econômico Pessimista	96
Tabela 6.20 - Processo de Otimização - Caso 3D – Modelo Geológico Pessimista e Cenário Econ. Intermediário	96
Tabela 6.21 - Processo de Otimização - Caso 3D – Modelo Geológico Pessimista e Cenário Econômico Otimista	97
Tabela 6.22 - Processo de Otimização - Caso 3D – Modelo Geológico Intermediário e Cenário Econ. Pessimista	97
Tabela 6.23 - Processo de Otimização - Caso 3D – Modelo Geológico Intermediário e Cenário Econ. Intermediário	97
Tabela 6.24 - Processo de Otimização - Caso 3D – Modelo Geológico Intermediário e Cenário Econ. Otimista	98
Tabela 6.25 - Processo de Otimização - Caso 3D – Modelo Geológico Otimista e Cenário Econômico Pessimista	98
Tabela 6.26 - Processo de Otimização - Caso 3D – Modelo Geológico Otimista e Cenário Econômico Intermediário	98
Tabela 6.27 - Processo de Otimização - Caso 3D – Modelo Geológico Otimista e Cenário Econômico Otimista	99
Tabela 6.28 - Resultados Finais - Caso 3D	101

Tabela 6.29 - Desempenho da estratégia inicial	103
Tabela 6.30 – IDC dos poços para a estratégia inicial.....	105

Nomenclatura

A_i^G	Aptidão do indivíduo i da geração G
Aac_i^G	Aptidão acumulada do indivíduo i da geração G
G	Número da geração
G_{max}	Número máximo de gerações
$LMUT$	Limite de ativação da mutação
N	Número de células na direção i
NP^G	Número de indivíduos na geração G
M	Número de células na direção M
MGR	Modelo geológico representativo
MGR_1	Grupo 1 de modelos geológicos representativos
MGR_2	Grupo 2 de modelos geológicos representativos
\vec{P}^e	Vetor com as probabilidades de ocorrência dos cenários econômicos
\vec{P}^g	Vetor com as probabilidades de ocorrência dos modelos geológicos
\vec{P}^{ge}	Matriz de probabilidades
PC_i^G	Probabilidade de seleção para cruzamento do indivíduo i da geração G
$PMUT$	Probabilidade de haver mutações
RND_k	Número aleatório
ROI	Retorno sobre investimento

$S_{(k)}$	Índice selecionado no processo de seleção
TIR	Taxa interna de retorno
TMA	Taxa mínima de atratividade
VME	Valor monetário esperado
$VMEE$	Valor monetário esperado econômico
$VMEG$	Valor monetário esperado geológico
VPL	Valor presente líquido
\vec{X}_i^G	Cromossomo - Indivíduo i da geração G
$x_{i,j}^G$	Gene - Componente i do indivíduo j da geração i

Capítulo 1 - Introdução

Selecionar a estratégia de produção a ser adotada na exploração de uma jazida de petróleo se constitui em um dos desafios mais importantes da engenharia de reservatórios. A escolha adequada permite que a produção seja feita de forma eficiente, visando maximizar o desempenho do reservatório. Entretanto, o processo de seleção representa uma tarefa extremamente complexa, onde várias etapas de tomada de decisão devem ser realizadas em um contexto estritamente multidisciplinar (Mezzomo, 2005). Quase todas as áreas da engenharia de petróleo são envolvidas neste processo que visa à definição de itens como: tecnologia e capacidade do sistema de produção, arranjo submarino (em um ambiente marítimo), métodos de elevação artificial, tipos de poços e suas compleтаções bem como as suas quantidades e posicionamentos entre outros.

Projetos de exploração de campos de petróleo, geralmente encontram-se cercados de incertezas de origem geológica, econômica, tecnológica e operacional. O desconhecimento de parâmetros importantes do modelo de fluxo, do cenário econômico futuro, do avanço tecnológico e das condições operacionais do campo podem gerar grandes variações na expectativa de desempenho do projeto, expondo a empresa a elevados níveis de risco. Frequentemente, o gerenciamento deste tipo de risco é feito através da adoção de políticas que definem a postura da empresa perante às incertezas visando conferir maior robustez e flexibilidade ao projeto. Uma forma de se reduzir o impacto destas incertezas no desempenho do projeto é considerá-las no processo de seleção da estratégia de produção permitindo que seja escolhida a estratégia que apresente maior adaptabilidade diante das possíveis variações. Em projetos com grandes incertezas e baixa flexibilidade, como é o caso de campos marítimos, é interessante que esta consideração seja feita de forma rigorosa para que se possa explorar o máximo do potencial da jazida.

Outro ponto de grande relevância com relação à seleção de estratégia de produção é o processo de otimização ao qual as opções de estratégias são submetidas. Para que a escolha seja feita de forma adequada, as opções concebidas inicialmente devem ser otimizadas para revelar o seu potencial. É importante comparar estratégias otimizadas, para que somente estratégias de

potencial comprovadamente baixo sejam excluídas no decorrer do processo de seleção (Mezzomo, 2005). A escolha da técnica de otimização a ser aplicada deve ser feita visando encontrar a que melhor se adapta à superfície de resposta gerada por este tipo de problema. Os métodos de otimização baseados no cálculo dos gradientes, por exemplo, possuem grande eficiência em busca local, contudo existe a tendência de se concentrarem em regiões específicas do espaço solução restringindo a abrangência da busca. Processos de otimização de estratégia de produção, mais especificamente de otimização da quantidade e posicionamento dos poços, possuem grande potencial de geração de valores extremos locais sendo necessário serem abordados por técnicas de busca por valor extremo global. Neste tipo de técnica de otimização, o espaço solução é mais bem explorado, dando maior confiança que a resposta obtida representa um valor otimizado.

Os algoritmos genéticos representam uma categoria de técnica de otimização que prioriza a diversificação, sendo guiada por um processo que em parte é aleatório, buscando alternativas mais diversificadas no espaço solução. De uma forma geral, este tipo de algoritmo consegue adquirir informações sobre determinadas características de boas soluções testadas durante o processo de otimização e transmiti-las para as próximas iterações buscando a melhora da qualidade das soluções geradas a cada iteração.

1.1 Motivação

Incorporar um procedimento de otimização assistida aos processos de seleção e refinamento de estratégias de produção confere maior dinâmica e confiabilidade ao processo decisório. Técnicas manuais de otimização (Nakajima, 2003) guiadas por tentativa e erro tendem a requerer um grande volume de trabalho e podem conduzir o processo para um valor extremo local da função-objetivo. Em contraposição às técnicas manuais, os procedimentos de otimização assistida, além de requererem pouca ou nenhuma intervenção, geram resultados mais confiáveis, pois exploram melhor o espaço de soluções do problema garantindo uma segurança maior que o problema foi otimizado de forma consistente.

Os algoritmos genéticos (Goldberg, 1989) constituem uma categoria de técnicas de busca por valor extremo global e geralmente estão associados a um elevado custo computacional. O seu emprego, em problemas de otimização, deve ser justificado pela possibilidade de ocorrência de

valores extremos locais na superfície de resposta em questão que inviabilizaria a aplicação de métodos menos custosos. Sendo assim, é interessante a realização de um esforço visando reduzir o número de simulações comumente necessárias para a otimização por estes métodos. O conhecimento do problema, a princípio, permite que sejam feitas adaptações no algoritmo, incluindo técnicas de engenharia para aumentar a eficiência do processo.

Os elevados níveis de incerteza e risco associados a determinados projetos de exploração de campos de petróleo sugerem a utilização de estratégias de produção otimizadas probabilisticamente. Avaliar o desempenho das estratégias de produção em vários modelos geológicos e sob vários cenários econômicos possíveis permite que se faça a escolha da estratégia que melhor se ajusta às incertezas existentes, absorvendo melhor o efeito destas variações e tornando-a mais adaptável às incertezas. Sendo assim, uma avaliação probabilística sob diversos contextos geológicos e econômicos permite que se gerenciem as incertezas de forma a maximizar o desempenho do projeto e ajustar a exposição ao risco de acordo às diretrizes da empresa.

O impacto que as incertezas geológicas causam no desempenho esperado de um projeto de exploração justifica a adoção de um plano de aquisição de informações do reservatório. Este plano pode objetivar, por exemplo, reduzir, prioritariamente, as incertezas mais impactantes no desempenho esperado do projeto, possibilitando que sejam realizadas re-otimizações da estratégia em contextos cada vez mais realistas. Permite-se, desta forma, que ao final do desenvolvimento de um campo o desempenho do projeto esteja mais próximo do real potencial da jazida.

1.2 Objetivos

Este trabalho se propõe a atingir os seguintes objetivos:

- Propor uma metodologia de otimização de estratégias de produção (quantidade e posicionamento de poços) utilizando algoritmo genético, com especial atenção à eficiência do processo.
- Desenvolver uma técnica que possibilite a incorporação das incertezas na função-objetivo, com a finalidade de guiar o processo de otimização por completo, conferindo maior rigor na abordagem das incertezas.

- Implementar uma ferramenta computacional de otimização de estratégias de produção sob incertezas.
- Propor uma metodologia para indicar a seqüência de perfuração e testes de formação dos poços visando à re-otimização da estratégia, maximizando o seu desempenho e acelerando a redução da exposição ao risco.

1.3 Premissas

O escopo deste trabalho é restrito a etapa automática do processo de seleção de estratégia de produção, mais especificamente na otimização da quantidade e posicionamentos dos poços.

A utilização de algoritmos genéticos tem por objetivo mostrar que métodos de busca por valor extremo global podem ser aplicados, com ganho de eficiência, em problemas de otimização de estratégias de produção, quando são adequadamente adaptados para se valerem do conhecimento prévio de características importantes do problema. Este trabalho não visa apresentar o estado da arte deste tipo de algoritmo, apenas indicar que adaptações fundamentadas na engenharia do problema de otimização de estratégia de produção podem conferir maior eficiência ao processo.

A técnica de otimização probabilística é aplicável em casos em que as incertezas geológicas são bem representadas por poucos modelos geológicos, já que a otimização simultânea requer que todos os modelos de fluxo sejam simulados a cada iteração do processo de simulação. Pode-se utilizar o conceito de modelos geológicos representativos (Schiozer *et al.*, 2004) para aplicação desta técnica em casos reais.

Capítulo 2 - Fundamentos Teóricos

Neste capítulo serão apresentados alguns dos fundamentos utilizados neste trabalho, com a intenção de facilitar o entendimento da metodologia proposta. As definições iniciais, seleção e otimização da estratégia de produção têm como finalidade definir o contexto no qual este trabalho foi realizado. Será apresentado também, um sumário a respeito das principais categorias de técnicas de otimização com o objetivo de explicitar suas características mais relevantes. Uma descrição mais detalhada será feita para os algoritmos genéticos, na sua formulação clássica, para que no capítulo de metodologia se destaque apenas as contribuições e os aspectos mais importantes realizados para esta dissertação. Finalmente, os conceitos básicos de avaliação econômica e financeira de projetos de exploração de campos de petróleo utilizados neste trabalho são apresentados.

2.1 Estratégia de Produção

Estratégia de produção é o termo utilizado para designar, de forma geral, o plano que estabelece a maneira como uma jazida de petróleo será explorada. Ao definir uma estratégia de produção definem-se vários de aspectos importantes do plano de desenvolvimento do campo como, por exemplo:

- Métodos de recuperação primária e secundária do campo.
- Tipos, quantidades e posicionamentos dos poços.
- Condições operacionais e cronograma de entrada dos poços.
- Tecnologia e capacidade do sistema de produção.
- Disposição espacial dos equipamentos submarinos (no caso de campos marítimos).
- Dimensões de linhas e colunas de produção.
- Método de elevação artificial.

2.2 Seleção de Estratégia de Produção

As diversas composições, tecnicamente viáveis, dos itens listados acima formam o domínio do problema de seleção de estratégias de produção que deve ser selecionada considerando estas opções. A complexidade deste problema reside, em parte, na grande quantidade de opções que podem ser concebidas pela combinação desses itens. Otimizar cada uma delas em padrão de refinamento seria uma tarefa impraticável dado o volume de trabalho requerido. No sentido de reduzir este volume de trabalho, algumas estratégias devem ser excluídas, criteriosamente, do processo de seleção antes da etapa de refinamento. Outras, entretanto, devem ser refinadas para revelar o seu real potencial. Mezzomo (2005) propõe uma metodologia a ser aplicada neste processo com a consideração do risco envolvido. A metodologia proposta por Mezzomo (2005) divide o processo de seleção em fases as quais são subdivididas em etapas. Uma descrição com maiores detalhes da metodologia proposta por Mezzomo (2005) é realizada no Item 3.1.

2.3 Otimização de Estratégias de Produção

A necessidade de otimizar estratégias de produção pode ocorrer em diversas etapas do processo de seleção ou mesmo no refinamento final da estratégia selecionada. A otimização da estratégia de produção pode, ainda, ser feita durante o desenvolvimento do campo¹. Neste sentido, processos de otimização manuais, assistidos ou automatizados são utilizados nestas várias etapas. A adequabilidade de cada tipo de processo vai depender de quatro fatores principais: (1) natureza do problema de otimização, (2) tempo disponível para a realização da otimização, (3) disponibilidade de ferramentas de otimização e (4) precisão requerida para a resposta.

2.4 Otimização de Estratégias de Produção sob Incertezas

Em uma abordagem convencional, a otimização da estratégia de produção sob incertezas, é feita através da composição dos modelos geológicos representativos (MGR) com as realizações para os cenários econômicos formando uma árvore de decisão. Para cada ramo desta árvore, uma

¹ Como a perfuração dos poços não é realizada simultaneamente, as informações adquiridas como a perfuração de um poço pode justificar a necessidade de re-otimização dos posicionamentos dos poços ainda não perfurados.

estratégia de produção é otimizada independentemente, conforme mostra a Figura 2.1. Ao final do processo de otimização dos ramos, a estratégia que apresentasse o maior valor monetário esperado (VME) seria considerada otimizada sob incerteza. Como pode ser observado, neste caso, a consideração das incertezas ocorre depois que os ramos da árvore de decisão foram otimizados. Para garantir um melhor fluxo de informações esta metodologia de otimização de estratégias de produção será designada neste trabalho por MADC (metodologia da árvore de decisão convencional)

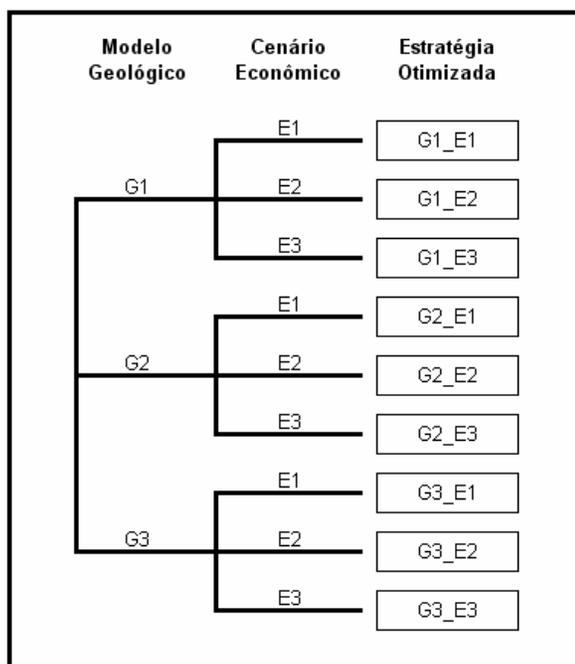


Figura 2.1 – Árvore de decisão utilizada pela MADC

2.5 Técnicas de Otimização

As técnicas convencionais de otimização tanto as baseadas no cálculo dos gradientes quanto às de busca direta possuem grande eficácia na busca por valores extremos locais. Em consequência disto, estas técnicas de otimização são mais adequadas para problemas de superfícies de resposta conhecidas ou bem comportadas. Em problemas que envolvam superfícies de resposta mais complexas, com grande potencial de gerar valores extremos locais, torna-se interessante aplicar métodos mais robustos como os de busca dispersa, nos quais se enquadram os

algoritmos genéticos (Goldberg, 1989 e Mitchell, 1998) e *simulated annealing* (Beckner, 1995). Neste tipo de técnica de otimização, onde se busca diversificação, o espaço de solução é mais bem explorado e o algoritmo tende a não se prender a regiões de valores extremos locais.

2.6 Algoritmos Genéticos

2.6.1 Aspectos Gerais

Os algoritmos genéticos são técnicas de computação evolucionária e possuem amplas aplicações na resolução de problemas de otimização nas mais diversas áreas do conhecimento (Mitchell, 1998 e Goldberg, 1989). São inspirados na biologia evolucionária e possuem como característica fundamental simular mecanismos inerentes ao processo evolutivo como seleção, cruzamento, herança e mutação, e aplicá-los a subconjuntos do domínio de problemas matemáticos visando a sua otimização. Portanto, representam heurísticas de otimização de busca por valor extremo global, baseada na mecânica da seleção natural. Embora as heurísticas dos algoritmos genéticos possuam um caráter aleatório, o procedimento se vale do histórico construído e espontaneamente transmite informações das gerações passadas para as seguintes, buscando sempre indivíduos de desempenho superior aos já avaliados.

A natureza traz muitos exemplos de soluções robustas de adaptabilidade de seres vivos aos mais diferentes ambientes. Coube às ciências biológicas o mapeamento dos mecanismos naturais responsáveis pela adequação destes seres aos ambientes que vivem. A chave para o entendimento do processo está no Darwinismo que vem evoluindo desde a sua proposição no século XIX por Charles Darwin na sua “Origem das Espécies” até a chamada teoria da síntese evolutiva moderna ou neo-Darwinismo do meado do século XX, que sistematiza o processo evolutivo e seus mecanismos (Futuyma, 1986). Hoje, muitos destes mecanismos são bem entendidos e podem ser mimetizados para resolução de problemas de engenharia.

Os algoritmos genéticos surgem com o objetivo de aplicar estes mecanismos evolutivos em problemas de otimização matemática. Os algoritmos genéticos reproduzem as principais características do processo evolutivo incorporando-as em técnicas de busca por valores extremos globais. As implementações destes algoritmos, por sua vez, podem ser realizadas com elevado grau de sofisticação visando uma reprodução mais fidedigna do processo evolutivo ou possuir

simplificações e adaptações visando aumentar a eficácia do processo. Compete ao responsável pela implementação do algoritmo calibrar o procedimento visando alcançar à robustez requerida com eficácia necessária.

2.6.2 Descrição do Algoritmo Genético

Neste item, serão apresentados os conceitos básicos necessários para a implementação de um algoritmo genético simples conforme apresentado por Goldberg (1989) e Michalewicz (1996).

Assim como ocorre no processo de evolução natural, os algoritmos genéticos aplicados em problemas de otimização matemática atuam sobre populações de indivíduos. Estes indivíduos são soluções válidas para o problema e são representados em uma estrutura chamada de cromossomo. Os elementos fundamentais desta estrutura são designados por genes.

Para facilitar o entendimento do algoritmo genético e de seus componentes pode-se imaginar, por exemplo, um problema simples de posicionamento de um poço em um reservatório retangular representado por uma malha Cartesiana e uniforme de $N \times M$ células. O problema consiste em encontrar o posicionamento do poço que gere a maior produção acumulada de óleo para um tempo específico².

Uma representação cromossômica para este problema pode ser definida considerando a seguinte representação vetorial:

$$\vec{X} = (x_1, x_2); \quad 1 \leq x_1 \leq N; \quad 1 \leq x_2 \leq M; \quad x_i \in Z_+^* \quad \text{Eq. 2.1}$$

Portanto, o cromossomo é definido por dois genes representados pelos números inteiros x_1 e x_2 , Um indivíduo é definido por dois valores válidos para estes genes.

O problema de otimização pode ser escrito da seguinte forma:

² Considerar ainda que as condições operacionais sejam fixas e que o poço somente pode ser posicionado nos centros das células.

$$\max \{f(\vec{X})\} \quad \text{Eq. 2.2}$$

onde $f(\vec{X})$ é a produção de óleo acumulada para o poço na posição definida por \vec{X} . No processo de otimização, $f(\vec{X})$ é a função-objetivo calculada para o indivíduo \vec{X} .

O processo de otimização por algoritmo genético é iniciado com a criação de uma população inicial representada por:

$$\vec{X}_i^0 \quad i = 1, \dots, NP^0 \quad \text{Eq. 2.3}$$

O índice superior indica a geração a qual o indivíduo pertence (zero – população inicial), o inferior é relativo ao indivíduo em si e NP é o número de indivíduos da população naquela geração. Esta população inicial pode ser gerada de diversas maneiras como, por exemplo: sorteio aleatório dos valores dos genes, distribuição com espaçamento uniforme no espaço solução ou mesmo através de pequenas alterações a partir de um determinado indivíduo.

Após a criação da população inicial são calculadas todas as $f(\vec{X}_i^0)$. Para este caso em questão, o valor da função-objetivo para cada indivíduo pode ser obtido por simulação de fluxo.

Nos algoritmos genéticos, os indivíduos de uma população são classificados a partir de sua “aptidão”. A aptidão é uma medida de desempenho que possibilita a classificação dos indivíduos do mais apto ao menos apto a otimizar o problema. Para o cálculo da aptidão dos indivíduos da geração G é necessário conhecer os valores máximos e mínimos para a função-objetivo nesta geração.

$$f \max^G = \max \{f(\vec{X}_1^G), \dots, f(\vec{X}_{NP}^G)\} \quad \text{Eq. 2.4}$$

$$f \min^G = \min \{f(\vec{X}_1^G), \dots, f(\vec{X}_{NP}^G)\} \quad \text{Eq. 2.5}$$

Considerando um processo de otimização por maximização da função-objetivo, calcula-se a aptidão A_i^G de cada indivíduo i da geração G da seguinte forma:

$$A_i^G = \frac{f(\bar{X}_i^G) - f \min^G}{f \max^G - f \min^G} \quad \text{Eq. 2.6}$$

Pode-se observar, a partir da definição, que a aptidão assume valores que vão de zero a um. Quanto mais próximo da unidade estiver a aptidão de um indivíduo mais apto ele é para a otimização do problema. Nos algoritmos genéticos os indivíduos de maior aptidão são privilegiados no processo de seleção e cruzamento e, portanto, tendem a passar, com maior intensidade, o seu material genético para as próximas gerações.

Após o cálculo das aptidões dos indivíduos, uma nova geração deve ser criada a partir da atual. O primeiro passo para a criação desta nova geração é realizar a seleção dos pares de indivíduos que serão cruzados. A seleção de pares de indivíduos para cruzamento é um mecanismo de fundamental relevância no processo evolutivo. Ela atua juntamente com os demais mecanismos de evolução visando gerar indivíduos cada vez mais adaptados na resolução do problema em questão e tem por objetivo copiar, de maneira simplificada, o que ocorre na seleção natural, dos seres vivos. Nos algoritmos genéticos existem diversas formas de se operar a seleção. O método da roleta é um deles, e estabelece que a probabilidade de um indivíduo ser selecionado para participar de um cruzamento é proporcional a sua aptidão.

Para aplicar o método da roleta é necessário definir a aptidão acumulada por indivíduo na geração G.

$$Aac_i^G = \sum_{k=1}^i A_k^G \quad \text{Eq. 2.7}$$

O método da roleta estabelece que a probabilidade de um indivíduo ser selecionado para realizar o cruzamento é proporcional a sua aptidão e dada por:

$$PC_i^G = \frac{A_i^G}{Aac^G} \quad \text{Eq. 2.8}$$

Desta forma verifica-se que:

$$\sum_{i=1}^{NP} PC_i^G = 1 \quad \text{Eq. 2.9}$$

A seleção é feita realizando sorteios de $2 \times NP$ números aleatórios (RND_k ; $k = 1, \dots, 2 \times NP$) entre 0 e Aac_{NP}^G .

Desta forma, o número sorteado está necessariamente entre duas aptidões acumuladas, definindo o indivíduo selecionado como sendo aquele com a aptidão acumulada imediatamente superior ao valor sorteado.

Portanto, caso:

$$Aac_{i-1}^G < RND_k \leq Aac_i^G \quad i = 1 \dots NP \quad \text{Eq. 2.10}$$

Então o indivíduo sorteado para participar do processo de cruzamento é o de índice i . Os índices dos indivíduos sorteados são guardados na variável $S_{(k)}$, e posteriormente são utilizados para a formação dos pares que serão cruzados.

$$S_{(k)} = i \quad \text{Eq. 2.11}$$

Portanto os pares de indivíduos ficam definidos:

$$\vec{X}_{S(1)}^G \text{ e } \vec{X}_{S(2)}^G; \dots; \vec{X}_{S(2 \cdot NP - 1)}^G \text{ e } \vec{X}_{S(2 \cdot NP)}^G \quad \text{Eq. 2.12}$$

De maneira mais geral os pares selecionados são definidos por:

$$\vec{X}_{S(2i-1)}^G \text{ e } \vec{X}_{S(2i)}^G \quad i = 1, \dots, NP \quad \text{Eq. 2.13}$$

A Figura 2.2 mostra um exemplo de como a aptidão acumulada pode ser utilizada para a realização dos sorteios. Um valor do eixo vertical é aleatoriamente sorteado, definindo o indivíduo selecionado para o cruzamento no eixo horizontal.

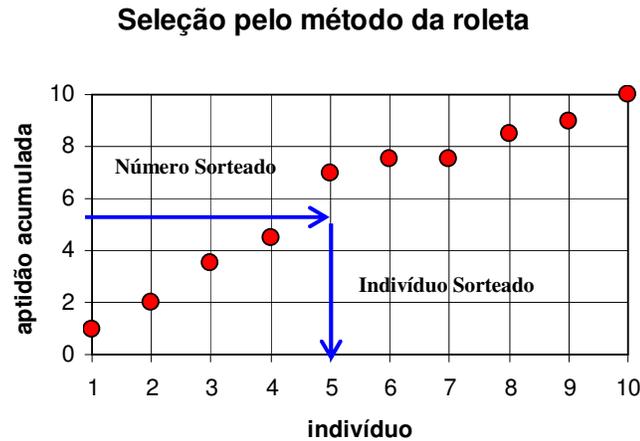


Figura 2.2 - Método da Roleta

Após a seleção dos pares é importante definir como serão realizados os cruzamentos. Novamente, existem diversas maneiras de se operar o cruzamento entre indivíduos. Para o exemplo em estudo poder-se-ia cruzar dois indivíduos fazendo-se a média a entre os componentes dos vetores de posicionamento. Desta forma, como resultado do cruzamento dos indivíduos $\vec{X}_{S(2i-1)}^G$ e $\vec{X}_{S(2i)}^G$ teríamos:

$$\vec{X}_i^{G+1} = \left(\frac{x_{1,S(2i-1)}^G + x_{1,S(2i)}^G}{2}, \frac{x_{2,S(2i-1)}^G + x_{2,S(2i)}^G}{2} \right) \quad \text{Eq. 2.14}$$

O cruzamento poderia, ainda, ser feito através da permutação das componentes dos vetores de posicionamento. Assim, teríamos:

$$\vec{X}_i^{G+1} = (x_{1,S(2i-1)}^G, x_{2,S(2i)}^G) \text{ ou } \vec{X}_i^{G+1} = (x_{1,S(2i)}^G, x_{2,S(2i-1)}^G) \quad \text{Eq. 2.15}$$

A escolha ou definição do operador de cruzamento deve ser feita visando à adequabilidade do operador no problema em questão. Este operador é um importante instrumento no processo de otimização e é responsável, em parte, por sua eficiência e pela confiabilidade da resposta.

Outro ponto importante nos processos de otimização por algoritmos genéticos é a mutação. Ela opera geralmente, após a realização dos cruzamentos incidindo nos indivíduos ou diretamente

sobre os genes. A atuação da mutação dos indivíduos é controlada por uma taxa que representa a porcentagem da população ou dos genes que irão sofrer mutação. A função da mutação é realizar pequenas alterações em um indivíduo para conferir maior diversidade genética à população. No exemplo em questão a mutação poderia agir sobre uma parcela da população alterando um ou os dois genes de um indivíduo para um valor aleatório válido. Este procedimento amplia efetivamente a região de busca do processo de otimização dando confiabilidade à resposta.

A população gerada desta forma inicia uma nova iteração e o processo prossegue até que se atinja o número máximo de iterações conforme mostra o fluxograma da Figura 2.3³.

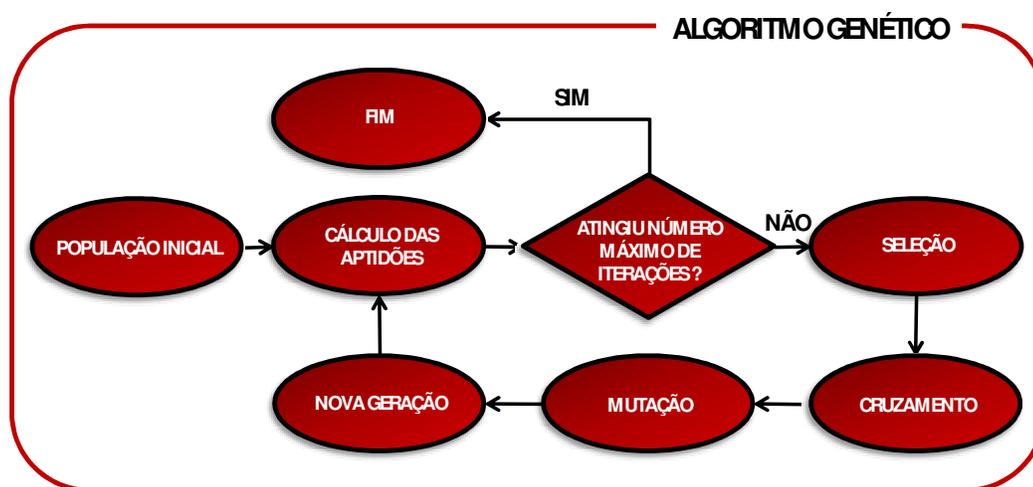


Figura 2.3 – Fluxograma para um algoritmo genético simples

2.6.3 Implementação de Algoritmos Genéticos

Os algoritmos genéticos possuem uma grande flexibilidade para implementações. Um mesmo problema pode ser abordado por diferentes variações deste tipo de técnica de otimização. Esta é uma característica muito interessante já que torna possível a modelagem da implementação para ajustar-se com as necessidades do problema. Por exemplo, problemas de otimização que envolvem simulações numéricas geralmente requerem um tempo elevado para o cálculo das funções-objetivo, portanto, torna-se interessante implementar um algoritmo genético com atenção

³A eficiência do processo de evolução nos algoritmos genéticos é fortemente dependente da representação cromossômica e dos operadores genéticos utilizados. Neste trabalho, estes itens são construídos fundamentados no conhecimento da engenharia do problema para acelerar o processo de evolução. No Item 4.2.5 são descritos em detalhes.

especial à eficiência do processo. Com os algoritmos genéticos, é possível realizar este tipo de moldagem de forma a ganhar eficiência sem perder a eficácia do processo. Nos algoritmos genéticos, o balanço entre eficiência e eficácia pode ser feito tanto através da definição e controle dos operadores genéticos, quanto na definição da representação cromossômica dos indivíduos a serem otimizados, como será abordado nos capítulos subseqüentes.

2.7 Integração com Avaliação Econômica

O desempenho de estratégias de produção pode ser avaliado ou quantificado de diferentes maneiras. Frequentemente são utilizados indicadores financeiros como valor presente líquido (VPL), valor monetário esperado (VME), taxa interna de retorno (TIR) e retorno sobre investimento (ROI).

O desempenho pode ainda ser avaliado por medidas de produção como: produção de óleo acumulada, produção de água acumulada, fator de recuperação, razões de produção. Além disso, podem-se combinar várias medidas de desempenho para se criar uma função-objetivo composta.

Neste trabalho, é adotado como função-objetivo o valor monetário esperado (VME) do projeto. Nas situações onde é necessário medir os desempenhos dos poços, isto será feito de forma simplificada como será descrito, com maiores detalhes, nos itens subseqüentes.

Como para o cálculo do VME, é necessário utilizar os VPL do campo nos diversos modelos geológicos e sob os vários cenários econômicos, primeiramente será descrito o procedimento de cálculo do VPL.

2.7.1 VPL

A seguir são descritos os itens necessários para o cálculo do VPL.

Classes de Investimentos - INV

Os investimentos são subdivididos em classe com o objetivo de gerar a possibilidade de descontos diferenciados na tributação e nos impostos, e da contabilidade da depreciação de equipamentos. São consideradas as seguintes classes de investimentos.

- Investimentos na exploração, INVE.
- Investimentos na avaliação, INVA.
- Investimentos na construção dos poços, INVP.
- Investimentos em facilidades de produção, INVF.
- Investimentos no descomissionamento do campo, INVD.

Cada classe de investimento pode estar distribuída ao longo de tempo.

Receitas operacionais - RO

As receitas operacionais são advindas das curvas de produção de óleo e gás considerando os preços constantes ou com variação linear ao longo do tempo. Sendo assim a receita operacional para o ano i é dada por:

$$RO_i = PO_i \cdot PRDO_i + PG_i \cdot PRDG_i \quad \text{Eq. 2.16}$$

onde para o ano i temos:

- PO_i – Preço de venda para o óleo
- PG_i – Preço de venda para o gás
- $PRDO_i$ – Produção de óleo
- $PRDG_i$ – Produção de gás

Custos operacionais - CO

Os custos operacionais são contabilizados da considerando as curvas de produção de óleo, gás e água além da curva de injeção de água conforme a seguinte expressão:

$$CO_i = CPO_i \cdot PRDO_i + CPG_i \cdot PRDG_i + CPA_i \cdot PRDA_i + CIA_i \cdot INJ_i \quad \text{Eq. 2.17}$$

onde para o ano i temos:

- CPO_i – Custo de produção do óleo
- CPG_i – Custo de produção do gás
- CPA_i – Custo de produção de água

- CIA_i – Custo de injeção de água
- PRDA_i – Produção de água
- INJ_i – Injeção de água

Royalties - ROY

Os royalties incidem diretamente na receita bruta com alíquota constante (na legislação em vigor, TXROY = 10%). Desta forma, tem-se:

$$ROY_i = TXROY \cdot RO_i \quad \text{Eq. 2.18}$$

PIS/PASEP COFINS - PPC

Da mesma forma que os royalties o PIS/PASEP COFINS incidem sobre a receita operacional do campo com alíquota constante, TXPPC.

$$PPC_i = TXPCC \cdot RO_i \quad \text{Eq. 2.19}$$

Depreciação - DEP e DEP₂

Neste trabalho é adotado o modelo de depreciação uniforme. Para fins de dedução do imposto de renda todo o investimento em facilidades de produção é depreciável em um determinado número de anos, NADEP. Sendo assim:

$$DEP_i = INV F / NADEP \quad i = i_{ip}, \dots, i_{ip} + NADEP \quad \text{Eq. 2.20}$$

Onde i_{ip} é o i relativo ao início da produção.

Para fins de dedução da participação especial, o investimento na construção dos poços também pode sofrer depreciação. Desta forma:

$$DEP2_i = (INV F + INV P) / NADEP \quad i = i_{ip}, \dots, i_{ip} + NADEP \quad \text{Eq. 2.21}$$

Participação especial - PE

A participação especial é um tributo que incide na receita operacional de campos de grande produtividade. Ela incide sobre a receita operacional, RO_i, descontados o custo operacional, CO_i, os investimentos em exploração e avaliação do campo, INVE_i e INVA_i, e as depreciações tanto das facilidades de produção quanto dos poços, DEP_{2i}. A taxa efetiva da participação especial TXPE_i é calculada conforme a regulamentação em vigor e é detalhada em anexo e depende do volume produzido no trimestre e da localização da jazida (terra, marítima de águas rasas e marítima de águas profundas). Como simplificação o cálculo da participação especial será anual e não trimestral como regulamenta a ANP.

$$PE_i = TXPE_i \cdot (RO_i - CO_i - INVE_i - INVA_i - DEP_{2i}) \quad \text{Eq. 2.22}$$

Imposto de renda e contribuição social - IR e CS

O imposto de renda e a contribuição social incidem sobre a mesma base de cálculo chamada lucro tributável. Para o cálculo do lucro tributável deve-se deduzir da receita operacional, RO, o custo operacional, CO, os royalties, ROY, o PIS/PASEP COFINS, PPC, a participação especial, PE, a depreciação das facilidades de produção, DEP, e os investimentos em exploração, INVE, e avaliação do campo, INVA. É realizado ainda o provisionamento dos investimentos no descomissionamento do campo e deduzi-los. As alíquotas em vigor são:

- Imposto de renda – TXIR = 25%
- Contribuição social – TXCS = 9%

Desta forma:

$$IR_i = TXIR_i \cdot (RO_i - CO_i - ROY_i - PPC_i - PE_i - INVE_i - INVA_i - INVD_i - DEP_i) \quad \text{Eq. 2.23}$$

$$CS_i = TXCS_i \cdot (RO_i - CO_i - ROY_i - PPC_i - PE_i - INVE_i - INVA_i - INVD_i - DEP_i) \quad \text{Eq. 2.24}$$

Deduções

Um ponto importante a respeito das deduções deve ser mencionado. Em projetos de exploração de campos de petróleo grande parcela dos investimentos é realizada, geralmente, antes do início da produção do campo. Portanto a dedução dos investimentos para fins de abatimento do imposto de renda é dificultada, já que investimentos e receitas ocorrem em períodos fiscais distintos. Para que tal incentivo não perca a função em projetos de exploração de campos de petróleo, a legislação permite que se faça a dedução de investimentos realizados em períodos fiscais passados, seguindo para isso algumas regras e limites. A legislação, entretanto, é um pouco intrincada e para ser aplicada a rigor se deve subdividir os investimentos em mais classes. Neste trabalho uma simplificação é feita para se evitar a complexidade do cálculo rigoroso. Neste sentido, é considerado não haver limites para deduzir do imposto de renda, contribuição social e participação especial os investimentos dedutíveis realizados em períodos fiscais passados.

Fluxo de Caixa

Sendo assim o fluxo de caixa para o ano i pode ser montado:

$$FC_i = RO_i - CO_i - ROY_i - PPC_i - PE_i - INV_i - IR_i - CS_i \quad \text{Eq. 2.25}$$

onde INV_i é a soma de todas as classes de investimento para o ano i

VPL

Para o cálculo do VPL o fluxo de caixa é descontado à taxa mínima de atratividade, TMA, até o ano inicial do projeto ($i=0$).

$$VPL_n = \sum_{i=0}^n \frac{FC_i}{(1 + TMA)^i} \quad \text{Eq. 2.26}$$

onde n é o tempo, em anos, do projeto.

2.7.2 VME total

A consideração de incertezas em projetos de exploração e produção de petróleo geralmente é feita através do seu VME. Para isso deve-se, primeiramente, calcular o VPL da estratégia em cada modelo geológico e para cada cenário econômico. Desta forma, obtém-se uma matriz de VPL.

$$VPL_{i,j} = \left[\begin{array}{cccc|c} VPL_{1,1} & VPL_{1,2} & VPL_{1,3} & VPL_{1,4} & VPL_{1,n} \\ VPL_{2,1} & VPL_{2,2} & VPL_{2,3} & VPL_{2,4} & VPL_{2,n} \\ VPL_{3,1} & VPL_{3,2} & VPL_{3,3} & VPL_{3,4} & VPL_{3,n} \\ \hline VPL_{m-1,1} & VPL_{m-1,2} & VPL_{m-1,3} & VPL_{m-1,4} & VPL_{m-1,n} \\ VPL_{m,1} & VPL_{m,2} & VPL_{m,3} & VPL_{m,4} & VPL_{m,n} \end{array} \right] \quad \text{Eq. 2.27}$$

sendo $VPL_{i,j}$ o VPL da estratégia no modelo geológico i no cenário econômico j

$$VPL_{i,j} \text{ para } 1 \leq i \leq m \text{ e } 1 \leq j \leq n \quad \text{Eq. 2.28}$$

onde m e n são respectivamente o número de modelos geológicos e o número de cenários econômicos considerados na análise de incerteza.

Para cada modelo geológico e cenário econômico deve-se atribuir uma probabilidade de ocorrência.

Sendo assim temos para os modelos geológicos:

$$\vec{P}_i^g = [P_1^g \quad P_2^g \quad P_3^g \quad P_4^g \mid P_m^g] \text{ para } 1 \leq i \leq m \quad \text{Eq. 2.29}$$

onde \vec{P}_i^g é a probabilidade de ocorrência do i -ésimo modelo geológico, de forma que:

$$\sum_{i=1}^m \bar{P}_i^g = 1 \quad \text{Eq. 2.30}$$

Da mesma forma deve-se atribuir uma probabilidade para cada cenário econômico.

$$\bar{P}_j^e = [P_1^e \quad P_2^e \quad P_3^e \quad P_4^e \mid P_n^e] \text{ para } 1 \leq j \leq n \quad \text{Eq. 2.31}$$

onde também existe a restrição

$$\sum_{j=1}^n \bar{P}_j^e = 1 \quad \text{Eq. 2.32}$$

Desta forma pode-se construir uma matriz de probabilidade de ocorrência simultânea de um modelo geológico i e de um cenário econômico j da seguinte forma:

$$\bar{P}_{i,j}^{ge} = P_i^g \cdot P_j^e \text{ para } 1 \leq i \leq m \text{ e } 1 \leq j \leq n \quad \text{Eq. 2.33}$$

A matriz de probabilidade, portanto pode ser escrita:

$$\bar{P}_{i,j}^{ge} = \begin{bmatrix} P_{1,1}^{ge} & P_{1,2}^{ge} & P_{1,3}^{ge} & P_{1,4}^{ge} & P_{1,n}^{ge} \\ P_{2,1}^{ge} & P_{2,2}^{ge} & P_{2,3}^{ge} & P_{2,4}^{ge} & P_{2,n}^{ge} \\ P_{3,1}^{ge} & P_{3,2}^{ge} & P_{3,3}^{ge} & P_{3,4}^{ge} & P_{3,n}^{ge} \\ P_{m-1,1}^{ge} & P_{m-1,2}^{ge} & P_{m-1,3}^{ge} & P_{m-1,4}^{ge} & P_{m-1,n}^{ge} \\ P_{m,1}^{ge} & P_{m,2}^{ge} & P_{m,3}^{ge} & P_{m,4}^{ge} & P_{m,n}^{ge} \end{bmatrix} \quad \text{Eq. 2.34}$$

O cálculo do VME é realizado da seguinte forma:

$$VME = \sum_{i=1}^m \sum_{j=1}^n P_{i,j}^{ge} \cdot VPL_{i,j} \text{ para } 1 \leq i \leq m \text{ e } 1 \leq j \leq n \quad \text{Eq. 2.35}$$

O VME calculado pela Eq. 2.35 é chamado VME total.

Com o objetivo de separar os efeitos das incertezas geológicas das econômicas, são calculados VME geológico para um cenário econômico e o VME econômico para um modelo geológico.

2.7.3 VME geológico para um cenário econômico

O VME geológico (VMEG) é calculado considerando um dos cenários econômicos por vez, ou seja, calcula-se o VME analisando apenas as incertezas geológicas. Desta forma, são gerados tantos VME geológicos quanto forem os cenários econômicos.

$$VMEG_j = \sum P_i^g \cdot VPL_{i,j} \text{ para } 1 \leq i \leq m \text{ e } 1 \leq j \leq n \quad \text{Eq. 2.36}$$

2.7.4 VME econômico para um modelo geológico

Da forma semelhante pode-se definir o VME econômico (VMEE) como sendo o VME para um modelo geológico considerando apenas as incertezas econômicas. Sendo assim:

$$VMEE_i = \sum P_j^e \cdot VPL_{i,j} \text{ para } 1 \leq i \leq m \text{ e } 1 \leq j \leq n \quad \text{Eq. 2.37}$$

Capítulo 3 - Revisão Bibliográfica

Neste capítulo, é feita uma revisão da bibliografia existente a respeito dos tópicos abordados neste trabalho. São analisados trabalhos referentes à seleção e otimização de estratégias de produção bem como a aplicação de algoritmos genéticos neste tipo de problema. Ao final do capítulo, são revistos trabalhos a respeito da consideração de incertezas em processos de otimização de estratégias de produção.

3.1 Seleção de Estratégia de Produção Assistida

O processo de seleção da estratégia de produção a ser adotada em um plano de desenvolvimento é uma tarefa extremamente trabalhosa que envolve diversos ramos da engenharia de petróleo em um complexo fluxograma de tomadas de decisão.

Mezzomo (2005) propôs uma metodologia robusta e flexível para subsidiar as tomadas de decisão em um processo de seleção de estratégias de produção. Na abordagem proposta, etapas de seleção e otimizações, manuais e automatizadas, são combinadas visando à definição dos itens que compõe uma estratégia de produção. Ao processo proposto estão associados procedimentos de avaliação de risco e ferramentas de análise de decisão onde é possível considerar riscos de ordem técnica, operacional, geológica e econômica.

O processo de otimização proposto por Mezzomo vai além da etapa inicial da definição da estratégia de produção e propõe re-otimizações nas fases de desenvolvimento e de produção do campo. Nestas fases, os níveis de incertezas, foram reduzidos em relação à fase de exploração, o que justifica novas otimizações considerando este novo nível de incerteza.

A Figura 3.1 mostra um diagrama que esquematiza o processo de seleção de estratégias de produção proposto pela autora. Este diagrama ilustra o processo de seleção de forma simplificada, que a rigor, possui um caráter iterativo onde é permitido que algumas fases possam ser revisadas, não necessariamente na ordem indicada. Neste diagrama, pode ser observado a potencialidade do emprego de procedimentos de otimização em todas as fases listadas do processo.

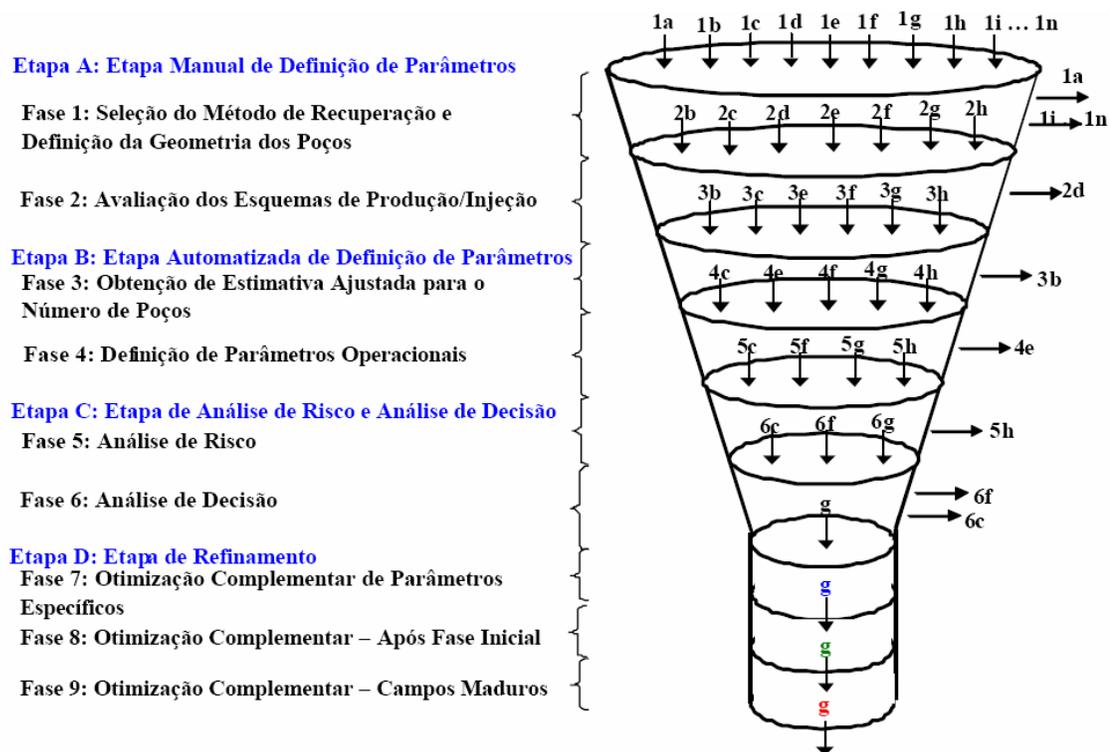


Figura 3.1 – Etapas do processo de seleção e otimização de estratégias de produção. (Mezzomo, 2005)

3.2 Metodologias de Otimização de Estratégias de Produção

Grandes esforços têm sido feitos no sentido de propor metodologias de otimização de estratégias de produção que utilizem tanto procedimentos manuais quanto automatizados. Estes procedimentos se aplicam, não somente no refinamento da estratégia selecionada como também no próprio processo de seleção.

Os primeiros esforços, de importância histórica, foram no sentido de se obter formulações analíticas para o espaçamento ótimo entre poços. Nesta linha foram os trabalhos de Clark *et al.* (1944) e Arps *et al.* (1967). Nestes trabalhos, os autores procuram ajustar curvas analíticas a dados históricos de campos reais, visando definir uma espécie de correlação empírica.

Numa segunda fase os trabalhos começaram a se valer de simulação numérica de fluxo para prever o comportamento do reservatório e inferir o seu desempenho financeiro.

Nystad (1985) utilizou simulação numérica para realizar a otimização da quantidade e de posicionamentos de poços de uma forma simplificada. Em seu trabalho, Nystad procurou desenvolver uma metodologia para a otimização do VPL (calculado simplificadamente) através de dois parâmetros: espaçamento entre os poços e vazão de produção. A superfície de resposta foi construída através de experimentos numéricos gerados por simulação de fluxo.

Numa terceira fase os trabalhos começaram a apresentar preocupações com relação ao número de simulações necessárias para se realizar os processos de otimização. Mostrava-se a necessidade de realizar otimizações cada vez mais precisas com um número cada vez menor de simulações.

Damsleth *et al.* (1991) realizaram planejamento estatístico para adquirir informações relevantes a respeito do comportamento da função-objetivo em relação a importantes aspectos do reservatório (permeabilidades horizontal e vertical, volume de óleo *in situ*, curvas de permeabilidade relativas, compartimentação do reservatório e etc.) com um número reduzido de simulações. Com isso foi possível realizar o processo de otimização através de uma aproximação polinomial (metamodelo ou *proxy model*) em lugar da simulação numérica.

Uma quarta fase pode ser identificada no processo de evolução dos sistemas de otimização de estratégias de produção. Nesta fase, os processos de otimização tendem a ficar mais precisos e sofisticados. O problema relativo à quantidade de simulações necessárias para a realização da otimização é contornado não somente por simplificações do processo, mas também através da utilização de computação paralela diminuindo consideravelmente o tempo total do processo.

A busca por eficácia e a possibilidade da utilização de computação paralela guia os trabalhos no sentido de utilizar técnicas de otimização cada vez mais sofisticadas.

Beckner e Song (1995) empregaram uma técnica baseada em *simulated annealing* para definir o posicionamento e cronograma de perfuração de 12 poços horizontais em um projeto de desenvolvimento de um campo marítimo.

Pedroso Jr. (1999) utilizou o recurso de computação paralela para otimizar a quantidade e os posicionamentos de poços em um reservatório em estágio inicial de produção.

3.3 Metodologias de Otimização Manuais

Schiozer *et al.* (2002) desenvolveram uma metodologia e uma ferramenta computacional que visa melhorar estratégias de produção (refinamento). A metodologia classifica os poços produtores em termos de seis índices de desempenho: valor presente líquido (VPL), produções acumuladas de óleo, gás e água (N_p , G_p e W_p respectivamente), vazão média de óleo (QoM) e um índice referente à qualidade do reservatório na região do poço (M_p). Para facilitar a análise, é construído um mapa de classificação dividido em regiões que definem o desempenho do poço relativo a estes índices.

Seguindo um critério quantitativo, cada poço produtor do campo é alocado em uma posição bem definida dentro deste mapa. A depender da posição ocupada pelo poço, a metodologia propõe realizar alterações do tipo:

- Exclusão do poço
- Alteração do intervalo de completação
- Aumento do limite da vazão de óleo
- Alteração do cronograma de abertura do poço
- Alteração do posicionamento do poço
- Conversão para poço horizontal
- Conversão para poço injetor
- Abandono do poço

Estas alterações na estratégia de produção devem seguir uma seqüência de priorização. A Figura 3.2 mostra o mapa de classificação com a indicação do caminho de alterações prioritárias sugeridas pela metodologia em função da posição ocupada pelo poço no mapa de classificação.

Nakajima (2003) propôs aperfeiçoamentos na metodologia desenvolvida por Schiozer *et al.* (2002) visando incorporar técnicas que permitissem sugerir alterações em poços horizontais.

Os trabalhos desenvolvidos nesta linha, além de serem úteis em processos de otimizações manuais, podem subsidiar processos de otimizações automatizadas ou assistidas de estratégias de produção, no sentido de conferir maior eficiência aos processos. Ao realizar a otimização de

estratégias de produção manualmente, se ganha sensibilidade em relação ao problema permitindo que se conheça os aspectos mais impactantes no desempenho da estratégia.

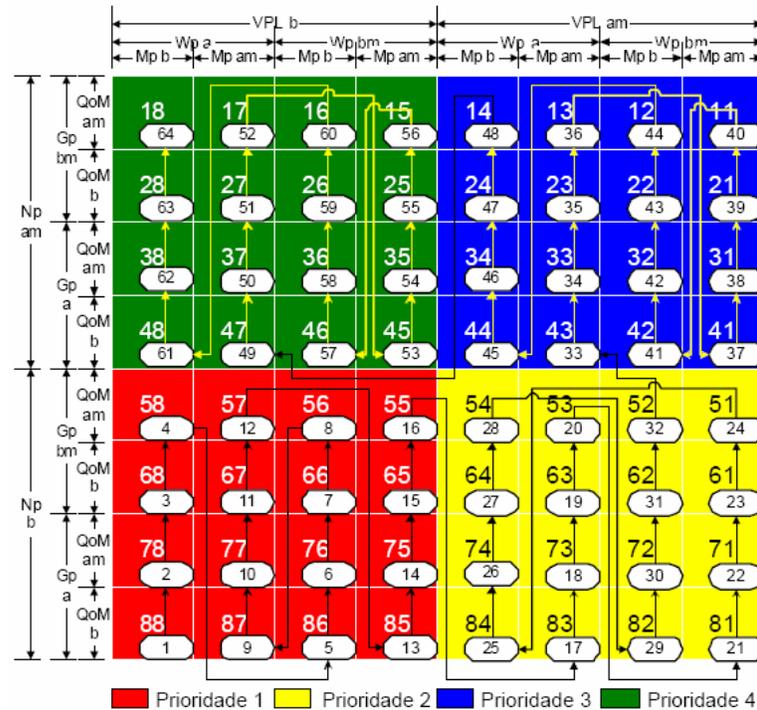


Figura 3.2 – Mapa de classificação – caminho de prioridades de alterações (Schiozer *et al.*, 2002)

3.4 Aplicação de Algoritmos Genéticos em Problemas de Otimização de Estratégias de Produção

Bittencourt (1997) desenvolveu um algoritmo que mescla técnicas de busca dispersa como algoritmo genético, método polítipo e busca tabu para otimizar planos de desenvolvimento de campos de petróleo. Sua metodologia possui um caráter bastante amplo considerando vários itens que compõe uma estratégia de produção. Porém, cada item é abordado de maneira simplificada para possibilitar a realização de uma análise mais abrangente.

Güyağüller *et al.* (2000) utilizaram algoritmo genético associado a ferramentas baseadas na teoria da utilidade para otimizar o posicionamento de poços em reservatórios.

Almeida (2007) propôs utilizar algoritmo genético para realizar o controle pró-ativo de válvulas de poços inteligentes. Em seu trabalho, o algoritmo genético atua no sentido de

encontrar a configuração de abertura e fechamento das válvulas que evite a chegada prematura de fluidos indesejados nos poços produtores, otimizando o VPL do projeto.

Túpac *et al.* (2007) desenvolveram um sistema de otimização de quantidade e posicionamento de poços baseados em algoritmo genético bastante sofisticado. No algoritmo implementado as curvas de produção acumuladas de fluidos são obtidas tanto por simulação de fluxo quanto por aproximação polinomial (metamodelo ou *proxy model*). Uma parte da população de uma geração é submetida ao simulador de fluxo e outra a um modelo definido por aproximação polinomial. Os autores se valeram também de computação paralela para distribuir as simulações de fluxo com o intuito de ganhar tempo de processamento.

3.5 Otimização de Estratégias de Produção sob Incertezas

Newendorp (1975) apresentou os conceitos fundamentais e metodologias necessárias para consideração das incertezas e quantificação do risco em projetos de exploração de produção de campos de petróleo. Em seu livro são discutidos os princípios de probabilidade e estatística aplicados neste tipo de problema através de técnicas como simulação de Monte Carlo e árvore de derivação. São apresentados, ainda os conceitos de valor presente líquido e valor monetário esperado.

Steagall (2001) definiu uma metodologia para extrair, de uma série de realizações do modelo geológico, modelos representativos de percentis da função-objetivo. Estes modelos são chamados modelos geológicos representativos (MGR) e são representantes de intervalos de classes do histograma de frequência da função-objetivo. Geralmente são definidos três intervalos: pessimista, intermediário e otimista. Em alguns casos, cada intervalo de classe pode possuir mais de um representante.

Xavier (2004) com o propósito de calcular o valor de informação utiliza o conceito de MGR para otimizar estratégias de produção separadamente nos modelos pessimista, intermediário e otimista. As estratégias otimizadas nos MGR são permutadas para calcular os seus VME.

A permutação das estratégias otimizadas nos MGR para o cálculo do VME é a metodologia básica do processo de otimização de estratégias de produção sob incertezas, e será designada

neste trabalho por MADC. Neste trabalho é proposta uma metodologia, diferente da convencional, que visa conferir maior rigor a este processo.

Hayashi (2006) utilizou metodologia semelhante à utilizada por Xavier (2004) para o cálculo do valor da flexibilização do desenvolvimento de campos de petróleo por módulos.

Mezzomo (2005) incorporou a metodologia à análise de risco de projetos de desenvolvimento de campos sob incertezas.

Capítulo 4 - Metodologia

Neste capítulo é feita, primeiramente, uma descrição da metodologia de trabalho utilizada nesta dissertação, enumerando em etapas a seqüência seguida para alcançar os objetivos previamente definidos. Em seguida, são apresentadas a metodologia de otimização de estratégias de produção e a técnica para a consideração das incertezas ao longo de todo processo, bem como as rotinas implementadas com estes propósitos. E, finalmente, é descrito um procedimento genérico com a utilização das ferramentas desenvolvidas para indicar a seqüência de perfuração dos poços de desenvolvimento visando atingir um determinado objetivo.

4.1 Metodologia de Trabalho

Com a finalidade de se atingir com êxito os objetivos previamente definidos no Capítulo 1 desta dissertação é proposta a seguinte metodologia de trabalho:

- **Etapa 1 – Estudo da Superfície de Resposta de um Problema de Posicionamento de Poços**

Realizar um estudo simplificado de otimização de estratégia de produção em que seja possível definir o processo por $f : R^2 \rightarrow R$. Isso possibilita que a análise do comportamento da superfície de resposta seja feita de maneira visual. Com este propósito, é gerada uma superfície de resposta para um problema em que o domínio é o posicionamento de dois poços de uma estratégia de produção (R^2) e a imagem representa o VPL desta estratégia (R). A partir da análise desta superfície espera-se ser possível a realização da inferência qualitativa a respeito das características da superfície de resposta gerada por um problema mais geral $f : R^n \rightarrow R$, alvo de estudo deste trabalho. Este estudo visa verificar a adequabilidade da utilização dos algoritmos genéticos para realizar este tipo de otimização.

- **Etapa 2 – Otimização Determinística de Estratégias de Produção**

Desenvolver uma metodologia de otimização de estratégias de produção utilizando algoritmo genético com especial atenção à eficiência do processo. Para tanto, a otimização é feita

em passos onde o espaço solução é restringido para que uma solução satisfatória seja encontrada mais rapidamente. O propósito desta abordagem é reduzir o número de simulações necessárias para a otimização já que se espera que após a realização de um número pequeno de etapas, o processo convirja para uma solução robusta.

- **Etapa 3 – Otimização Probabilística de Estratégias de Produção**

Desenvolver uma técnica que permita que o processo de otimização seja completamente conduzido pelo valor monetário esperado (VME), com a intenção de dar uma abordagem mais precisa à manipulação das incertezas. Realizar processos de otimização em modelos com diferentes níveis de complexidade através da metodologia proposta e da MADC. Comparar os resultados obtidos quando a otimização é completamente guiada pelo VME (MADI) e quando a otimização é guiada pelo VPL dos diferentes contextos (MADC).

- **Etapa 4 – Estudo para Indicação da Seqüência de Perfuração dos Poços**

Utilizar as ferramentas geradas para o desenvolvimento da metodologia proposta para indicar a seqüência de perfuração dos poços de desenvolvimento de acordo com objetivos predefinidos.

- **Ferramenta Computacional**

Para a realização das etapas listadas acima é necessário implementar uma ferramenta computacional que realize de forma automatizada a otimização da estratégia de produção sob incertezas econômicas e geológicas. A implementação é feita por módulos que realizam etapas distintas durante o processo de otimização, gerenciados por uma rotina que interliga os módulos, dando continuidade ao processo.

4.2 Metodologia de Otimização de Estratégias de Produção

Neste item é apresentada a metodologia de otimização da quantidade e posicionamento dos poços de desenvolvimento baseada em algoritmos genéticos.

Primeiramente é apresentada a idéia básica para o processo de otimização e em seguida são descritos os itens que procuram conferir eficiência ao processo, incorporando à técnica clássica

dos algoritmos genéticos mecanismos fundamentados na engenharia do problema, visando à aceleração do processo evolutivo.

4.2.1 Descrição Geral

Os algoritmos genéticos representam uma técnica de busca por valor extremo global e geralmente estão associados a um elevado custo computacional. Este trabalho visa aplicar esta técnica na otimização da quantidade e posicionamento dos poços com adaptações que possibilitem aumentar a sua eficiência.

A primeira medida, neste sentido, é a realização da otimização em etapas. A presente metodologia propõe a alternância de etapas de otimização de quantidade e de posicionamento de poços, provocando um desmembramento do problema original. Este desmembramento possibilita restringir o espaço solução de cada etapa fazendo que a solução seja obtida mais rapidamente. Esta redução do espaço solução permite que se trabalhe com pequenas populações por poucas gerações, sem que se perca a sua representatividade, possibilitando um aumento de eficiência em termos globais.

Outro ponto de grande importância para a realização do processo de otimização de forma eficiente é a representação cromossômica das soluções do problema. Com uma representação cromossômica adequada é possível realizar uma busca próxima à configuração inicial, reduzindo a possibilidade de gerar indivíduos de desempenhos evidentemente baixos, e conferindo maior velocidade ao processo. Como uma representação deste tipo pode restringir demais a região de busca da solução, é adotado um procedimento, como será descrito em detalhes nos próximos itens, que permite que a estrutura do cromossomo sofra pequenas alterações durante uma etapa de otimização. A metodologia permite ainda que alterações mais significativas sejam feitas de uma etapa para outra diversificando, ainda mais, a busca.

Uma terceira adaptação permite que se realize o processo de otimização dos posicionamentos dos poços de forma ainda mais eficiente. Na técnica clássica dos algoritmos genéticos (Goldberg, 1989), um filho é gerado a partir do material genético dos pais sem que haja uma tendência predefinida de herança destes genes, portanto, o filho tem igual probabilidade de herdar um determinado gene do pai ou da mãe. O processo imita, em termos gerais, o cruzamento

dos seres vivos, onde os filhos são uma mistura praticamente aleatória do material genético dos pais. A metodologia presente propõe que os genes tenham uma medida de desempenho específica para que os filhos gerados herdem os melhores genes dos seus pais. Mas como toda adaptação, isto pode trazer resultados indesejados como, por exemplo, empregar uma tendência viciosa ao processo de otimização. Portanto, somente parte da população será submetida a este tipo de cruzamento.

4.2.2 Função-Objetivo

A função-objetivo a ser adotada nos processos de otimização considerando um único modelo geológico e um cenário econômico determinístico é o valor presente líquido (VPL) calculado conforme descrição do Item 2.7.1. Quando houver incertezas geológicas e econômicas passa-se a adotar como função-objetivo o valor monetário esperado (VME). Mas para a adoção do VME como função-objetivo é necessário desenvolver uma técnica que permita medir o VME de uma estratégia para todos os pontos de avaliação requeridos pelo processo de otimização. Esta técnica é desenvolvida no Item 4.3.

4.2.3 Desempenhos dos Poços

Como veremos com mais detalhes nos itens seguintes, para guiar os processos de otimização com eficiência é necessário medir os desempenhos dos poços. Entretanto, não existe consenso a respeito de como deve ser medido o desempenho financeiro de um poço. Sendo assim, este trabalho propõe e utiliza duas formas distintas de medida de desempenho de poços, com o objetivo de empregá-las de maneira conveniente na condução do processo de otimização.

Uma forma rigorosa, e que não é utilizada neste trabalho (mas deve ser mencionada para fundamentar a proposição das outras), de quantificar o desempenho financeiro de poços é medir a influência que um determinado poço tem no VPL do campo. Para isso é calculada a diferença entre o VPL do campo, com e sem a presença do poço em questão. Para ser rigoroso, o VPL do campo sem a presença do poço deve ser otimizado, ou seja, os poços remanescentes devem ser reposicionados para que se possa quantificar sua real influência no desempenho global do campo (considera-se que somente estratégias otimizadas têm potencial de serem implementadas). Entretanto, este procedimento de cálculo é extremamente custoso e, portanto, proibitivo de ser

utilizado em processos de otimização, sendo útil apenas quando se quer realizar uma análise rigorosa do desempenho de um poço específico. Para se medir o desempenho de um poço com o intuito de guiar um processo de otimização deve-se optar por simplificações que permitam avaliar, de forma rápida, estes desempenhos.

A simplificação mais imediata que surge é a de calcular a diferença entre o VPL do campo, com e sem o poço, sem que a estratégia sem o poço seja otimizada. Neste trabalho, esta diferença será designada por: influência do poço no desempenho do campo (IDC). A adoção deste procedimento permite medir o desempenho financeiro de um poço com uma simulação adicional (em relação à simulação necessária para medir o desempenho do campo), e é utilizada para conduzir o processo de otimização da quantidade de poços de uma estratégia de produção.

Neste momento, torna-se importante uma análise do sinal do IDC. Um poço com IDC negativo indica que a sua exclusão da estratégia de produção acarretará, necessariamente, em uma melhora de desempenho do campo. Por outro lado, um poço com IDC positivo não garante que a sua exclusão piorará o desempenho do campo. A recíproca, neste caso, não é verdadeira, já que é possível que, após um remanejamento adequado dos poços remanescentes, o desempenho do campo sem o poço supere o original.

Existem etapas do processo de otimização em que não é conveniente realizar simulações adicionais para se medir o desempenho de poços, já que uma análise mais simplificada já é suficiente para os objetivos daquela etapa específica. Este é o caso da medida de desempenho de poços necessária para guiar o processo de otimização do posicionamento dos poços. Neste sentido, o desempenho financeiro do poço é avaliado através de uma única simulação (a mesma realizada para avaliar o desempenho do campo). Com este propósito, são utilizadas as curvas de produção de óleo, gás e água de cada poço produtor. Um fluxo de caixa é montado considerando as receitas advindas das curvas de produção de óleo e gás, e os custos associados à produção de água do poço e o compartilhamento dos demais dispêndios do campo. Os gastos com o CAPEX e OPEX (inclusive impostos e tributos) do campo, são compartilhados de forma ponderada em relação ao investimento total feito em cada poço produtor. O fluxo de caixa, montado desta forma, é descontado à taxa mínima de atratividade gerando o que chamaremos de indicador de desempenho financeiro (IDF) para o poço produtor (não é possível calcular o IDF para poços injetores).

$$IDF_n^k = \sum_{i=0}^n \frac{RO_i^k - CO_i^k - \omega^k \cdot DC_i}{(1 + TMA)^i} \quad \text{Eq. 4.1}$$

onde:

- RO_i^k e CO_i^k são respectivamente receita e custo operacionais gerados pelo k-ésimo poço no i-ésimo período.
- DC_i são os dispêndios compartilhados do campo para o i-ésimo período.
- ω^k é o peso atribuído ao k-ésimo poço proporcionalmente ao seu investimento.
- TMA é a taxa mínima de atratividade.
- n é o período no qual está sendo medido o IDF, geralmente n é igual à quantidade total de períodos.

É possível verificar que:

$$\sum_{k=1}^{NP} IDF_n^k = VPL \quad \text{Eq. 4.2}$$

onde o índice k refere-se ao k-ésimo poço produtor e n é o número de poços produtores no campo.

É importante mencionar que o objetivo de compartilhar os dispêndios do campo ponderadamente em relação ao investimento total feito no poço é gerar uma maior cobrança de desempenho nos poços em que foram feitos os maiores investimentos.

Contrariamente ao IDC, a análise do sinal do IDF não traz muita informação a respeito da alteração do VPL do campo caso um poço com IDF positivo ou negativo seja excluído. O IDF é útil para classificar poços produtores de uma determinada estratégia de produção e comparar os desempenhos de um mesmo poço produtor em posições diferentes do reservatório. Portanto, não é aconselhável indicar a exclusão de um poço baseado no fato deste poço possuir o pior IDF do campo, ou um IDF negativo ou mesmo possuir o menor IDF do campo. Contudo, ele é útil para guiar, juntamente com outros critérios, o processo de otimização do posicionamento dos poços produtores.

4.2.4 Desempenhos Esperados dos Poços

Quando a função-objetivo do processo de otimização é o VME, os desempenhos dos poços passam a ser medidos em termos de desempenhos esperados: IDC esperado e IDF esperado, e os seus cálculos são feitos seguindo o procedimento semelhante ao realizado para o cálculo do VME.

4.2.5 Algoritmo Genético

Neste item serão apresentadas as principais características dos algoritmos genéticos montados para a resolução dos problemas de otimização dos posicionamentos e da quantidade dos poços.

Otimização do Posicionamento dos Poços

- Representação Cromossômica

A representação cromossômica de um indivíduo (solução viável) é um dos itens mais importantes de uma implementação de algoritmo genético. Uma representação inadequada pode gerar problemas com relação à eficiência do processo de otimização bem como com relação a confiabilidade da resposta. Nos dois itens seguintes, é descrita a representação cromossômica utilizada no algoritmo genético implementado para realizar a otimização dos posicionamentos dos poços no reservatório.

A representação cromossômica do problema de otimização do posicionamento dos poços é feita com o intuito de reduzir o número de arranjos possíveis, e conseqüentemente melhorar a eficiência do processo. Para isso, é realizada uma setorização do reservatório. São definidas sub-regiões (genes) a partir da estratégia inicial, pelo critério do vizinho mais próximo. Cada setor do reservatório que engloba algumas células da malha de simulação delimita uma sub-região do reservatório onde é permitido, durante o processo, alocar o poço que a definiu. Este procedimento possui duas conseqüências importantes no processo de otimização. A primeira delas é que a probabilidade de gerar indivíduos de baixíssimo desempenho fica reduzida, já que são feitas apenas pequenas alterações na estratégia inicial. Isso confere uma maior velocidade de evolução da otimização.

A outra consequência é que a delimitação de sub-regiões do reservatório para alocação dos poços pode restringir o domínio de busca da solução, conduzindo o processo para um mínimo local. Mas este inconveniente pode ser contornado com a adoção de um procedimento que confere maior flexibilidade na alocação dos poços. Com este intuito, o processo de otimização é guiado até que se encontre um arranjo que supere o melhor indivíduo. Neste momento, uma nova setorização do reservatório é feita. Para isso, novos setores são definidos seguindo o critério do vizinho mais próximo, tomando como base esta nova melhor estratégia. Desta forma, os poços tendem a serem centralizados nos setores conferindo maior liberdade de alocação em todas as direções. Esta abordagem fornece maior flexibilidade ao processo. Os poços, apesar de terem as suas possibilidades de alocações restringidas numa mesma população, tendem a possuir maior liberdade ao longo do processo todo.

Procedimento semelhante é dado a poços horizontais. A referência para a definição dos setores, neste caso, passa a ser o centro do poço. O processo ganha mais um grau de liberdade que é a rotação do poço em relação ao seu centro. Com isso, é possível alterar o posicionamento de poços horizontais através da sua translação e rotação em relação ao seu centro. Durante o processo alteradas as camadas de completação dos poços nem seus comprimentos.

Portanto para esta etapa do problema de otimização o cromossomo é a representação vetorial dos posicionamentos dos poços no reservatório. Desta forma, o problema de otimização fica definido por:

$$\max \left\{ f(\vec{X}) : \vec{X} = (x_1, \dots, x_n); 1 \leq x_j \leq x \max_j^G; \vec{X} \in Z_+^{*n} \right\} \quad \text{Eq. 4.3}$$

A função $f(\vec{X})$ representa o VPL da estratégia \vec{X} . O vetor \vec{X} (cromossomo composto por n genes) define as posições dos n poços no reservatório. Cada elemento do vetor define a posição que um poço ocupa dentro das sub-regiões do reservatório. A Figura 4.1 mostra um exemplo da representação vetorial de uma estratégia definida pelo vetor $X=(11,7,9,5,9,8,10,9,8,8)$. É mostrado em destaque o poço quatro ocupando a quinta casa da quarta sub-região.

O valor $x \max_j^G$ representa o número de posições que o poço j pode ser locado na sua sub-região na geração G. É importante lembrar que as estruturas das sub-regiões são alteradas durante

o processo de otimização, portanto um mesmo vetor X pode representar estratégias diferentes caso as estratégias utilizadas para definição das suas sub-regiões forem diferentes.

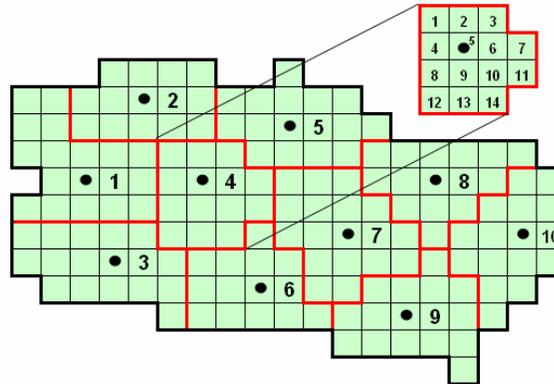


Figura 4.1 - Representação cromossômica do problema de otimização do posicionamento dos poços

Portanto a população da geração G é composta pelos indivíduos X_i .

$$\vec{X}_i^G \quad i = 1, \dots, NP^G \quad G = 1, \dots, G \max \quad \text{Eq. 4.4}$$

O índice i é relativo ao indivíduo. Cada população em uma determinada geração G possui NP^G indivíduos. O número de indivíduos em uma geração pode variar ao longo do processo, por isso NP é indexado pela geração G . G_{\max} é o número de gerações que define o término do processo. Portanto, \vec{X}_1^0 representa a estratégia inicial. A primeira geração é criada a partir dela, da seguinte forma:

$$\vec{X}_i^0 = M(\vec{X}_1^0) \quad i = 2, \dots, NP^G \quad \text{Eq. 4.5}$$

onde M representa o operador da mutação e será descrito em maiores detalhes ao final deste item. A Figura 4.2 mostra um exemplo para uma população inicial gerada a partir de um indivíduo.

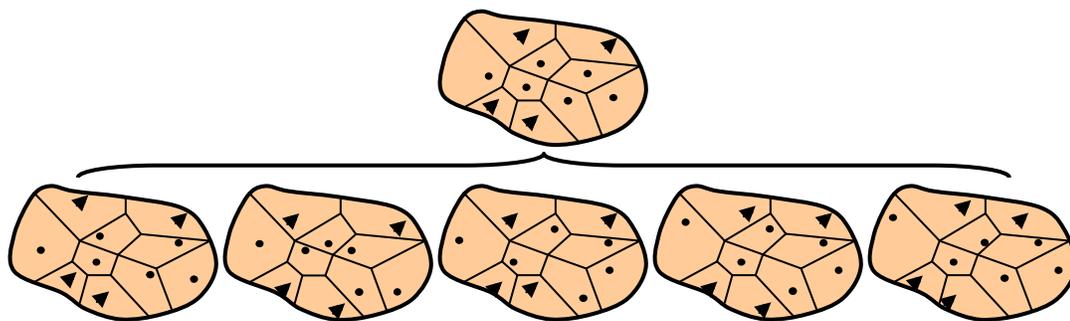


Figura 4.2 - Exemplo de população inicial gerada a partir a estratégia inicial (superior)

- Seleção

A seleção para o processo de cruzamento é feita através do método da roleta, conforme descrito no Item 2.6.2.

- Cruzamento

Com o objetivo de aumentar a eficiência do processo de otimização, sem perder o caráter de busca dispersa, são definidos dois operadores de cruzamento. O primeiro realiza o cruzamento selecionando os genes que o filho herdará de seus pais. O segundo operador não realiza esta seleção para não restringir a região de busca. Portanto, cada par selecionado é submetido a um dos dois operadores. Um sorteio define a qual operador o par será submetido. Este sorteio é feito de forma que a probabilidade do par ser submetido ao cruzamento C_1 é igual à probabilidade dele ser submetido ao cruzamento C_2 .

O operador relativo à técnica de cruzamento C_1 opera de maneira distinta em genes de poços produtores e injetores.

No caso de poços produtores o filho gerado herda o gene referente à posição do poço que possui maior IDF. Para os poços injetores o filho herda aleatoriamente a posição do poço do pai ou da mãe.

Portanto, sendo o i -ésimo indivíduo definido por:

$$\bar{X}_i^G = (x_1^G, \dots, x_n^G) = x_{i,j}^G \quad i = 1 \dots NP \quad \text{Eq. 4.6}$$

Para j relativo a um poço produtor (gene de poço produtor), o cruzamento é realizado da seguinte forma:

$$C_1(\bar{X}_{S(2i-1)}^G, \bar{X}_{S(2i)}^G) = \bar{X}_i^{G+1} \quad \text{de tal forma que} \quad \text{Eq. 4.7}$$

$$x_{i,j}^{G+1} = \max\{g(x_{S(2i-1),j}^G), g(x_{S(2i),j}^G)\} \quad \text{Eq. 4.8}$$

$S(2i-1)$ e $S(2i)$ são os índices que definem o i -ésimo par, selecionado pelo método da roleta e $g(x_{i,j}^G)$ é o IDF do poço $x_{i,j}^G$.

Para j relativo a um poço injetor, o cruzamento é realizado da seguinte forma:

$$x_{i,j}^{G+1} = RND_{50\%}\{x_{S(2i-1),j}^G, x_{S(2i),j}^G\} \quad \text{Eq. 4.9}$$

Ou seja, neste caso o filho herda aleatoriamente o gene de um dos pais.

De maneira semelhante, o operador C_2 atua em dois indivíduos da geração anterior para criar um indivíduo da próxima geração, e não há distinção quanto a ser um gene de poço produtor ou injetor. Neste caso não é feita a escolha dos genes que o filho herdará dos pais.

$$C_2(\bar{X}_{S(2i-1)}^G, \bar{X}_{S(2i)}^G) = \bar{X}_i^{G+1} \quad \text{Eq. 4.10}$$

$$x_{i,j}^{G+1} = RND_{50\%}\{x_{S(2i-1),j}^G, x_{S(2i),j}^G\} \quad \text{para qualquer } j \quad \text{Eq. 4.11}$$

Como dito anteriormente, a definição de dois operadores de cruzamento permite que o processo evolutivo seja acelerado sem que se perca o caráter de busca por valores extremos globais. O operador C_1 possui um viés de gerar indivíduos condicionados ao IDF dos poços produtores, isso acelera o processo de evolução, entretanto pode guiar o processo para um valor

máximo local para a função-objetivo. O operador C_2 possui a função de fugir da restrição imposta pelo operador C_1 , e buscar por soluções em um domínio maior.

- Mutação

A mutação é um importante operador no processo de otimização por algoritmos genéticos. Através dele é que se confere maior diversidade genética a uma população. Com isso o processo de busca alcança maiores regiões do domínio do problema em questão.

O processo de mutação é ativado quando a geração G possuir a média dos valores das funções objetivos dos seus indivíduos, superior ao valor limite de ativação da mutação. Para isso, é estabelecida, no início do processo, a diferença mínima entre a função-objetivo do melhor indivíduo e a média da população (LMUT), para o processo transcorra sem que haja mutações. A partir deste limite a mutação é ativada. Este é um artifício montado para acelerar o processo de evolução da população, e estabelecer uma taxa de mutação efetiva equilibrada. O equilíbrio na taxa efetiva de mutação é um importante item para garantir a eficiência do processo de otimização, como será mais bem explicado a seguir.

Com a ausência de mutação no processo cria-se uma situação hipotética que é conhecida em biologia evolutiva pelo termo de herança por mistura (“blending inheritance”). Nesta situação os descendentes são indivíduos intermediários dos seus pais, e por conseqüência, em poucas gerações a população se torna totalmente homogênea. Da mesma forma, nos algoritmos genéticos, a não consideração da mutação faz com que a população convirja, para o melhor indivíduo (quando é utilizado elitismo). Isso ocorre devido à baixa diversidade de posicionamento dos poços faz com que o algoritmo encontre rapidamente a melhor configuração a partir dos posicionamentos iniciais.

Por outro lado, uma taxa excessivamente grande de mutação confere ao processo um caráter estritamente aleatório. O que também representa uma situação indesejada. Ao analisar os dois casos observa-se que no primeiro existe uma média das funções-objetivo elevada, porém uma baixa dispersão em torno dela, diminuindo a probabilidade de se superar o desempenho do melhor indivíduo. No segundo caso, apesar de se ter uma grande dispersão dos valores das funções-objetivo em torno da média, está é excessivamente baixa, diminuindo novamente, a chance de superar o desempenho do melhor indivíduo até então. Ao se criar um mecanismo de

ativação da mutação, permite-se gerar populações com médias altas e grandes dispersões em torno delas. Isso aumenta a probabilidade de gerar um indivíduo que supere o desempenho do melhor indivíduo.

Sendo a média da função-objetivo para a população G:

$$\bar{f}^G = \frac{\sum_{i=1}^n f(\bar{X}_i^G)}{NP} \quad \text{Eq. 4.12}$$

Caso a média das funções-objetivo incida na região de ativação da mutação, todos os genes gerados para a próxima geração terão uma probabilidade PMUT (definida a princípio) de sofrer mutação.

Portanto, caso:

$$(f \max^G - LMUT) < \bar{f}^G < f \max^G \quad \text{Eq. 4.13}$$

Então há uma probabilidade PMUT dos genes sofrerem mutação. Caso um determinado gene seja sorteado, o operador de mutação agirá sobre ele da seguinte forma:

$$x_{i,j}^G = M(x_{i,j}^G) = RND(1, \dots, x \max_j^G) \quad \text{Eq. 4.14}$$

ou seja, o operador altera aleatoriamente o valor de $x_{i,j}^G$ para um dos valores possíveis de posicionamento na sub-região j.

Como pode ser observado nesta implementação de algoritmo genético, a mutação não opera sobre os indivíduos e sim diretamente sobre os genes. Como o processo trabalha com pequenas populações a taxa de mutação aplicada aos indivíduos conduz a uma baixa eficiência no processo de mutação, para fugir desta baixa eficiência foi adotada a mutação agindo diretamente sobre os genes.

A população gerada desta forma compõe uma nova geração e o processo prossegue até que se atinja o número máximo de gerações. A Figura 4.3 exemplifica o processo de evolução de uma população para a seguinte.

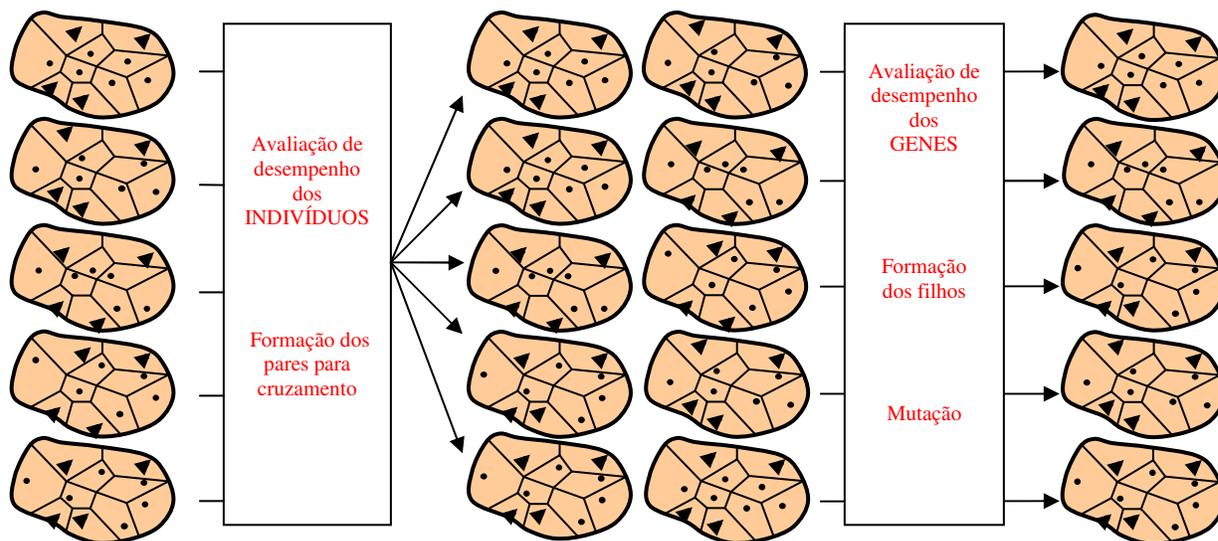


Figura 4.3 - Algoritmo Genético - Exemplo do Processo de Evolução de uma População

Otimização da Quantidade de Poços

- Representação Cromossômica

A representação cromossômica para a etapa da otimização da quantidade é mais simples que a da etapa da otimização do posicionamento. O cromossomo é representado por um vetor binário de dimensão igual ao número de poços. Cada elemento do vetor indica a presença ou não de um determinado poço na estratégia. A Figura 4.4 mostra um exemplo desta representação cromossômica.

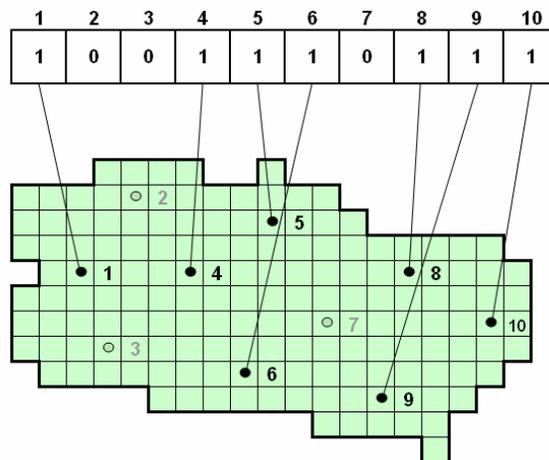


Figura 4.4 - representação Cromossômica do problema de otimização da quantidade de poços

- Seleção

O processo de seleção, como no caso da otimização do posicionamento dos poços é realizada através do método da roleta.

- Cruzamento

A diferença entre esta representação cromossômica e a do problema de otimização de posicionamento dos poços não permite que os mesmos operadores de cruzamento sejam utilizados neste processo de otimização. Portanto, é necessário criar operadores específicos para a resolução deste problema. De forma semelhante ao problema anterior, foi decidido adotar dois operadores de cruzamento para acelerar o processo de evolução, sem que haja perda da eficiência do processo.

O operador de cruzamento C_3 opera apenas nas diferenças entre os indivíduos. Ele confere ao processo, uma tendência de busca em regiões próximas dos melhores indivíduos, portanto tende a acelerar a evolução. Caso ambos os pais possuam um determinado poço o filho gerado para a próxima geração necessariamente o possuirá. Da mesma forma, caso ambos os pais não possuam um determinado poço, o filho necessariamente não o possuirá. Desta maneira, o operador C_3 agirá apenas onde houver diferenças entre as estratégias selecionadas para cruzamento. O filho terá igual probabilidade de herdar o gene do pai ou da mãe.

$$C_3(\bar{X}_{S(2i-1)}^G, \bar{X}_{S(2i)}^G) = \bar{X}_i^{G+1} \quad \text{Eq. 4.15}$$

Caso:

$$x_{S(2i-1),j}^G \neq x_{S(2i),j}^G \quad \text{Eq. 4.16}$$

Então:

$$x_{i,j}^{G+1} = RND_{50\%} \{x_{S(2i-1),j}^G, x_{S(2i),j}^G\} \quad \text{Eq. 4.17}$$

O operador C_4 age de forma diferente do operado C_3 . Para cada cruzamento feito por este operador, é sorteado um ponto de corte PCO, que a partir do qual será feita a combinação entre o material genético do pai com o da mãe para compor o cromossomo do filho. Este operador age de maneira a buscar soluções mais distantes dos melhores indivíduos gerados. Através dele, busca-se conferir maior robustez à solução.

$$C_4(\bar{X}_{S(2i-1)}^G, \bar{X}_{S(2i)}^G) = \bar{X}_i^{G+1} \quad \text{Eq. 4.18}$$

Tal que:

$$x_{i,j}^{G+1} = x_{S(2i-1),j}^G \quad \text{para } j < \text{PCO e} \quad \text{Eq. 4.19}$$

$$x_{i,j}^{G+1} = x_{S(2i),j}^G \quad \text{para } j \geq \text{PCO} \quad \text{Eq. 4.20}$$

- Mutação

O operador de mutação utilizado para a resolução deste problema é idêntico ao utilizado no problema da otimização do posicionamento dos poços.

4.2.6 Alternativa para a otimização da quantidade de poços

A utilização dos algoritmos genéticos para a otimização da quantidade de poços representa uma busca diversificada pelo espaço solução e requer um grande número de simulações. Em casos onde se espera excluir um número pequeno de poços, a realização deste tipo de busca é desnecessária, sendo mais apropriado adotar uma alternativa mais rápida.

Como alternativa à busca dispersa, a quantidade de poços pode ser otimizada através de exclusões seqüenciais de poços que conduzem ao maior incremento na função-objetivo. Com este intuito, inicia-se o processo de otimização com n poços, e avalia-se o desempenho do projeto com esta quantidade. Em seguida são testadas todas as configurações possíveis com $n-1$ poços. Caso o desempenho do projeto com $n-1$ poços seja superior ao de n poços, adota-se a configuração de $n-1$ poços que possua o melhor desempenho. O processo estende-se enquanto houver melhora de desempenho do projeto com a redução do número poços. Ou seja, são calculados os IDC de todos os poços do campo. O poço que possuir o IDC mais negativo é excluído a cada etapa. O procedimento prossegue até que não haja, no campo, poço com IDC negativo.

4.3 Técnica para Consideração das Incertezas ao Longo do Processo de Otimização

Para que se conduza o processo de otimização por completo, considerando as incertezas geológicas e econômicas, é necessário desenvolver uma técnica que possibilite o cálculo do VME a cada passo do processo. Esta técnica deve permitir que uma única estratégia seja otimizada simultaneamente em todos os modelos geológicos representativos (MGR) e sob todos os cenários econômicos considerados.

O objetivo desta técnica é realizar a otimização de estratégias de produção através de uma abordagem mais rigorosa que a MADC (Figura 2.1). Neste intuito, os ramos da árvore de decisão não devem ser otimizados isoladamente, e sim de forma dependente para que uma única estratégia seja otimizada. A Figura 4.5 esquematiza a idéia proposta que neste trabalho será designada por MADI (metodologia da árvore de decisão integrada).

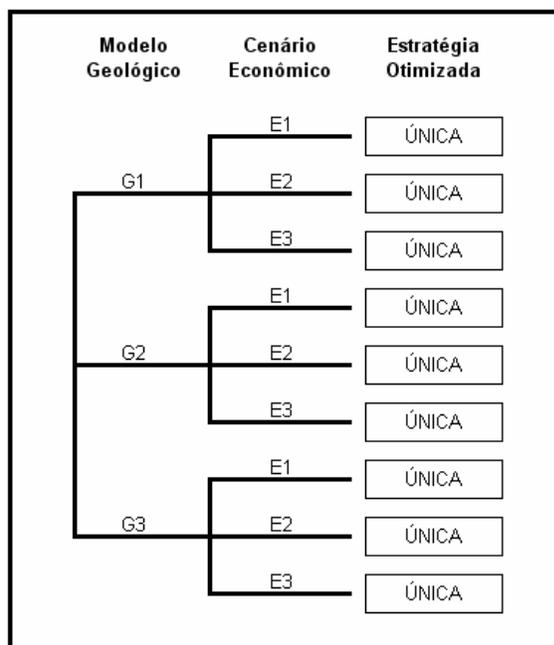


Figura 4.5 – Árvore de decisão utilizada na MADI – uma única estratégia é otimizada simultaneamente

O primeiro passo para o desenvolvimento desta técnica é construir os modelos de fluxo relativos aos MGR em malhas de iguais dimensões. Deve-se ainda, forçar que estas malhas representem uma mesma região geográfica, permitindo que haja uma perfeita superposição entre elas, conforme demonstra a Figura 4.6.

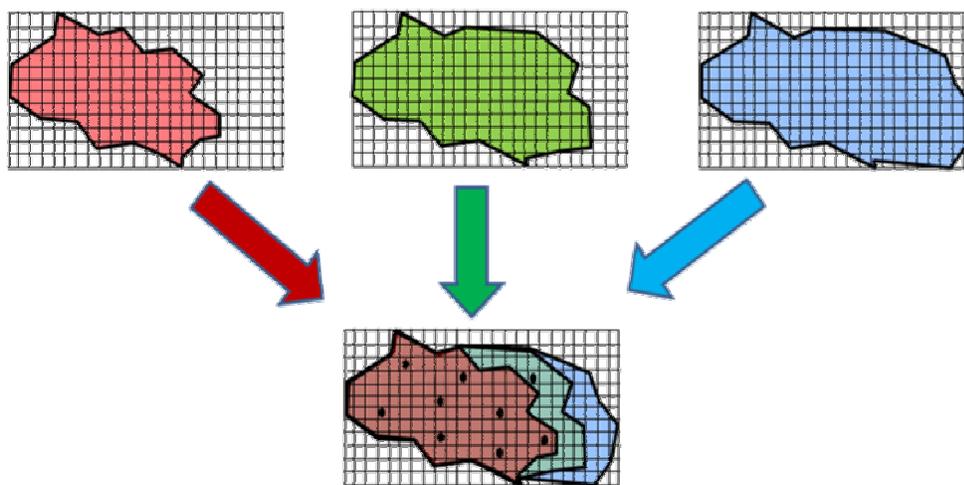


Figura 4.6 – Malhas dos Modelos de fluxo

O segundo passo é estruturar os modelos de fluxo dos MGR de forma que seja possível realizar o compartilhamento de um único arquivo de poços. O arquivo de poços é um arquivo anexo ao arquivo do modelo de fluxo que contem informações a respeito da quantidade e posicionamento dos poços. Ao compartilhar este arquivo, qualquer alteração deste arquivo impacta automaticamente em todos os modelos de fluxo considerados.

De uma forma geral, os processos de otimização desenvolvidos neste trabalho atuam somente no arquivo de poços, alterando suas quantidades e posicionamentos. Em seguida todos os modelos são submetidos à simulação de fluxo em um simulador comercial permitindo que se realize o cálculo do VPL de cada modelo geológico sob cada cenário econômico. Desta forma, é possível calcular o VME da estratégia a cada passo do processo de otimização, conforme a descrição do Item 2.7.2, e guiá-lo, por completo usando esta função-objetivo.

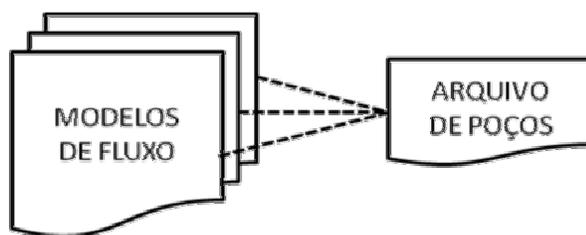


Figura 4.7 – Esquema dos arquivos dos modelos de fluxo

O processo de otimização tem a liberdade de alocar os poços dentro de toda a malha de simulação. A única restrição imposta é que os poços devem atravessar no mínimo uma célula ativa de pelo menos um modelo de fluxo. Caso um poço não atravessasse célula ativa de um determinado modelo de fluxo, o VPL desta estratégia é calculado considerando o investimento completo deste poço. Isto representa uma simplificação, já que em uma abordagem mais rigorosa os investimentos realizados em poços secos devem sofrer um abatimento com relação ao investimento de poços que são utilizados na produção do campo.

4.4 Planejamento de Aquisição de Informações do Reservatório

4.4.1 Descrição Geral

A realização do processo de otimização de estratégias de produção, como é proposto neste trabalho, permite que, ao final do processo, se tenha informações relevantes com relação aos desempenhos dos poços nos diferentes modelos geológicos considerados. Esta etapa da metodologia foi desenvolvida para guiar o planejamento da seqüência de perfuração e posterior realização de testes de formação de forma que forneçam as informações necessárias para se atingir objetivos previamente definidos. Os testes de formação são um importante instrumento de redução de incertezas durante a fase de desenvolvimento do campo e podem ser planejados para que as informações obtidas através deles atuem no sentido de causar um impacto desejado na curva de risco do projeto. A priorização da aquisição de certas informações do reservatório permite que a curva de risco original do projeto seja adequadamente alterada procurando seguir as diretrizes estabelecidas pela empresa.

O procedimento consiste em perfurar e testar os poços que possibilitem a aquisição das informações mais impactantes e em seguida realizar a re-otimização da estratégia de produção. O procedimento prossegue até não haver mais ganhos significativos com o emprego da metodologia.

Neste trabalho, é apresentado um exemplo onde esta metodologia é utilizada para acelerar a aquisição das informações mais impactantes na diferença entre os modelos otimista e pessimista. A aquisição destas informações possibilita revelar características das regiões do reservatório cujas incertezas causam maior impacto no risco do projeto. Esta postura permite que se faça a re-otimização do posicionamento dos poços ainda não perfurados em cenários cada vez mais realistas visando maximizar o desempenho final do reservatório (o VPL “real” do campo).

4.4.2 Mapas de Diferenças

Ao final do processo de otimização, os IDC (ou IDC econômicos) de todos os poços da estratégia otimizada estão calculados para todos os modelos geológicos. A depender do objetivo a ser atingido, pode-se construir diferentes mapas tendo o desempenho dos poços como base. Para

se atingir o objetivo exemplificado neste trabalho, são construídos mapas de diferenças de IDC entre modelos geológicos, com a finalidade de evidenciar as regiões do reservatório onde os poços possuem desempenhos discrepantes nos diferentes MGR. Estes mapas são comparados com os mapas de diferença de qualidade entre os MGR, para revelar regiões onde os poços possuam diferenças de desempenho associadas a diferenças de qualidade. Este estudo de comparação dos mapas de diferenças de desempenho e da qualidade do reservatório será designado, neste trabalho, por Análise Cruzada. A perfuração de poços e posterior realização de testes de formação nestas regiões possibilitam que se conheçam parâmetros importantes como espessura e permeabilidade do reservatório e índice de produtividade dos poços. A aquisição destas informações permite que se igualem estas características nos diversos MGR gerando a tendência de reduzir a diferença de desempenho dos poços nestes modelos e conseqüente redução do risco do projeto.

4.4.3 Procedimento Proposto

A Figura 4.8 mostra o procedimento proposto para a realização da análise cruzada durante o desenvolvimento de um campo. Após a realização da análise é feita uma avaliação do potencial de melhora pela utilização da metodologia. Caso haja este potencial, a indicação do próximo poço a ser perfurado é feita dando seqüência ao procedimento proposto. Caso não haja possibilidade de melhora, o desenvolvimento do campo prossegue sem haver indicação da seqüência de perfuração dos poços.

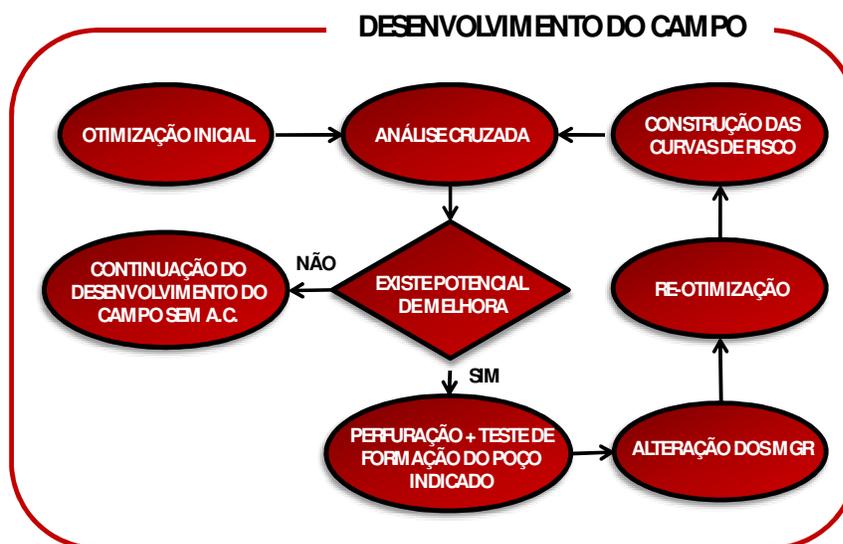


Figura 4.8 – Procedimento proposto para determinar ordem de perfuração de poços.

4.5 Rotinas de Cálculo da Função-Objetivo

Neste item, são mostrados os fluxogramas dos programas implementados para o cálculo da função-objetivo. A primeira rotina (TITANIUM - nomeada para ser referida nas outras etapas do processo) realiza o cálculo do VPL de uma determinada estratégia de produção. A segunda (AURUM) faz o cálculo do VME de uma estratégia. Para tanto, a estratégia é submetida à simulação de fluxo em todos os modelos geológicos considerados e com as curvas de produção obtidas são feitas às análises econômicas em todos os cenários econômicos. Com isso é possível montar a matriz de VPL necessária para o cálculo do VME.

A rotina TITANIUM realiza o cálculo do VPL de uma estratégia em um dos modelos geológicos considerando apenas um cenário econômico. No processo geral, possui a função de calcular um elemento da matriz de VPL como descrito nos itens anteriores. Ela realiza a análise econômica através da leitura das curvas de produção de óleo, gás e água e de injeção de água do arquivo de saída do simulador de fluxo comercial. Os investimentos são obtidos de um arquivo de investimento gerado especificamente para este propósito. Um terceiro arquivo de entrada é necessário para o fornecimento do cenário econômico. A Figura 4.9 mostra o fluxograma da rotina TITANIUM.



Figura 4.9 - Fluxograma da rotina TITANIUM – Cálculo do VPL

A rotina AURUM realiza o cálculo do VME total, geológico e econômico de uma estratégia de produção. Ela é responsável por submeter o modelo geológico à simulação de fluxo, e em seguida, chamar a rotina TITANIUM para realizar a análise econômica em todos os cenários considerados. Apenas um arquivo de entrada é necessário para referenciar tanto os arquivos de simulação e os arquivos de cenários econômicos, como também suas probabilidades de ocorrência. A Figura 4.10 mostra o fluxograma da rotina AURUM.

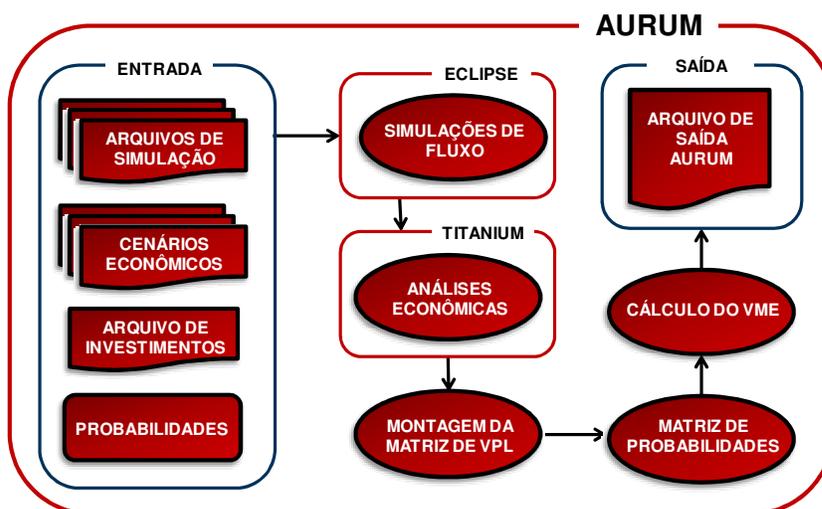


Figura 4.10 – Fluxograma da Rotina AURUM – Cálculo do VME

4.6 Rotinas de Otimização da Função-Objetivo

O processo pela busca por valores extremos da função-objetivo é constituído por etapas de otimização de quantidade e posicionamento que são gerenciados por uma rotina externa. A rotina externa de gerenciamento do processo de otimização será referenciada na descrição da metodologia por OPTIMUS. É responsável por guiar o processo de otimização entre as etapas de otimização de quantidade (referenciadas por PLUVIA e QUANTUM e a etapa de otimização do reposicionamento, DEO), conforme mostra o fluxograma da Figura 4.11.

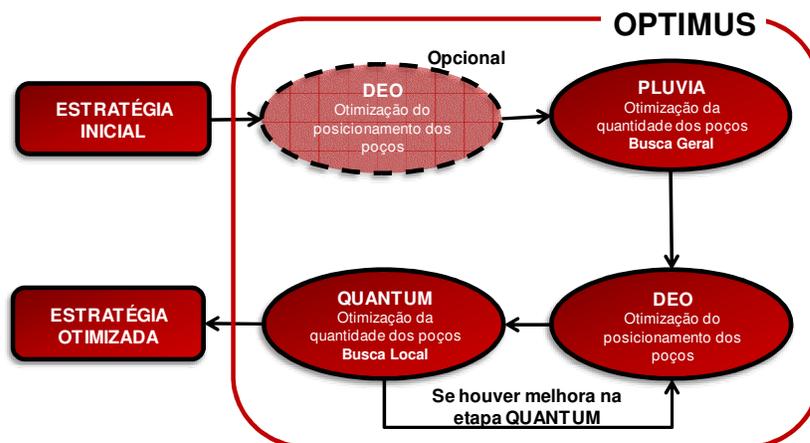


Figura 4.11 – Fluxograma rotina OPTIMUS – gerenciamento do processo de otimização de estratégias de produção

Para iniciar o processo de otimização, é necessário partir de uma estratégia de produção inicial. Esta estratégia deve possuir espaçamentos entre os poços reduzidos, para que o processo seja eficiente agindo sempre no sentido de reduzir o número de poços.

Caso a estratégia inicial tenha grande potencial de melhora pelo reposicionamento dos poços, é possível iniciar o processo pela rotina de otimização de posicionamento DEO, caso contrário, é mais adequado iniciar pelas rotinas de otimização da quantidade (PLUVIA e QUANTUM).

Foram implementadas duas rotinas de otimização de quantidade. A aplicação de cada uma depende da quantidade de poços que se espera excluir na etapa. Caso seja necessário excluir uma pequena quantidade de poços é adequada a utilização da rotina de QUANTUM (fluxograma da

Figura 4.12), que é baseada na exclusão seqüencial de poços de menor desempenho. Não é interessante a utilização desta rotina quando se espera excluir uma quantidade grande de poços, já que ele pode conduzir a um valor extremo local da função-objetivo. Neste caso, é mais adequado o emprego da rotina PLUVIA, que é uma implementação de algoritmo genético e, portanto representa um processo de busca mais robusto e confiável. Porém, geralmente, esta rotina necessita de um número maior de simulações que a rotina QUANTUM. Desta forma, deve-se ponderar a respeito da aplicação destas rotinas em cada caso.

Portanto, geralmente, inicia-se o processo de otimização pela rotina PLUVIA (fluxograma da Figura 4.13), já que pode haver uma redução significativa do número inicial de poços. Após a realização desta etapa é feita a otimização do posicionamento através da rotina DEO (fluxograma da Figura 4.13). Desta forma, obtém-se um arranjo mais eficiente para a quantidade de poços definida na primeira etapa. Mesmo com um arranjo eficiente dos poços, neste momento, é importante verificar se há a possibilidade de excluir um ou mais poços. Como se espera excluir uma pequena quantidade de poços nesta etapa, o processo pode ser alternado para a rotina QUANTUM, que necessita de um número menor de simulações.

O procedimento de alternância entre as rotinas DEO e QUANTUM prossegue gerenciado pela rotina OPTIMUS, até que não haja mais melhora de desempenho, e a estratégia definida é considerada ótima.

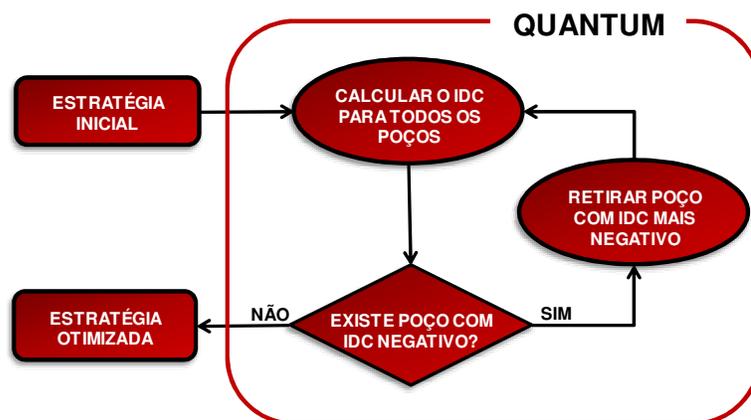


Figura 4.12 – Fluxograma rotina QUANTUM – otimização da quantidade de poços por exclusão seqüencial

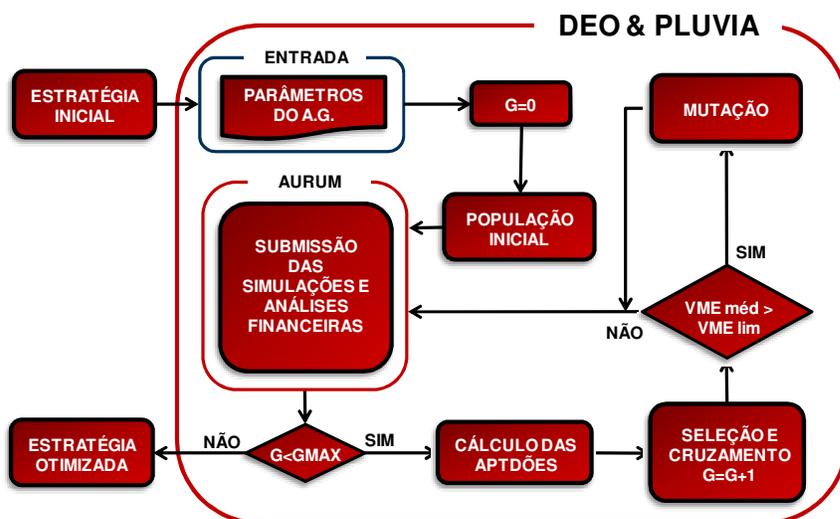


Figura 4.13 – Fluxograma rotinas DEO e PLUVIA – otimização do posicionamento e da quantidade de poços por algoritmo genético

Capítulo 5 - Aplicações

Neste capítulo, com o propósito de gerar estudos de casos, são estruturadas oito aplicações para os itens desenvolvidos nas Etapas de 1 a 4 da metodologia de trabalho. Estas aplicações são distribuídas da seguinte forma:

- **Etapa 1** – É realizado um caso relativo ao estudo da superfície de resposta em problema de otimização do posicionamento de poços.
- **Etapa 2** – São realizados dois casos relativos à otimização determinística de estratégias de produção. O primeiro refere-se à otimização de estratégia de produção que utiliza apenas poços verticais, o segundo que utiliza apenas poços horizontais.
- **Etapa 3** – São realizados quatro casos relativos à otimização probabilística de estratégias de produção. Dois dos quais considerando apenas incertezas geológicas, um considerando apenas incertezas econômicas e outro considerando simultaneamente incertezas geológicas e econômicas. As otimizações serão feitas de duas formas distintas, através das MADI e MADC, para que se possa comparar os resultados e concluir a respeito da aplicabilidade de cada uma.
- **Etapa 4** – É realizado um caso onde é estudada uma seqüência de perfuração que acelere a redução do risco do projeto, visando a realização de re-otimizações em contextos cada vez menos arriscados.

Nos itens subseqüentes são apresentados os modelos de fluxo e cenários econômicos utilizados nestas aplicações.

5.1 Modelos de Fluxo

5.1.1 Geologia

Foram gerados seis modelos geológicos sintéticos distintos nomeados por GP, GI, GO, GPc, G1c e GH. A criação destes modelos visa representar realizações de ordem pessimista,

intermediária e otimista e uma realização hipotética da geologia de um reservatório⁴ (estas realizações são necessárias para um estudo de otimização de estratégias sob incertezas). A princípio são gerados três modelos geológicos (GP, GI e GO) considerando a existência, no reservatório, de apenas um poço perfurado e testado. Para respeitar as informações obtidas neste poço, as propriedades petrofísicas dos seis modelos na sua região são idênticas⁵. Ao se distanciar do poço, os modelos geológicos começam a se diferenciar gerando as realizações pessimista (GP), intermediária (GI) e otimista (GO).

O modelo otimista (GO) considera que as propriedades petrofísicas medidas no poço perfurado possuem uma ampla continuidade espacial. O modelo intermediário (GI) considera que existe uma ligeira queda da qualidade destas propriedades ao se distanciar do poço. E o modelo pessimista (GP) considera que a qualidade das propriedades petrofísicas possui uma queda acentuada quando se distancia do poço. A Figura 5.1 representa uma perspectiva do reservatório evidenciando a sua estrutura. A perspectiva mostrada é do modelo intermediário (GI). Os modelos, pessimista (GP) e otimista (GO), possuem estrutura com características semelhantes. A Figura 5.2 que mostra os cortes indicados na Figura 5.1, indica que a região central do reservatório representa um alto estrutural.

Da Figura 5.3 à Figura 5.5 são mostradas as propriedades petrofísicas destes três modelos. Observa-se, através dos cortes apresentados na Figura 5.2 e dos mapas indicados nas Figuras 5.3 a 5.5 que a espessura porosa e a qualidade das propriedades petrofísicas vão diminuindo em direção à periferia. Estas três primeiras realizações formam um dos grupos de modelos geológicos representativos, MGR₁, que serão adotados neste trabalho.

Outros dois modelos geológicos (GPc e GIc) são gerados pela inclusão de falhas nos modelos geológicos pessimista (GP) e intermediário (GI). No modelo pessimista (GP), são incluídas quatro falhas totalmente selantes gerando cinco compartimentos do reservatório hidraulicamente isolados. No modelo intermediário (GI) é incluída uma falha 99% selante gerando dois compartimentos do reservatório fracamente comunicados. Estes modelos juntamente com o modelo geológico otimista do MGR₁ (GO) formam o segundo grupo de

⁴ Schiozer *et al.* (2004) propõem uma metodologia para a seleção de modelos geológicos representativos a partir de uma série de realizações.

⁵ Força-se ainda, que o poço tenha o mesmo índice de produtividade nos seis modelos de fluxo.

modelos geológicos representativos, MGR₂, utilizados nesta dissertação. A Figura 5.6 mostra os mapas de permeabilidade com a indicação da compartimentação do reservatório para este grupo de modelos geológicos representativos.

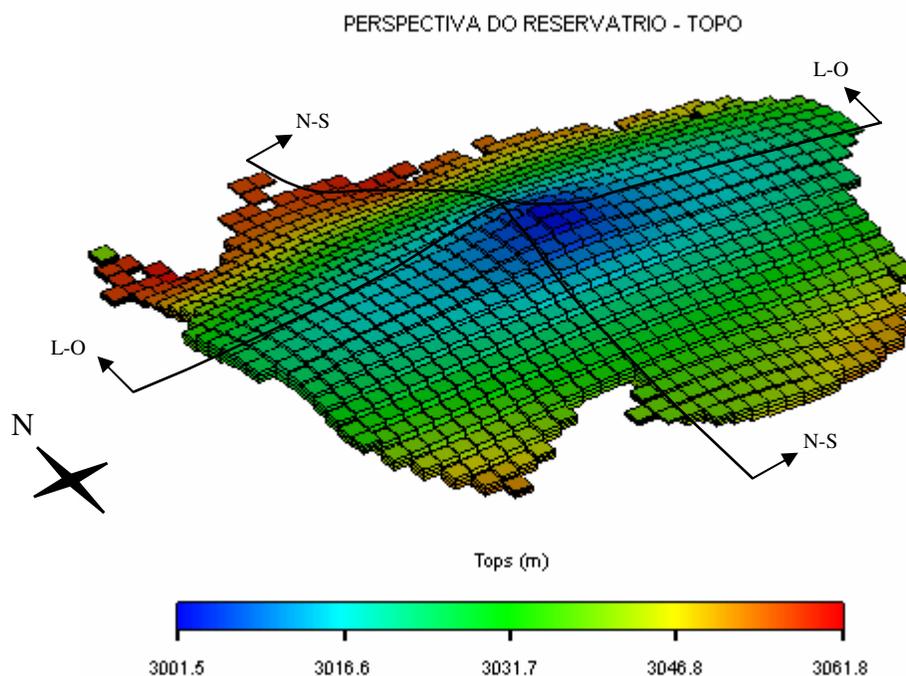


Figura 5.1 – Perspectiva da estrutura do reservatório indicando o topo das células – modelo intermediário – exagero vertical de 15x

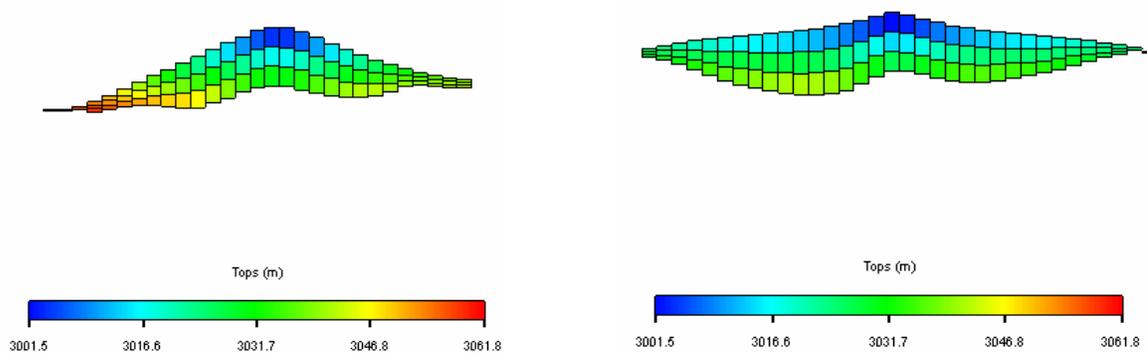


Figura 5.2 – Corte norte-sul e leste-oeste indicando o topo das células – modelo intermediário - exagero vertical de 15x

A adoção de dois grupos de modelos geológicos representativos com diferentes níveis de complexidade permite que se faça uma análise da aplicabilidade da metodologia proposta (desenvolvida na Etapa 3 da metodologia de trabalho) em função do nível de complexidade em relação à geologia do reservatório.

A criação do sexto modelo geológico permite adotá-lo como referência de reservatório “hipotético” para o estudo da seqüência de perfuração dos poços. Esse reservatório hipotético é usado como se fosse o reservatório “real”, gerando as propriedades que seriam consideradas medidas no processo. A Figura 5.7 mostra os mapas de permeabilidade, espessura e porosidade deste modelo.

Para a modelagem de fluxo deste reservatório foi adotada uma malha cartesiana de 35 x 35 x 3 células de dimensões 150 x 150 e espessura variada, guiada pela geologia. A Tabela 5.1 mostra um resumo das principais características dos modelos gerados.

Tabela 5.1 - Propriedades dos modelos geológicos

Modelos Geológicos	Grupo MGR1			Grupo MGR2			“Real”
	GP	GI	GO	GPc	GIc	GO	GH
VOIP (m³)	5.48E+07	5.72E+07	6.60E+07	5.48E+07	5.72E+07	6.60E+07	5.68E+07
Kmed (mD)	250	350	500	250	350	500	325
Hmed (m)	25	25	25	25	25	25	25
Células Ativas	2034	2358	2724	2034	2358	2724	2412
Falhas	Não	Não	Não	Sim	Sim	Não	Não

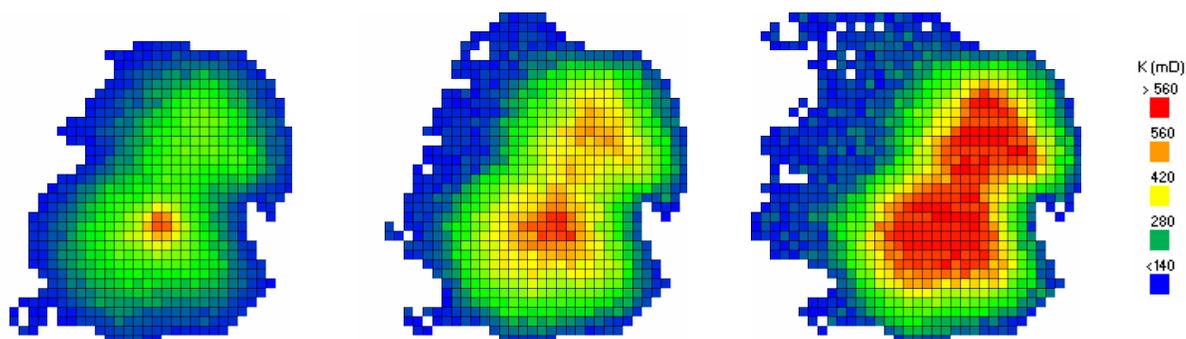


Figura 5.3 – MGR₁ - mapas de permeabilidade horizontal – GP, GI e GO

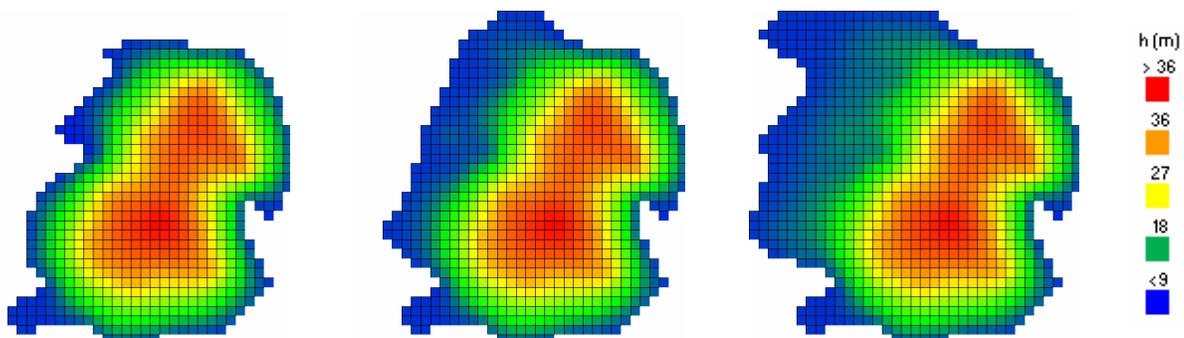


Figura 5.4 – MGR₁ - mapas de espessura – GP, GI e GO

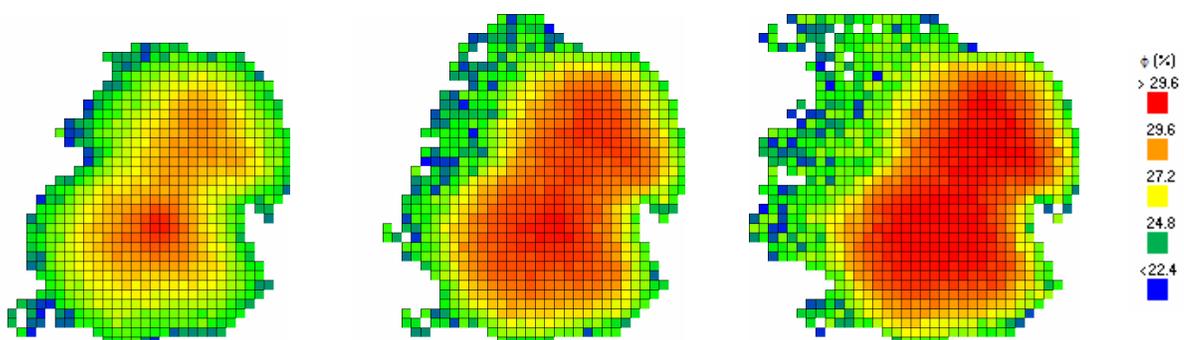


Figura 5.5 – MGR₁ - mapas de porosidades – GP, GI e GO

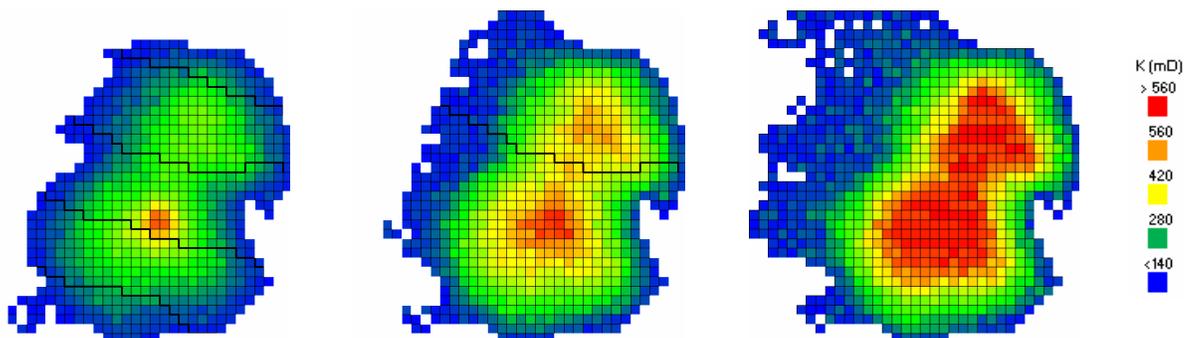


Figura 5.6 – MGR₂ - mapas de permeabilidade indicando a compartimentação do reservatório – GPc, GIc e GO

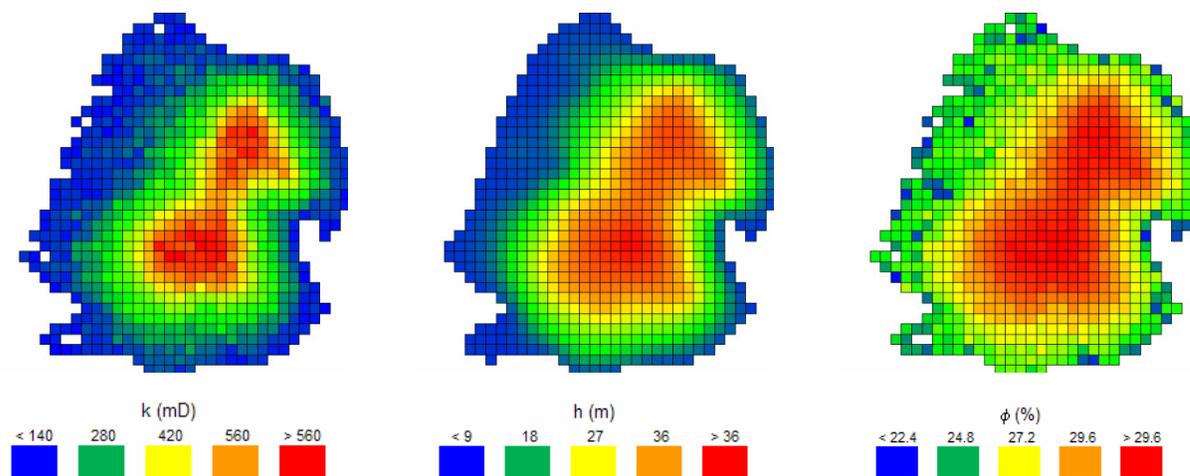


Figura 5.7 – Reservatório “hipotético” (GH) - mapas de permeabilidade horizontal, espessura e porosidade

5.1.2 Petrofísica

A Figura 5.8 mostra as curvas de permeabilidade relativas adotadas em todos os modelos de fluxo.

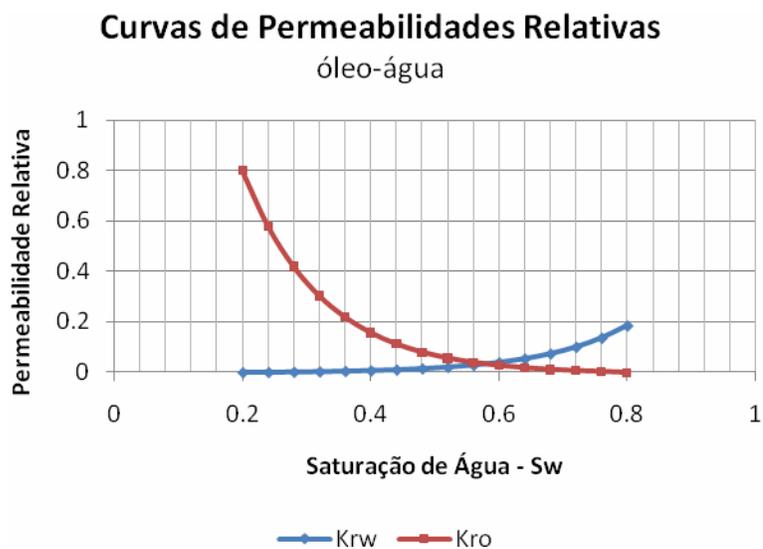


Figura 5.8 – Curvas de permeabilidades relativas

5.1.3 Fluidos

- Óleo

O óleo considerado nos modelos possui densidade de 32 °API e suas propriedades PVT são representadas na Figura 5.9. A pressão de saturação é de 210 kgf/cm². A compressibilidade do óleo acima da pressão de saturação é $150 \times 10^{-6} \text{ (kgf/cm}^2\text{)}^{-1}$. Também para pressões superiores a pressão de saturação a dependência da viscosidade com a pressão é $1,00 \times 10^{-3} \text{ (cp/kgf/cm}^2\text{)}$. Por simplificação não foram consideradas pressões capilares para os sistemas óleo-gás e óleo-água.

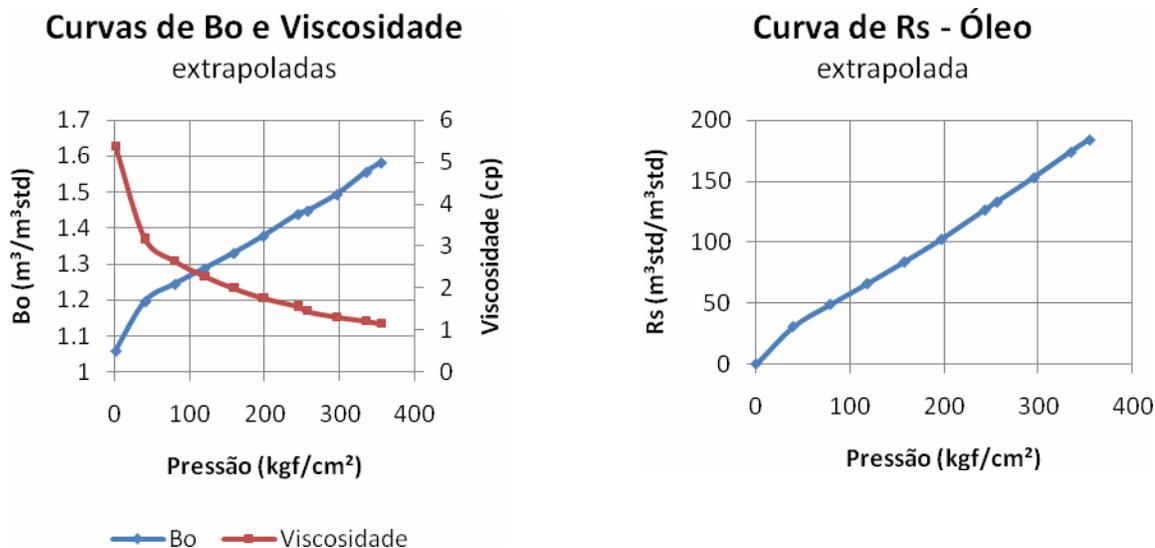


Figura 5.9 – Curvas de PVT do óleo

- Água

Foi considerado que a água do reservatório possui viscosidade de 0,6 cp, compressibilidade de $50 \times 10^{-6} \text{ (kgf/cm}^2\text{)}^{-1}$ e fator de formação de volume (B_w) de 1,04.

5.1.4 Condições Operacionais

A Tabela 5.2 mostra as condições de operação adotadas para os poços verticais e horizontais.

Tabela 5.2 - Condições Operacionais dos Poços

Condição Operacional	Poços Verticais		Poços Horizontais	
	Prod.	Injet.	Prod.	Injet.
Pressão de Fundo Limite ⁶ (kgf/cm ²)	210	400	210	400
Vazão Máxima (m ³ /dia)	4000	6000	6000	8000
Corte de Água Máximo	0.9	---	0.9	---

5.1.5 Estratégias Iniciais

A Figura 5.10 mostra as estratégias iniciais adotadas nas Etapas 2 e 3 da metodologia de trabalho. A que utiliza poços verticais é composta por 25 poços produtores 29 injetores totalizando 54 poços arranjado em um sistema *five-spot*. A estratégia inicial para poços horizontais é composta por 5 poços produtores e 7 injetores totalizando 12 poços arranjados em um sistema de injeção periférica com produção central.

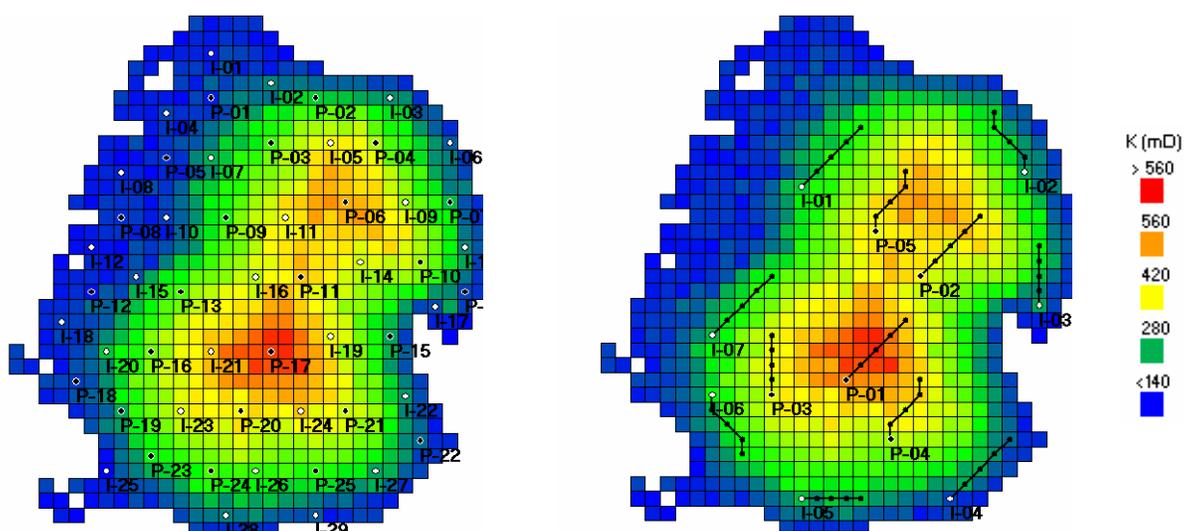


Figura 5.10 – Mapa de permeabilidade do GI com as estratégias iniciais.

⁶ Para poços produtores é mínima pressão de fluxo, para injetores é a máxima pressão de injeção

5.2 Cenários Econômicos

Para as análises econômicas sob incertezas (Etapa 3 da metodologia de trabalho) foram considerados três cenários econômicos: pessimista (EP), intermediário (EI) e otimista (EO). Como pode ser observado na

Tabela 5.3 eles diferem entre si apenas no preço do óleo e nos custos de produção e injeção de água.

Tabela 5.3 - Cenários econômicos

Pessimista – EP			Intermediário - EI			Otimista - EO		
Receitas	Óleo (US\$/bbl)	35,00	Receitas	Óleo (US\$/bbl)	50,00	Receitas	Óleo (US\$/bbl)	100,00
	Gás (US\$/m ³)	0,314		Gás (US\$/m ³)	0,314		Gás (US\$/m ³)	0,314
Custos (US\$/bbl)	Produção Óleo	4,79	Custos (US\$/bbl)	Produção Óleo	4,79	Custos (US\$/bbl)	Produção Óleo	4,79
	Produção do Gás	0,037		Produção do Gás	0,037		Produção do Gás	0,037
	Produção de Água	2,46		Produção de Água	0,82		Produção de Água	0,82
	Injeção de Água	2,46		Injeção de Água	0,82		Injeção de Água	0,82
Impostos	Imposto de Renda	25%	Impostos	Imposto de Renda	25%	Impostos	Imposto de Renda	25%
	Contribuição Social	9%		Contribuição Social	9%		Contribuição Social	9%
	Pis + Cofins	9,25%		Pis + Cofins	9,25%		Pis + Cofins	9,25%
	Royalty	10%		Royalty	10%		Royalty	10%
	Participação Especial	Variável		Participação Especial	Variável		Participação Especial	Variável
	Depreciação Linear (anos)	10		Depreciação Linear (anos)	10		Depreciação Linear (anos)	10
TMA	Taxa Mínima de Atratividade	12%	TMA	Taxa Mínima de Atratividade	12%	TMA	Taxa Mínima de Atratividade	12%

5.3 Investimentos

A Tabela 5.4 mostra os custos de cada item considerados nos projetos de desenvolvimento dos campos.

Tabela 5.4 - Tabelas de investimentos

Elemento	Investimento (US\$ x 10 ⁶)	Quando
Exploração	100	4 anos antes do início da produção
Avaliação	100	Durante 3 anos antes do início da produção
Plataforma	1000	
Poço Vertical	35	
Poço Horizontal	60	Ao final da produção
Descomissionamento	100	

5.4 Resumo das Aplicações

A Tabela 5.5 resume as estruturas montadas para as aplicações da metodologia. Nela são definidos que modelos geológicos e cenários econômicos serão utilizados em cada caso estudado. São indicadas ainda, as probabilidades de ocorrência que são adotadas para cada um dos modelos e cenários.

Tabela 5.5 – Resumo das Aplicações

Etapa	Caso	Aplicação	Modelos Geológicos					Modelos Econômicos		
			GP	GI	GO	GPc	GIc	EP	EI	EO
1	1	Estudo da Topologia		100%					100%	
2	2A	Otimização Determinística Poços Verticais		100%					100%	
	2B	Otimização Determinística Poços Horizontais		100%					100%	
3	3A	Otimização sob Incertezas Geológicas sem compartimentação	33%	34%	33%				100%	
	3B	Otimização sob Incertezas Geológicas com compartimentação			33%	33%	34%		100%	
	3C	Otimização sob Incertezas Econômicas			100%			33%	34%	33%
	3D	Otimização sob Incertezas Econômicas e Geológicas			33%	33%	34%	33%	34%	33%
4	4	Seqüência de Perfuração	33%	34%	33%				100%	

Capítulo 6 - Resultados

Neste capítulo, são apresentados os resultados obtidos para as aplicações estruturadas no Capítulo 5.

6.1 Etapa 1 - Estudo da Superfície de Resposta de Problema de Otimização de Posicionamento de Poços

6.1.1 Caso 1

Neste caso é realizada uma aplicação que visa analisar a superfície de resposta para um caso simples de otimização de posicionamento de poços. O exemplo é limitado a 2 parâmetros para possibilitar a visualização.

O problema consiste em encontrar, dentro de regiões definidas, os posicionamentos de dois poços de uma estratégia de produção que maximizem seu VPL. A Figura 6.1 mostra, no mapa de permeabilidade do modelo, as regiões onde são possíveis os posicionamentos destes dois poços.

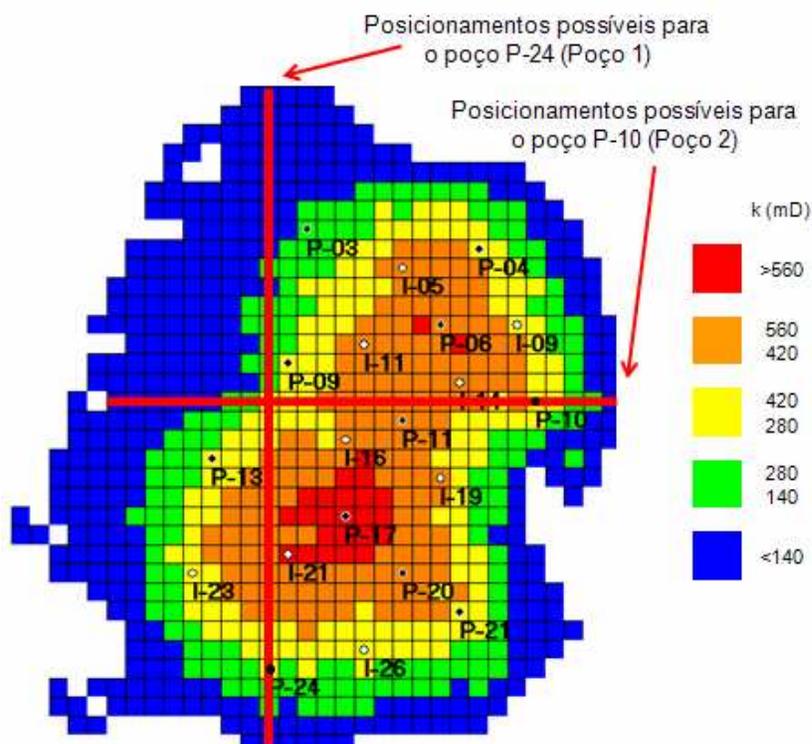


Figura 6.1 – Posicionamentos possíveis para os poços 1 e 2 para obtenção da superfície de resposta de um problema de otimização de estratégia de produção.

Para construir a superfície de resposta deste problema são executadas todas as combinações possíveis para os posicionamentos dos dois poços⁷, desta forma gera-se a superfície de resposta para o VPL da estratégia conforme mostrado na Figura 6.2. Nela aparecem, além do máximo global, algumas regiões que representam máximos locais para o VPL.

A existência destas regiões de máximos locais contra-indica a aplicação, neste tipo de problema, de métodos de otimização baseados no cálculo dos gradientes da função-objetivo. Com este tipo de superfície torna-se mais adequado o emprego de técnicas de busca dispersa, como é o caso dos algoritmos genéticos.

⁷ O posicionamento dos poços é feito apenas no centro de cada célula.

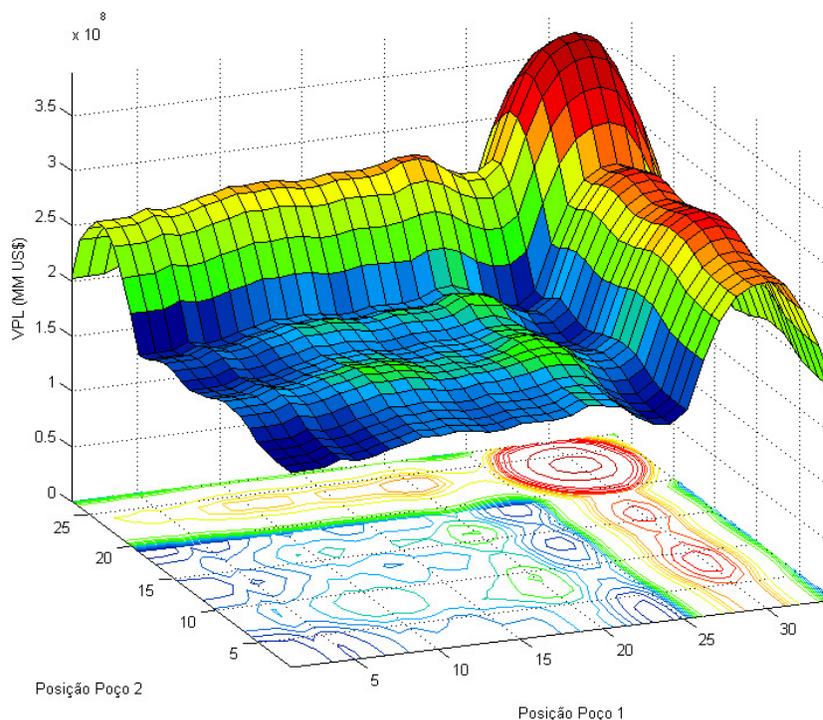


Figura 6.2 – Superfície de resposta para o problema de otimização dos posicionamentos de dois poços

Com o conhecimento prévio das características da superfície de resposta, torna-se interessante empregar uma técnica de otimização baseada em algoritmo genético para avaliar o seu desempenho na resolução deste problema. Para tanto, foi montado um algoritmo simples seguindo o fluxograma indicado na Figura 2.3 do Capítulo 2. Como cada poço possui apenas um grau de liberdade, são necessários apenas dois números inteiros⁸ para definir suas posições na malha de simulação. Desta forma, o algoritmo pode ser montado utilizando como representação cromossômica um vetor bidimensional de números inteiros onde cada componente representa a célula que o poço será alocado. Foram adotadas populações de 12 indivíduos e durante o processo foram avaliadas 4 gerações além da população inicial.

A Figura 6.3 mostra a evolução do processo de otimização da população inicial até a segunda geração (para não carregar demais a figura, as outras duas gerações não foram

⁸ A única restrição imposta é que estes números representem duas células ativas da malha de simulação.

representadas). Já na segunda geração, com apenas 23 indivíduos simulados, obteve-se o melhor indivíduo do processo. A Figura 6.4 mostra a evolução da função-objetivo (VPL) ao longo do processo.

O valor máximo da superfície de resposta é de US\$ 578,59 x 10⁶. O VPL do melhor indivíduo gerado pelo processo de otimização foi de US\$ 557,40 x 10⁶, representando uma eficácia de 94,9%.

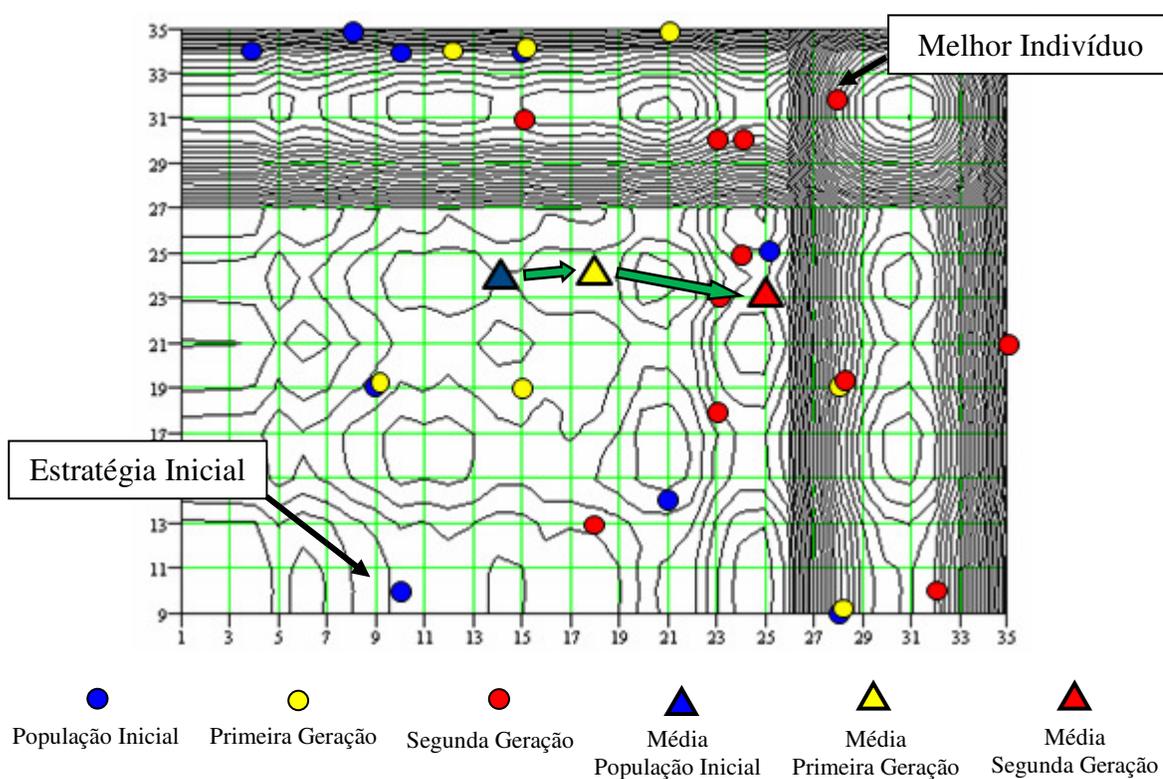


Figura 6.3 – Evolução da população no processo de otimização por algoritmo genético

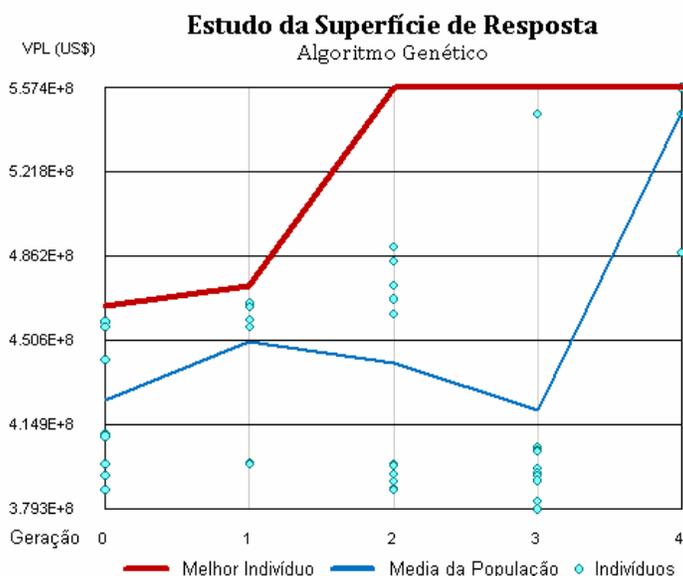


Figura 6.4 – Evolução do VPL no processo de otimização por algoritmo genético

A superfície de resposta para este caso simples de otimização já apresentou regiões de máximos locais. A tendência é que, ao aumentar a complexidade do problema, a complexidade da sua superfície de resposta também aumente. Portanto, a inadequação de métodos de otimização baseados no cálculo do gradiente da função-objetivo para a resolução de problemas com este tipo de superfície de resposta justifica o emprego de técnicas de otimização, que apesar de possuírem um custo computacional elevado, são mais adequadas para problemas que envolvam superfícies de respostas com estas características.

6.2 Etapa 2 – Otimização Determinística de Estratégias de Produção

6.2.1 Caso 2A - Estratégias com Poços Verticais

O processo de otimização, guiado pela rotina OPTIMUS (Figura 4.11), foi iniciado através da rotina PLUVIA de otimização da quantidade de poços por algoritmo genético. A Tabela 6.1 mostra os parâmetros do algoritmo genético utilizados neste passo do processo de otimização.

Tabela 6.1 - Parâmetros do algoritmo genético - Caso 2A

Parâmetro	Valor
Número de Indivíduos	12
Número de Gerações	35
Elite	1
Taxa de Mutação	0.05
Limite de Mutação	US\$ 20E6

A estratégia inicial possui VPL de US\$ $-195,56 \times 10^6$. Com a execução da rotina PLUVIA foi possível excluir 18 poços aumentando o VPL para US\$ $378,57 \times 10^6$. Figura 6.5 mostra as alterações realizadas pela rotina PLUVIA na estratégia inicial e como ficou a estratégia após a realização deste passo de otimização.

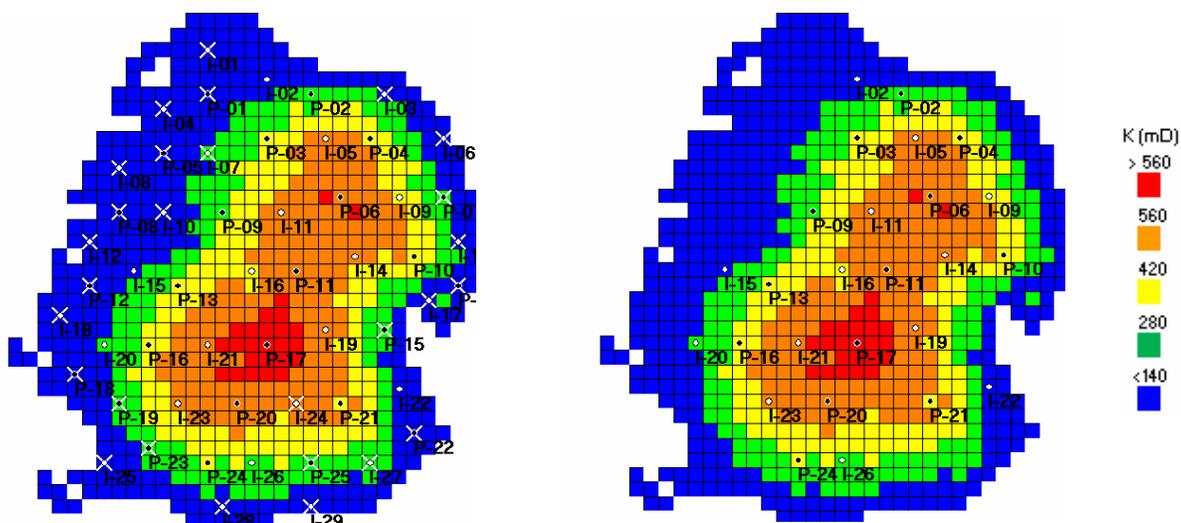


Figura 6.5 – Alterações realizadas pela rotina PLUVIA na estratégia inicial e a estratégia após a realização deste passo.

A Figura 6.6 apresenta a evolução do VPL ao longo deste processo de otimização. Neste passo foram executadas 177 simulações.

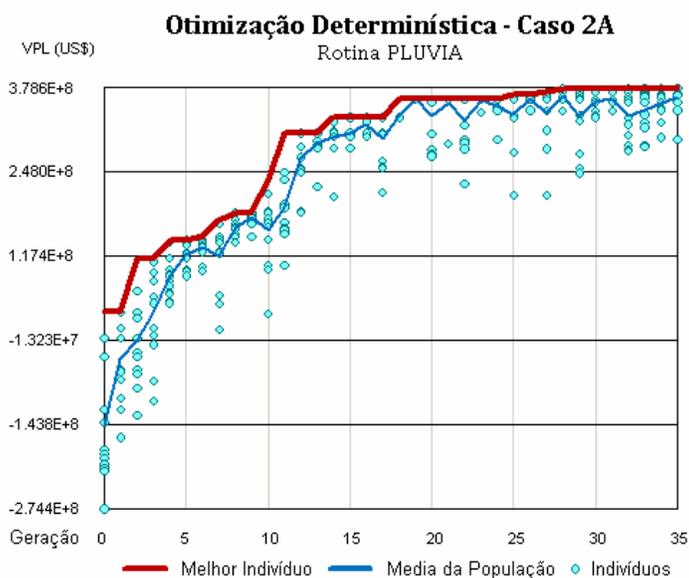


Figura 6.6 – Evolução do VPL ao longo da rotina PLUVIA – CASO 2A

A estratégia definida após a execução da rotina PLUVIA foi submetida à rotina DEO para a otimização dos posicionamentos dos poços. No processo foram adotados os mesmos parâmetros do algoritmo genético da PLUVIA. A Tabela 6.1 apresenta os valores destes parâmetros. Após a realização deste passo o VPL passou para US\$ $471,71 \times 10^6$. A Figura 6.7 mostra as alterações feitas pela rotina DEO na estratégia anterior e como ficou a estratégia após a realização deste passo.

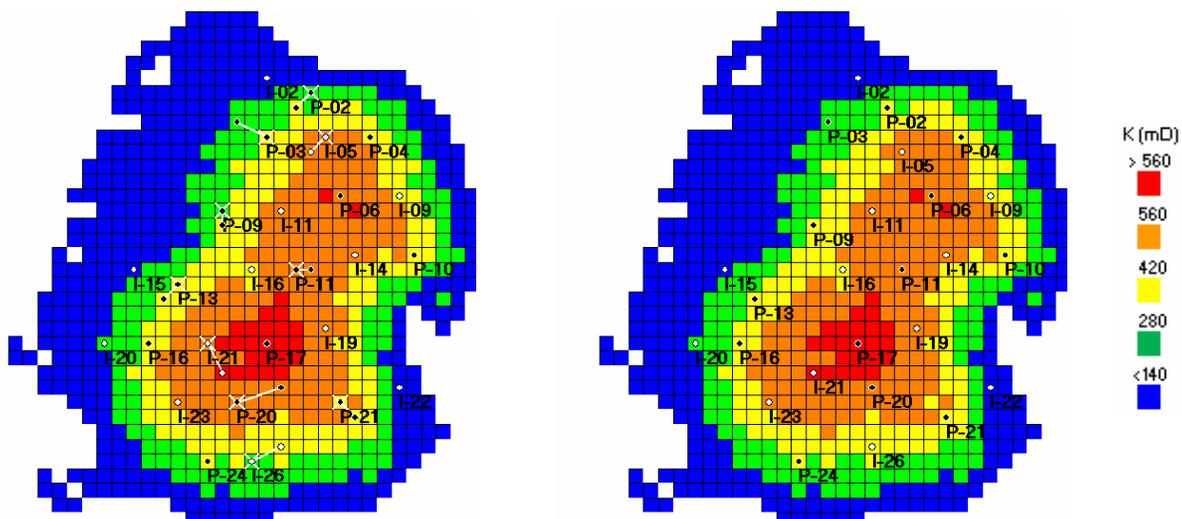


Figura 6.7 – Alterações realizadas pela rotina DEO na estratégia anterior e a estratégia após a realização deste passo.

O gráfico da Figura 6.8 representa a evolução do VPL ao longo deste processo de otimização. Neste passo, foram executadas 215 simulações, totalizando, ao longo do processo, até este passo, 392 simulações.

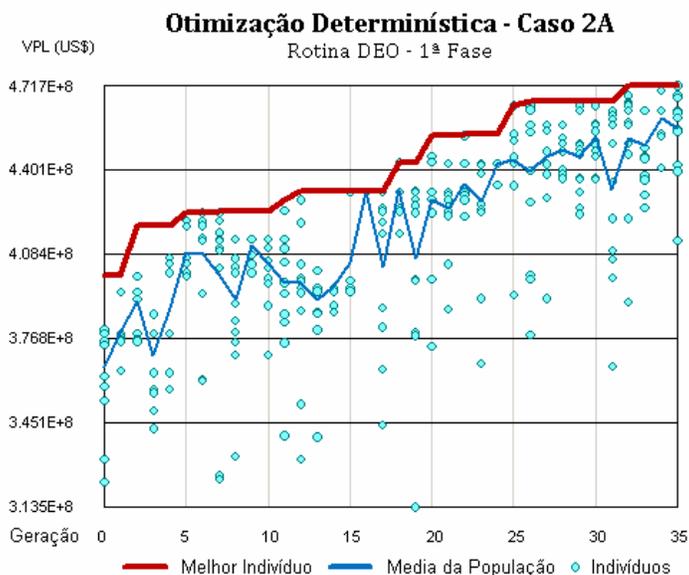


Figura 6.8 – Evolução do VPL ao longo da rotina DEO – 1ª Fase – CASO 2A

A estratégia definida no passo anterior foi submetida à rotina QUANTUM para otimização da quantidade de poços por exclusão seqüencial de poços de baixo desempenho. Após 155 simulações foram excluídos 6 poços fazendo o VPL atingir US\$ 566,21 x 10⁶. A Figura 6.9 mostra as alterações feitas pela rotina QUANTUM na estratégia anterior e como ficou a estratégia após a realização deste passo.

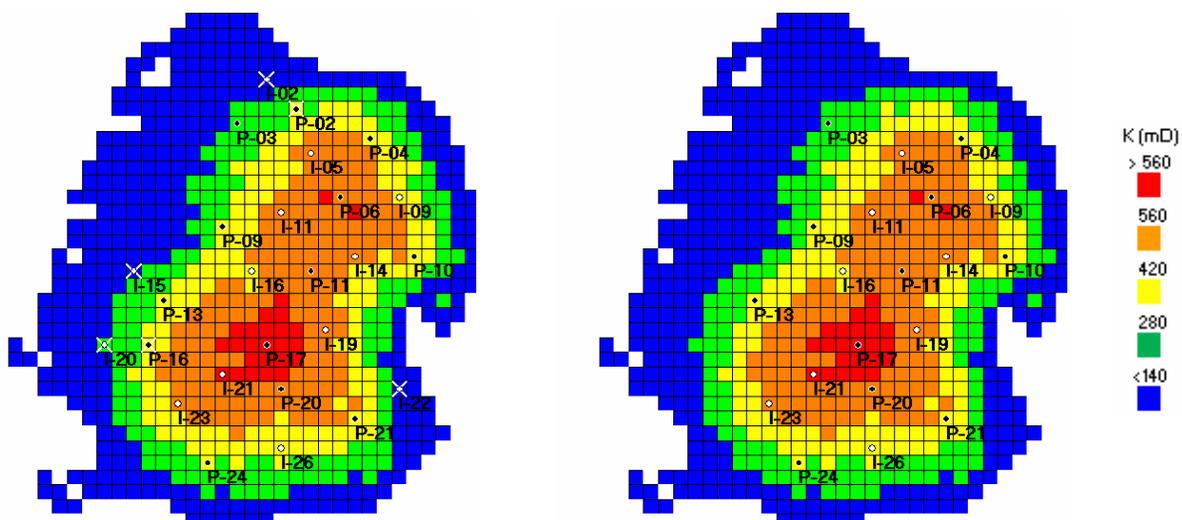


Figura 6.9 – Alterações realizadas pela rotina QUANTUM na estratégia anterior e a estratégia após a realização deste passo.

A estratégia definida no passo anterior foi submetida novamente à rotina DEO para realizar o re-posicionamento dos poços. Após 198 simulações o VPL passou para US\$ $587,59 \times 10^6$. A Figura 6.10 mostra as alterações feitas pela rotina DEO na estratégia anterior e como ficou a estratégia após a realização deste passo.

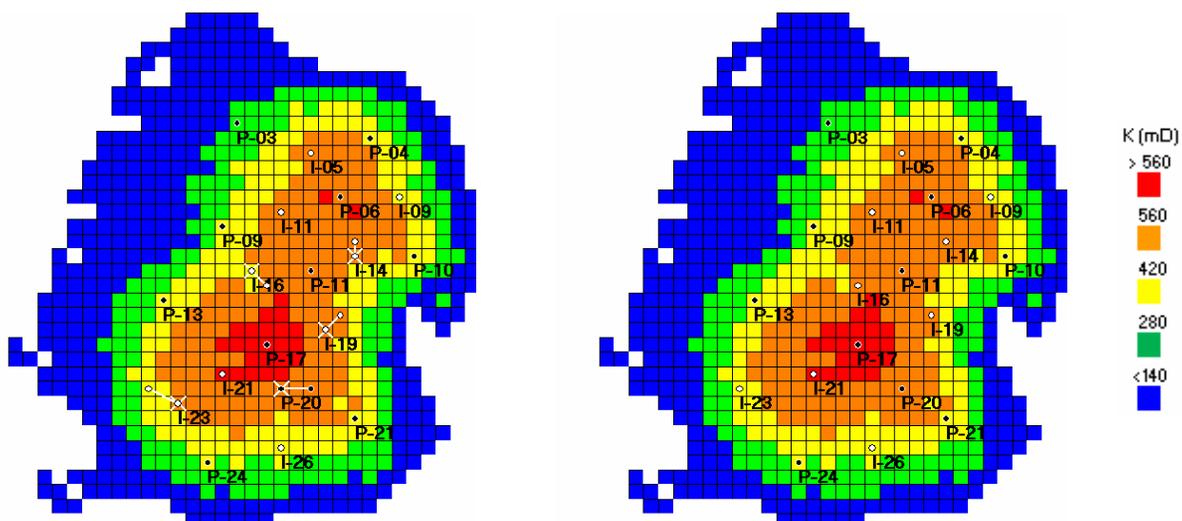


Figura 6.10 – Alterações realizadas pela rotina DEO na estratégia anterior e a estratégia como ficou após a realização deste passo.

O gráfico da Figura 6.11 representa a evolução do VPL ao longo da segunda fase de re-posicionamento dos poços.

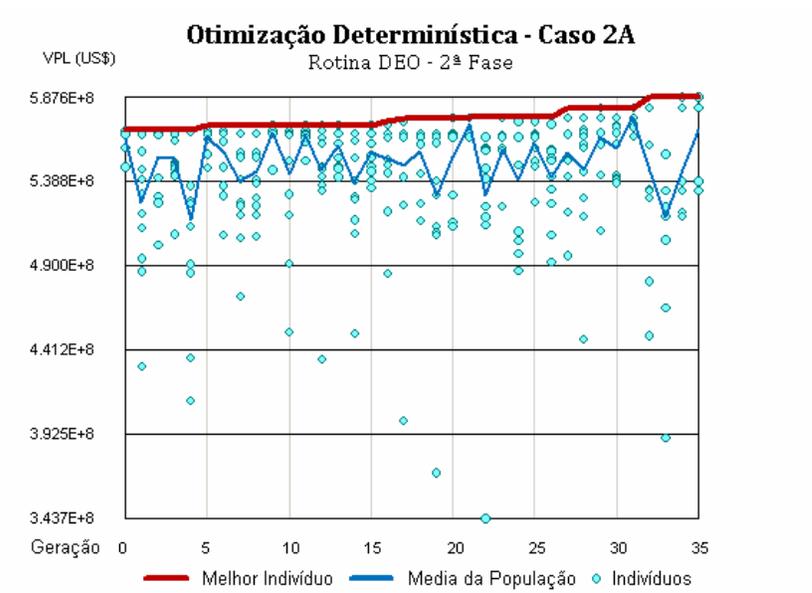


Figura 6.11 – Evolução do VPL ao longo da rotina DEO – 2ª Fase – CASO 2A

Após a realização deste passo, a estratégia foi submetida à rotina QUANTUM onde não foi possível excluir mais nenhum poço. Neste ponto a rotina OPTIMUS interrompe o processo e a estratégia definida no passo anterior é considerada otimizada.

A Tabela 6.2 resume o processo de otimização indicando inclusive o número e o tempo total de simulações que foram necessários para completar o processo. O tempo de simulação foi medido em uma máquina com processador Pentium IV de 3.4 GHz e com 4 Gb de memória RAM. Como os indivíduos de uma mesma geração são simulados independentemente, o processo é facilmente paralelizável, com potencial de redução significativa do tempo de otimização.

Tabela 6.2 - Processo de Otimização - Caso 2A

Passo	Rotina	VPL (MM US\$)	Estratégia	Poços			Núm. de Simulações		Tempo de Sim.
				Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial		-195.56	Figura 5.10	54	25	29			
1	PLUVIA	378.57	Figura 6.5	26	13	13	177	177	
2	DEO	471.71	Figura 6.7	26	13	13	215	392	
3	QUANTUM	566.21	Figura 6.9	20	11	9	155	547	
4	DEO	587.59	Figura 6.10	20	11	9	198	745	
5	QUANTUM	587.59	Figura 6.10	20	11	9	20	765	2,2 h

A Figura 6.12 mostra a evolução do VPL com o número de simulações realizadas. A estabilização ao final do processo indica a sua convergência. Apesar de não ser possível afirmar que se trata de um valor ótimo ou sub-ótimo, a confiança no processo é justificada pela extensa busca realizada no espaço solução.

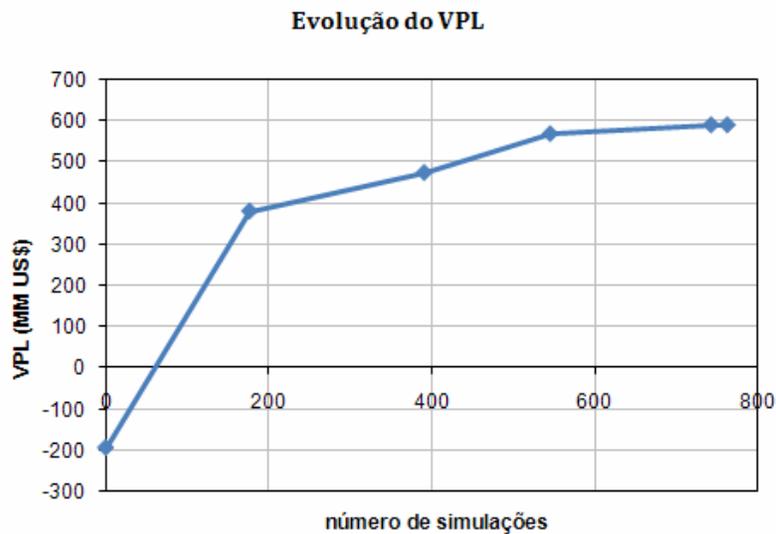


Figura 6.12 – Evolução do VPL com o número de simulações – CASO 2A

6.2.2 Caso 2B - Estratégias com Poços Horizontais

Diferentemente do caso anterior, de poços verticais, o Caso 2B possui apenas 12 poços em sua estratégia inicial, e conforme justificado no item 4.2.6 é inadequado utilizar a rotina PLUVIA

nestes casos. Nestas condições, o ideal é saltar os dois primeiros passos do fluxograma da Figura 4.11 e iniciar o processo de otimização com a rotina DEO e, ao longo do processo, alternar com passos de execução da rotina QUANTUM até o término da otimização.

A Tabela 6.3 apresenta os parâmetros do algoritmo genético utilizado neste caso.

Tabela 6.3 - Parâmetros do algoritmo genético - Caso 2B

Parâmetro	Valor
Número de Indivíduos	20
Número de Gerações	90
Elite	1
Taxa de Mutação	0.05
Limite de Mutação	US\$ 20E6

A Figura 6.13 mostra a evolução do VPL na execução da rotina DEO. O VPL passou de US\$ 287,13 x 10⁶ para US\$ 607,78 x 10⁶ após 599 simulações.

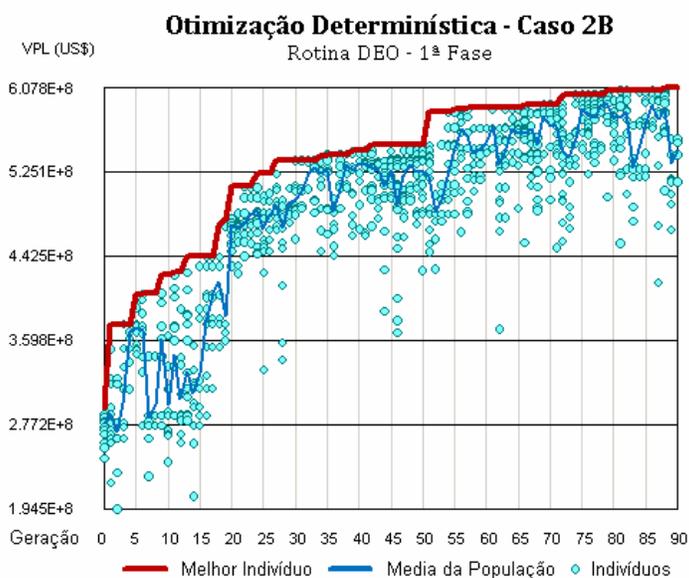


Figura 6.13 – Evolução do VPL ao longo da rotina DEO – 1ª Fase – CASO 2B

A Figura 6.14 mostra como ficaram re-arranjados os 12 poços da estratégia inicial após este processo.

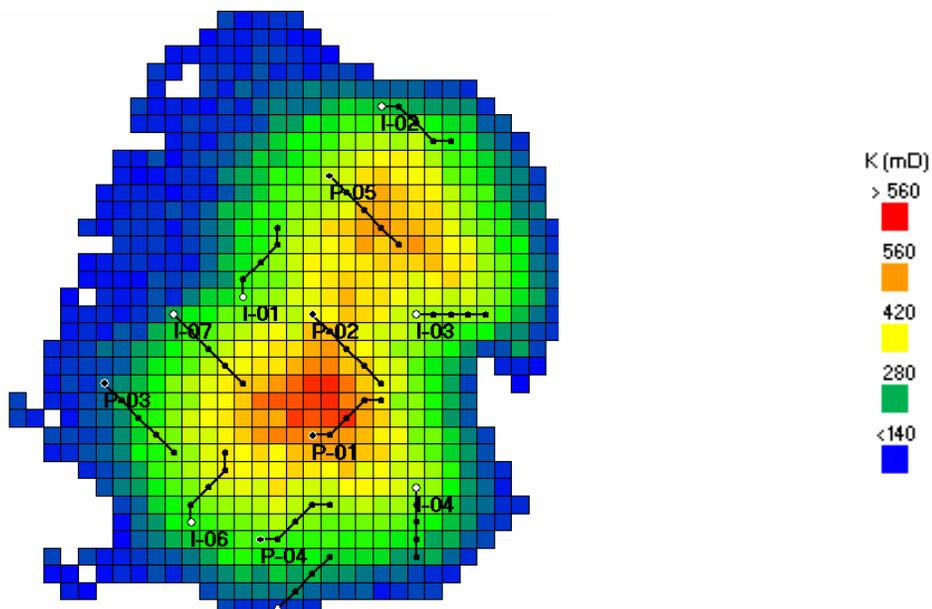


Figura 6.14 – Estratégia de produção após a execução da rotina DEO – 1ª Fase – CASO 2B

O passo seguinte é a execução da rotina QUANTUM que após 24 simulações indicou a exclusão de um poço injetor (I-05), fazendo o VPL aumentar para US\$ 633,82 x 10⁶. A exclusão deste poço gera a oportunidade de realizar um novo re-arranjo dos poços através da rotina DEO. A Figura 6.15 mostra a evolução do VPL ao longo deste passo do processo. O VPL final alcançado neste passo foi de US\$ 669,09 x 10⁶ após 638 simulações. A rotina QUANTUM foi executada e após 11 simulações concluiu-se que não era possível excluir mais nenhum poço.

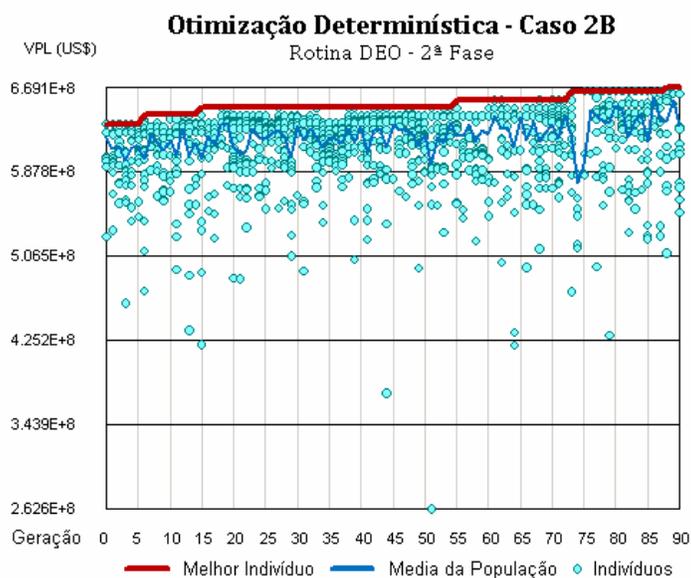


Figura 6.15 – Evolução do VPL ao longo da rotina DEO – 2ª Fase – CASO 2B

A Figura 6.16 apresenta a estratégia otimizada. Observa-se que houve uma mudança em relação ao plano de drenagem inicial. A estratégia inicial (Figura 5.10) foi concebida para que a drenagem fosse feita através de injeção periférica com produção central. O processo de otimização alterou esta idéia inicial alternando poços injetores e produtores.

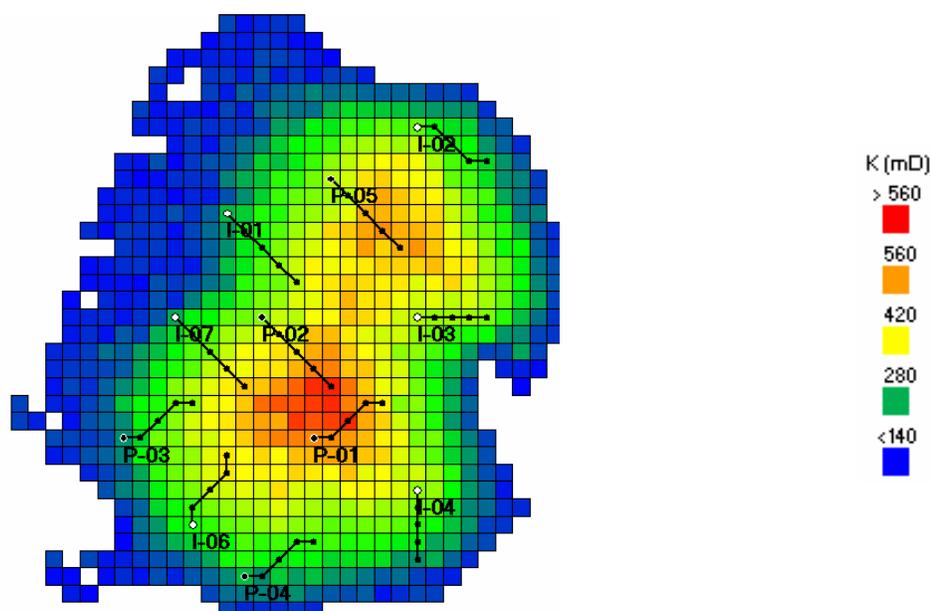


Figura 6.16 – Estratégia de produção após a execução da rotina DEO – 2ª Fase – CASO 2B

Tabela 6.4 mostra um resumo do processo de otimização para este caso.

Tabela 6.4 - Processo de Otimização - Caso 2B

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial		287,17	12	5	7			
1	DEO	607,78	12	5	7	599	599	
2	QUANTUM	633,82	11	5	6	24	623	
3	DEO	669,09	11	5	6	638	1261	
4	QUANTUM	669,09	11	5	6	11	1272	4,2

A Figura 6.12 mostra a evolução do VPL com o número de simulações realizadas. A estabilização ao final do processo indica a sua convergência. Como no caso anterior, apesar de não ser possível afirmar que se trata de um valor ótimo ou sub-ótimo a confiança no processo é justificada pela extensa busca realizada no espaço solução.

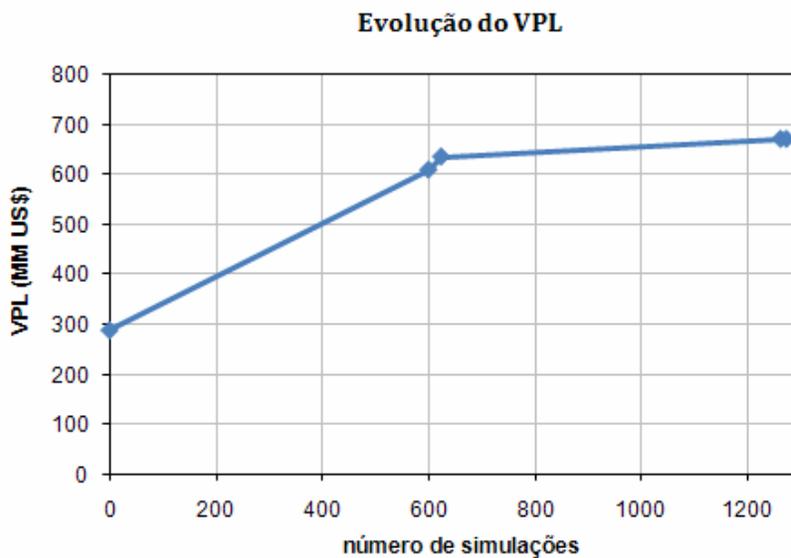


Figura 6.17 – Evolução do VPL com o número de simulações – CASO 2B

A realização destes dois casos exemplifica a utilidade que uma ferramenta de otimização assistida pode ter em um processo de seleção de estratégias de produção. Este tipo de ferramenta não possui aplicação apenas no refinamento de uma estratégia de produção; ela pode subsidiar o processo de uma forma mais abrangente. Nos Casos 2A e 2B, foram testadas duas concepções diferentes para a estratégia de produção de um mesmo campo. Se a intenção fosse escolher entre a utilização de poços horizontais ou verticais, os resultados destas serviriam de auxílio no processo de tomada de decisão. Outras concepções poderiam ser testadas como adoção de uma estratégia mista, utilização de poços inteligentes, utilização de poços multi-laterais entre outras para garantir uma seleção feita de forma robusta. Portanto, a adoção de uma ferramenta deste tipo em um processo de seleção de estratégia de produção, como o proposto por Mezzomo (2005), permite realizar um número maior de análises, propiciando decisões mais seguras.

6.3 Etapa 3 – Otimização Probabilística de Estratégias de Produção

Nesta etapa, são apresentados os resultados das otimizações realizadas nos casos estruturados na Etapa 3 definida no Capítulo 5.

As otimizações, sob incertezas são feitas através da MADC e da MADI para possibilitar a comparação dos seus desempenhos. Portanto, as estratégias de produção otimizadas nestes processos devem estar o mais próximo possível do máximo global das suas funções-objetivo. A comparação somente será justa se todas as estratégias estiverem próximas do seu potencial máximo. Por sua vez, resultados de processos de otimização baseados em procedimentos estocásticos podem apresentar pequenas dispersões, ou seja, a repetição de um processo de otimização deste tipo, em um problema da magnitude do que está sendo analisado, dificilmente conduzirá ao mesmo resultado obtido anteriormente. Possivelmente os resultados estarão próximos, mas apresentarão uma pequena dispersão. Para garantir que a comparação seja feita de forma adequada, os processos de otimização devem ser realizados de forma exaustiva, tendo em vista que, mesmo pequenas, variações podem comprometer a análise dos resultados.

É importante observar que guiar processos de otimização sob incertezas com esta abordagem somente tem sentido caso o intuito seja comparar resultados de metodologias. Quando não se tem este objetivo, é inadequado realizar uma busca tão exaustiva, dado que o ganho que se

tem, ao adotar um procedimento deste tipo, geralmente é insignificante em relação ao impacto das incertezas.

Com propósito de realizar esta busca exaustiva para comparar as metodologias, todas as otimizações dos Casos 3A, 3B e 3C são iniciadas pela rotina PLUVIA de otimização da quantidade de poços por algoritmo genético e as sete melhores estratégias obtidas neste passo prosseguirão no processo de otimização, gerando uma ramificação do processo de busca. Isto permite varrer ainda mais o espaço solução do problema garantindo que as comparações das abordagens para as incertezas sejam feitas de forma adequada.

No Caso 3D, também é realizada a comparação entre as metodologias, mas os processos de otimização não sofrem ramificações. Neste caso as metodologias de consideração de incertezas MADC e MADI têm desempenhos muito discrepantes fazendo que seja desnecessário o refinamento do processo de otimização.

6.3.1 Caso 3A - Incertezas Geológicas sem Compartimentação do Reservatório

Neste caso, o reservatório é representado pelo grupo MGR_1 considerando somente cenário econômico intermediário. É otimizada uma estratégia composta somente por poços verticais.

Otimização pela MADI

A Figura 6.18 mostra o processo de otimização pela MADI, onde foi realizado o processo de ramificação. O trecho inicial (curva de cor vermelha) da curva de evolução do VME representa a evolução do processo durante a execução da rotina PLUVIA. As sete melhores estratégias obtidas neste passo seguem o processo de otimização. Cada um dos ramos coloridos representa a continuidade do processo para cada uma das sete melhores estratégias obtidas pela rotina PLUVIA. Neles estão agrupadas as evoluções realizadas pelas estratégias, pela alternância das rotinas DEO e QUANTUM até o final do processo.

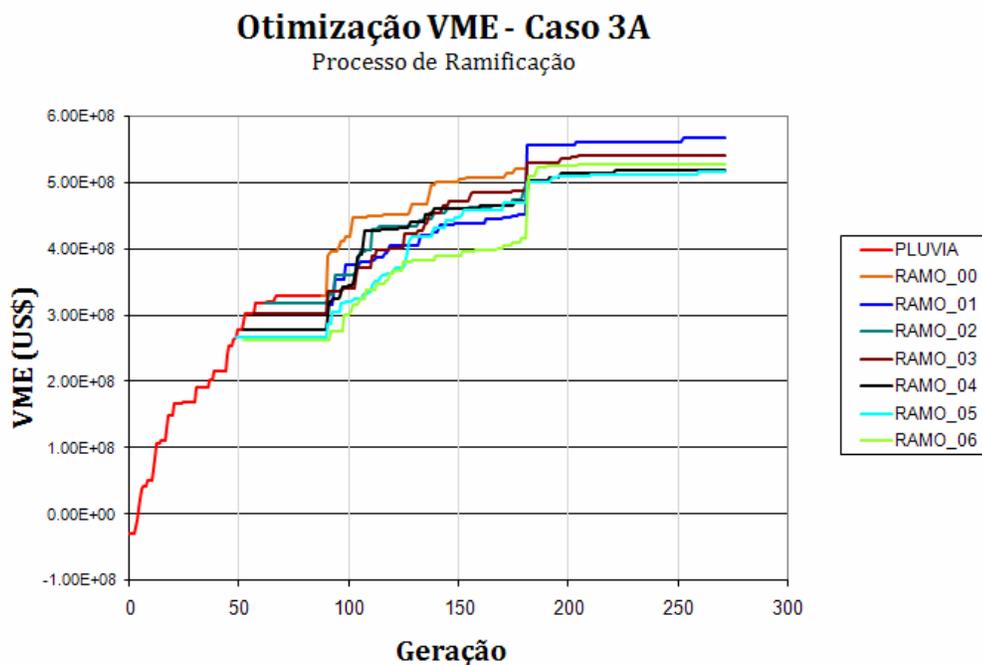


Figura 6.18 – Processo de Ramificação – CASO 3A – Otimização pela MADI

A Tabela 6.5 resume o processo de otimização para o melhor ramo (ramo_01 indicado pela curva de cor azul da Figura 6.18). Como não há informação relevante nos processos de otimização dos outros seis ramos perdedores, estes não são apresentados em forma de tabela.

Tabela 6.5 - Processo de Otimização - Caso 3A – E_MADI

Passo	Rotina	VME (MM US\$)	Poços			Núm. de Simulações ⁹		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial			54	25	29			
1	PLUVIA	253,92	21	12	9	1122	1122	3,7
2	DEO	451,51	21	12	9	1245	2367	7,9
3	QUANTUM	496,01	16	9	7	333	2700	9,0
4	DEO	555,75	16	9	7	1035	3735	12,5
5	QUANTUM	567,77	16	9	7	48	3783	12,6

⁹O número de simulações realizadas em cada etapa do processo de otimização do Caso 3A é estimado a partir do tempo de simulação de cada etapa. Para os Casos 3B, 3C e 3D o número de simulações é exato, já que foi implementado um contador para as simulações realizadas.

Otimização pela MADC

O mesmo procedimento de ramificação realizado na otimização pela MADI é adotado na otimização pela MADC. As Tabelas 6.6, 6.7 e 6.8 resumem os processos de otimização indicando a evolução do ramo vencedor de cada processo. As estratégias otimizadas para cada ramo da árvore de decisão receberão um nome que fará referência ao modelo geológico e cenário econômico para os quais foi otimizada.

Tabela 6.6 - Processo de Otimização - Caso 3A – E_GPEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial			54	25	29			
1	PLUVIA	-12,78	21	12	9	387	387	1,3
2	DEO	117,21	21	12	9	413	800	2,7
3	QUANTUM	153,24	18	10	8	36	836	2,8
4	DEO	168,47	18	10	8	355	1191	4,0
5	QUANTUM	189,92	16	8	8	32	1223	4,1
6	DEO	198,81	16	8	8	399	1622	5,4
7	QUANTUM	198,81	16	8	8	16	1638	5,4

Tabela 6.7 - Processo de Otimização - Caso 3A – E_GIEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial			54	25	29			
1	PLUVIA	423,05	21	12	9	417	417	1,4
2	DEO	468,67	21	12	9	388	805	2,7
3	QUANTUM	508,58	18	10	8	78	883	2,9
4	DEO	591,11	18	10	8	342	1225	4,1
5	QUANTUM	619,74	17	9	8	34	1259	4,2
6	DEO	631,35	17	9	8	311	1570	5,2
7	QUANTUM	634,00	16	8	8	32	1602	5,3
8	DEO	636,69	16	8	8	273	1875	6,2
9	QUANTUM	636,69	16	8	8	16	1891	6,3

Tabela 6.8 - Processo de Otimização - Caso 3A – E_GOEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	715,04	19	12	7	386	386	1,3
2	DEO	845,09	19	12	7	402	788	2,6
3	QUANTUM	846,79	18	11	7	36	824	2,7
4	DEO	887,28	18	11	7	784	1608	5,3
5	QUANTUM	887,28	18	11	7	18	1626	5,4

Resultados Finais para o Caso 3A

A Tabela 6.9 sintetiza os resultados para o Caso 3A. Nela são apresentados os desempenhos de todas as estratégias otimizadas em todos os ramos da árvore de decisão. Para comparar os desempenhos das metodologias MADC e MADI devem-se comparar o desempenho da estratégia otimizada pela MADI com o desempenho da estratégia E_GIEI, já que esta apresentou o maior VME dentre as estratégias otimizadas pela MADC.

A Figura 6.19 mostra as curvas de riscos para as estratégias otimizadas, nela é possível observar que a diferença mais relevante entre a estratégia otimizada pela MADI e a estratégia otimizada pela MADC se apresenta nos seus VPL no modelo pessimista (GP). O melhor desempenho da estratégia otimizada pela MADI neste modelo faz com que esta possua um VME maior que o da estratégia otimizada MADC.

Tabela 6.9 - Resultados Finais - Caso 3A

CASO_03A

ESTRATÉGIA	RESULTADOS						
	VME (MM US\$)	VPL NO MODELO GP (MM US\$)	VPL NO MODELO GI (MM US\$)	VPL NO MODELO GO (MM US\$)	POÇOS	PRODUTORES	INJETORES
E_MADI	567,77	885,28	636,65	179,30	16	9	7
E_GPEI	536,35	887,28	597,70	122,22	18	11	7
E_GIEI	558,97	883,44	636,69	154,41	16	8	8
E_GOEI	527,49	802,02	580,00	198,81	16	8	8

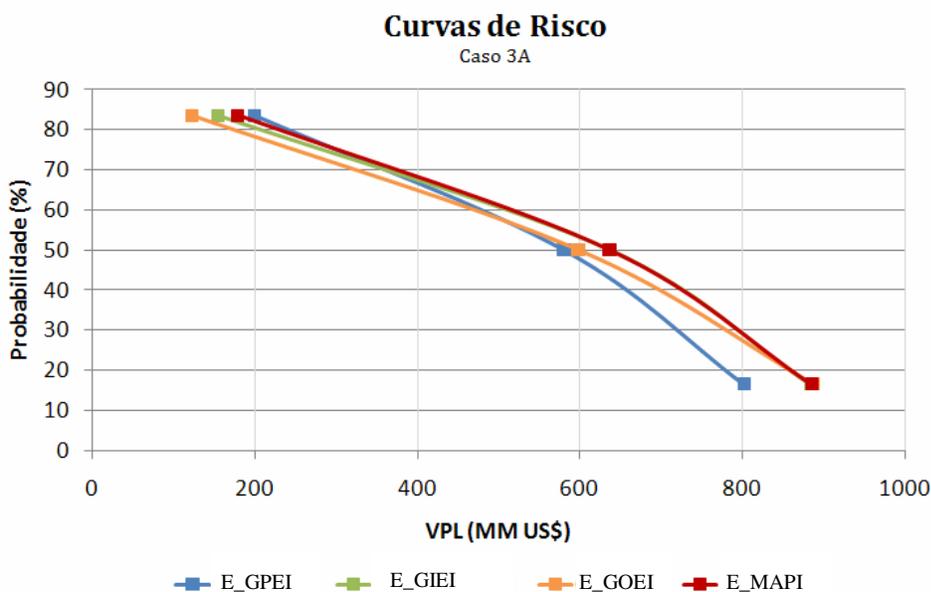


Figura 6.19 – Curvas de Risco Caso 3A

Observa-se que os valores máximos dos VPL de cada MGR são obtidos quando a otimização é guiada considerando o VPL daquele MGR como função-objetivo. O mesmo ocorre com o VME, que é maximizado quando é utilizado como função-objetivo. Isto mostra que os processos de otimização foram realizados de forma adequada.

Outro ponto de relevância é o fato da estratégia otimizada pela MADI não possuir o melhor VPL para nenhum MGR. Apesar disso, ela possui o maior VME do grupo. Isso mostra que a estratégia otimizada pela MADI mais adaptável às incertezas, ela tende a possuir um

comportamento mais uniforme em todos os modelos. A estratégia E_GOEI, por exemplo, possui o máximo VPL no modelo GO, mas, por outro lado, possui pior VPL no modelo GP. Já a estratégia otimizada pela MADI possui um bom desempenho tanto no modelo GP quanto no modelo GO (pode-se incluir o intermediário também), gerando o melhor VME.

Para o caso em questão as diferenças entre os VPL das estratégias otimizadas foram pequenas e tal fato motivou a realização do procedimento de otimização por ramificação. Se não fosse realizado um procedimento exaustivo de otimização, a tendência é que houvesse inversão dos alguns dos valores máximos para os VPL dos MGR. Poder-se-ia comparar valores sub-ótimos, comprometendo a análise dos resultados.

A diferença de desempenho, em termos de VME, entre a MADI e a MADC, para este caso, foi pequena (US\$ $8,8 \times 10^6$), mas como não há aumento do custo computacional (pelo contrário, houve redução) ao se adotar a MADI, qualquer ganho deve ser considerado.

O tempo total de simulação para a otimização pela MADI foi de 12,6 horas (simulação do melhor ramo), foi inferior à soma dos tempos de simulação dos melhores ramos das otimizações pela MADC 17,1 horas. Estes tempos representam, em termos de número de simulações, aproximadamente 3780 e 5130¹⁰ simulações respectivamente. O número de simulações foi muito superior ao realizado nos Casos 2A e 2B, devido à necessidade de realizar a comparação entre as metodologias de consideração das incertezas. O Caso 2A, por exemplo, representa a otimização do modelo GI do Caso 3A. Na otimização da estratégia de produção para este modelo no Caso 2A obteve-se um VPL de US\$ $587,59 \times 10^6$, com 765 simulações. Este mesmo modelo, no Caso 3A, foi obtido um VPL de US\$ $636,69 \times 10^6$, com aproximadamente 1890 simulações. Portanto, com apenas 40% das simulações realizadas na otimização do modelo intermediário no Caso 3A, a otimização no Caso 2A obteve uma eficácia de 94,3%.

¹⁰ As simulação levam, em média, 12 segundos de processamento em uma máquina equipada com processador Pentium IV de 3.4 Ghz e 4 Gb de memória RAM.

6.3.2 Caso 3B – Incertezas Geológicas com Compartimentação do Reservatório

Neste caso será estudado o impacto gerado, nos desempenhos das metodologias, pela adoção de uma complexidade geológica maior como é o caso da compartimentação do reservatório. As duas metodologias são utilizadas para otimizar estratégias de produção nos modelos que compõe o MGR₂.

Como no caso anterior, é adotado o procedimento de ramificações e os resultados, para os ramos vencedores, são apresentados nas Tabelas 6.10, 6.11 e 6.12. A estratégia para o modelo GO foi otimizada no caso anterior e seus resultados são aproveitados neste caso.

Otimização pela MADI

Tabela 6.10 - Processo de Otimização - Caso 3B – E_MADI

Passo	Rotina	VME (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	315,94	19	11	8	1179	1179	
2	DEO	432,42	19	11	8	1263	2442	
3	QUANTUM	452,12	18	11	7	108	2550	
4	DEO	466,73	18	11	7	1128	3678	
5	QUANTUM	466,73	18	11	7	54	3732	12,4

Otimização pela MADC

Tabela 6.11 - Processo de Otimização - Caso 3B – E_GPcEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	-26,77	25	13	12	420	420	
2	DEO	27,80	25	13	12	498	918	
3	QUANTUM	40,15	24	13	11	48	966	
4	DEO	47,74	24	13	11	463	1429	
5	QUANTUM	47,74	24	13	11	24	1453	4,8

Tabela 6.12 - Processo de Otimização - Caso 3C – E_GIcEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	479,19	21	12	9	397	397	
2	DEO	543,77	21	12	9	510	907	
3	QUANTUM	561,52	18	10	8	75	982	
4	DEO	570,45	18	10	8	386	1368	
5	QUANTUM	570,45	18	10	8	18	1386	4,6

Resultados Finais para o Caso 3B

A Tabela 6.13 resume os resultados obtidos neste caso. A comparação entre as metodologias deve ser feita comparando os desempenhos das estratégias E_MADI e E_GOEI já que este apresentou o máximo VME entre as estratégias otimizadas pela MADC.

A diferença entre o VME da estratégia otimizada pela MADI e o VME da estratégia otimizada pela MADC foi maior que a anterior, US\$ 28,01 x 10⁶, e se aproximou do custo de 1 poço US\$ 35,00 x 10⁶. Um ponto interessante pode ser observado: a adoção da estratégia indicada pela MADC (otimizada pelo VPL do modelo GO) implica em risco de prejuízo caso a geologia da região se aproxime do modelo pessimista, o que não ocorre com a estratégia otimizada pela MADI.

A Figura 6.20 mostra as curvas de risco para as estratégias otimizadas. O comportamento da curva de risco para a estratégia otimizada pela MADI mostra que apesar dela não possuir o VPL máximo em nenhum modelo de fluxo, ela está sempre confortavelmente à direita do gráfico. O seu desempenho está sempre entre os melhores desempenhos em todos os modelos geológicos representativos.

Novamente, neste caso o número de simulações necessárias para a otimização do ramo principal pela MADI, de 3732 simulações, foi inferior a soma das simulações necessárias para otimizar o ramo vencedor da otimização feita pela MADC, de 4465 simulações.

Tabela 6.13 - Resultados Finais - Caso 3B

CASO_03B

ESTRATÉGIA \ RESULTADOS	VME (MM US\$)	VPL NO MODELO GPC (MM US\$)	VPL NO MODELO GIC (MM US\$)	VPL NO MODELO GO (MM US\$)	POÇOS	PRODUTORES	INJETORES
E_MADI	466,73	827,46	560,61	9,29	18	11	7
E_GPCeI	438,72	887,28	513,33	-86,71	18	11	7
E_GIcEI	393,10	784,64	570,45	-181,17	18	10	8
E_GOEI	387,81	668,50	445,41	47,74	24	13	11

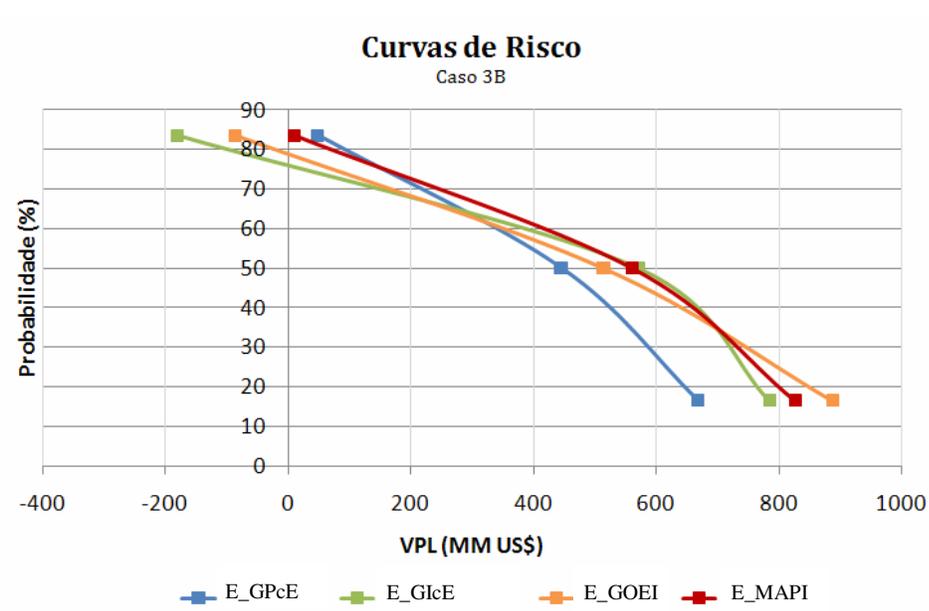


Figura 6.20 – Curvas de Risco Caso 3B

6.3.3 Caso 3C – Incertezas Econômicas

Neste caso será estudado o impacto gerado, nos desempenhos das metodologias, pela consideração apenas de incertezas econômicas. As duas metodologias são utilizadas para otimizar estratégias de produção no modelo geológico otimista considerando os três cenários econômicos (EP, EI e EO).

Como nos casos anteriores, é adotado o procedimento de otimização por ramificações e os resultados, para os ramos vencedores, são apresentados nas Tabelas 6.14, 6.15 e 6.16. O VPL para o cenário econômico EI foi otimizado no Caso 3A e seus resultados são aproveitados neste caso.

Otimização pela MADI

Tabela 6.14 - Processo de Otimização - Caso 3C – E_MADI

Passo	Rotina	VME (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	1254,3	22	13	9	1281	1281	
2	DEO	1336,4	22	13	9	1326	2607	
3	QUANTUM	1358,9	20	12	8	183	2790	
4	DEO	1374,2	20	12	8	1026	3816	
5	QUANTUM	1374,2	20	12	8	60	3876	12,9

Otimização pela MADC

Tabela 6.15 - Processo de Otimização - Caso 3C – E_GIEP

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	-153,23	12	7	5	354	354	
2	DEO	-34,02	12	7	5	432	786	
3	QUANTUM	0,17	9	5	4	39	825	
4	DEO	10,42	9	5	4	263	1088	
5	QUANTUM	10,42	9	5	4	9	1097	3,7

Tabela 6.16 - Processo de Otimização - Caso 3C – E_GIEO

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	3068,9	28	16	12	475	475	
2	DEO	3170,4	28	16	12	594	1069	
3	QUANTUM	3187,7	26	15	11	79	1148	
4	DEO	3255,5	26	15	11	568	1716	
5	QUANTUM	3269,2	25	14	11	50	1766	
6	DEO	3310,2	25	14	11	545	3211	
7	QUANTUM	3326,7	24	14	10	48	2359	
8	DEO	3354,0	24	14	10	488	2847	
9	QUANTUM	3354,0	24	14	10	24	2871	9,6

Resultados Finais para o Caso 3C

A Tabela 6.17 resume os resultados obtidos neste caso. A comparação entre as metodologias deve ser feita através da análise dos desempenhos das estratégias otimizadas pela MADI e a E_GIEI.

A diferença de desempenho entre as metodologias foi bem sutil neste caso. As estratégias otimizadas pela MADI e a E_GIEI possuem VPL bem semelhantes no cenário econômico

intermediário. A estratégia otimizada pela MADI possui desempenho superior no cenário EO, entretanto o risco de prejuízo caso se confirme o cenário pessimista (EP) é maior.

A E_GIEP possui o menor VME dentre as estratégias otimizadas, entretanto foi a única estratégia que eliminou completamente o risco de prejuízo. Outro ponto interessante de analisar com relação a esta estratégia é o retorno sobre investimento (ROI). Ao utilizar apenas 9 poços ela tende a apresentar um ROI muito superior às demais estratégias, fazendo com que a decisão quanto à seleção da estratégia não seja tão trivial. É importante citar que o seu VME foi prejudicado em relação aos das demais estratégias pelo fato de considerar fixo o investimento em facilidades de produção. Com uma variação tão expressiva do número de poços, para se realizar uma análise mais criteriosa, ter-se-ia que considerar o investimento em facilidade de produção proporcional a quantidade de poços.

A Figura 6.21 mostra as curvas de risco para as estratégias otimizadas. Os comportamentos das curvas de risco são bem semelhantes. A maior discrepância se dá para os VPL das estratégias E_GIEP e E_GIEO no cenário EO. Observa-se ainda que o desempenho da estratégia otimizada pela MADI está sempre entre os melhores desempenhos em todos os modelos.

Neste caso também, o número de simulações necessárias para a otimização do ramo vencedor pela MADI, 3876 simulações, foi inferior a soma das simulações necessárias para otimizar o ramo vencedor da otimização pela MADC, 5570 simulações.

Tabela 6.17 - Resultados Finais - Caso 3C

CASO_03C

ESTRATÉGIA \ RESULTADOS	VME (MM US\$)	VPL NO CENÁRIO EP (MM US\$)	VPL NO CENÁRIO EI (MM US\$)	VPL NO CENÁRIO EO (MM US\$)	POÇOS	PRODUTORES	INJETORES
E_MADI	1374	3343	883	-88,7	20	12	8
E_GIEP	1324	3354	828	-196,0	24	14	10
E_GIEI	1370	3289	887	-51,0	18	11	7
E_GIEO	1142	2692	735	10,0	9	5	4

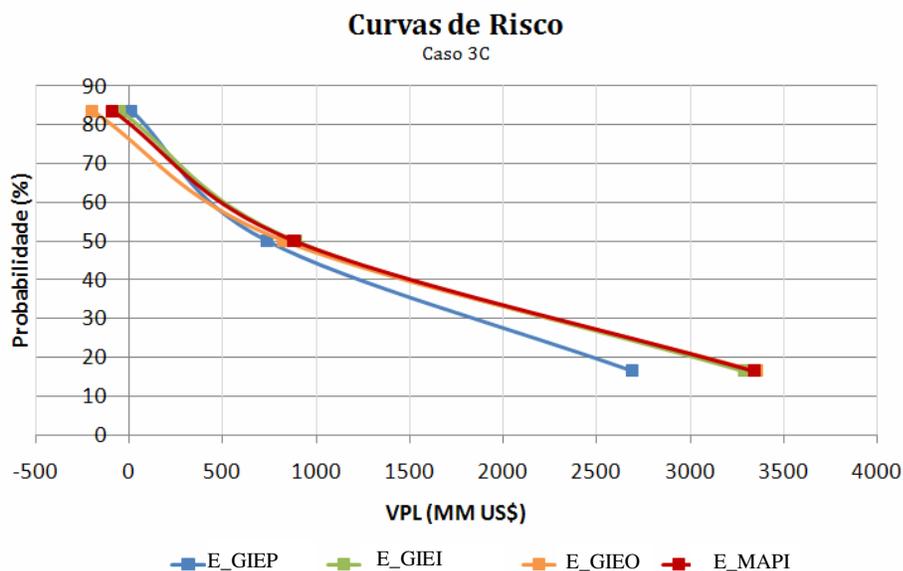


Figura 6.21 – Curvas de Risco Caso 3C

6.3.4 Caso 3D – Incertezas Geológicas com Compartimentação do Reservatório e Incertezas Econômicas

Neste item, é estudado um caso mais global que envolve tanto incertezas geológicas quanto econômicas. São considerados os três cenários econômicos (EP, EI e EO) e os modelos geológicos do grupo MGR₂. As duas metodologias, MADI e MADC, são utilizadas para otimizar estratégias de produção com todas estas incertezas.

Neste caso não é adotado o procedimento de otimização por ramificações conforme descrito no início deste capítulo. Os resultados das otimizações são apresentados nas Tabelas de 6.18 a 6.27.

Otimização pela MADI

Tabela 6.18 - Processo de Otimização - Caso 3D – E_MADI

Passo	Rotina	VME (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	708.01	20	12	8	1401	1401	4.67
2	DEO	803.1	20	12	8	1305	2706	9.02
3	QUANTUM	819.18	18	11	7	165	2871	9.57
4	DEO	849.62	18	11	7	1149	4020	13.40
5	QUANTUM	849.62	18	11	7	54	4074	13.58

Otimização pela MADC

Tabela 6.19 - Processo de Otimização - Caso 3D – E_GPEP

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	-561.95	14	7	7	650	650	2.17
2	DEO	-485.72	14	7	7	399	1049	3.50
3	QUANTUM	-485.51	13	7	6	26	1075	3.58
4	DEO	-468.73	13	7	6	343	1418	4.73
5	QUANTUM	-468.73	13	7	6	13	1431	4.77

Tabela 6.20 - Processo de Otimização - Caso 3D – E_GPEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	-81.1	17	10	7	622	622	2.07
2	DEO	42.57	17	10	7	385	1007	3.36
3	QUANTUM	43.75	16	9	7	32	1039	3.46
4	DEO	56.84	16	9	7	435	1474	4.91
5	QUANTUM	56.84	16	9	7	16	1490	4.97

Tabela 6.21 - Processo de Otimização - Caso 3D – E_GPEO

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	1389.5	24	13	11	663	663	2.21
2	DEO	1595.4	24	13	11	418	1081	3.60
3	QUANTUM	1595.4	24	13	11	24	1105	3.68

Tabela 6.22 - Processo de Otimização - Caso 3D – E_GIEP

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	-264.2	12	7	5	693	693	2.31
2	DEO	-187.47	12	7	5	308	1001	3.34
3	QUANTUM	-187.47	12	7	5	12	1013	3.38

Tabela 6.23 - Processo de Otimização - Caso 3D – E_GIEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	431.92	19	12	7	620	620	2.07
2	DEO	526.92	19	12	7	700	1320	4.40
3	QUANTUM	534.61	18	11	7	38	1358	4.53
4	DEO	557.4	18	11	7	397	1755	5.85
5	QUANTUM	557.4	18	11	7	18	1773	5.91

Tabela 6.24 - Processo de Otimização - Caso 3D – E_GIEO

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	2552.4	29	16	13	639	639	2.13
2	DEO	2691.7	29	16	13	494	1133	3.78
3	QUANTUM	2691.8	28	15	13	56	1189	3.96
4	DEO	2736.7	28	15	13	453	1642	5.47
5	QUANTUM	2737.4	27	14	13	54	1696	5.65
6	DEO	2748.1	27	14	13	451	2147	7.16
7	QUANTUM	2748.1	27	14	13	27	1669	5.56

Tabela 6.25 - Processo de Otimização - Caso 3D – E_GOEP

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	-90.9	11	7	4	632	632	2.11
2	DEO	-20.38	11	7	4	299	931	3.10
3	QUANTUM	-10.45	10	6	4	20	951	3.17
4	DEO	32.7	10	6	4	242	1193	3.98
5	QUANTUM	32.7	10	6	4	10	1203	4.01

Tabela 6.26 - Processo de Otimização - Caso 3D – E_GOEI

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	719.26	18	12	6	634	634	2.11
2	DEO	835.79	18	12	6	445	1079	3.60
3	QUANTUM	845.82	16	10	6	49	1128	3.76
4	DEO	861.98	16	10	6	358	1486	4.95
5	QUANTUM	861.98	16	10	6	16	1502	5.01

Tabela 6.27 - Processo de Otimização - Caso 3D – E_GOEO

Passo	Rotina	VPL (MM US\$)	Poços			Núm. de Simulações		Tempo de Sim.
			Total	Prod.	Inj.	Passo	Acum.	Acum.
Inicial								
1	PLUVIA	3073.7	31	16	15	644	644	2.15
2	DEO	3261.5	31	16	15	580	1224	4.08
3	QUANTUM	3294.1	26	14	12	166	1390	4.63
4	DEO	3301.5	26	14	12	379	1769	5.90
5	QUANTUM	3301.5	26	14	12	26	1795	5.98

Resultados Finais para o Caso 3D

A Tabela 6.28 resume os resultados obtidos neste caso. A comparação entre as metodologias deve ser feita através da análise dos desempenhos das estratégias E_MADI e E_GOEI, já que esta apresentou o máximo VME entre as estratégias otimizadas pela MADC.

Para este caso, a diferença de desempenho entre as metodologias é grande. O VME da estratégia otimizada pela MADI foi US\$ 70,0 x 10⁶ superior ao máximo VME das estratégias otimizadas pela MADC VPL (que representa o custo de 2 poços).

A Figura 6.22 mostra as curvas de risco para as estratégias otimizadas. Para não carregar demais a figura com informações redundantes são apresentadas apenas quatro curvas de risco para as seguintes estratégias:

- E_MADI – estratégia otimizada pela metodologia da árvore de decisão integrada.
- E_GPEP – estratégia otimizada no modelo pessimista considerando cenário econômico pessimista.
- E_GIEI – estratégia otimizada no modelo intermediário considerando cenário econômico intermediário.
- E_GOEO – estratégia otimizada no modelo otimista considerando cenário econômico otimista.

Mais uma vez a curva de risco para a estratégia otimizada pela MADI apresentou a tendência de se posicionar à direita das demais. O seu desempenho, em termos de VPL, está sempre entre os melhores para cada cenário econômico e modelo geológico considerado.

A otimização pela MADI consumiu 4074 simulações em aproximadamente 13,6 horas enquanto que a soma das simulações feitas pela MADC foi de 12981. Estas simulações foram realizadas em aproximadamente 43,3 horas. Esta diferença foi decorrente do fato que, na otimização pela MADC, ter sido necessário realizar otimizações independentes para cada cenário econômico. No caso da otimização pela MADI estas simulações não são necessárias.

Tabela 6.28 - Resultados Finais - Caso 3D

CASO_03D

ESTRATÉGIA \ RESULTADOS	VME (MM US\$)	VPL (MM US\$) GEO PESS ECO PESS	VPL (MM US\$) GEO PESS ECO INTER	VPL (MM US\$) GEO PESS ECO OTIM	VPL (MM US\$) GEO INTER ECO PESS	VPL (MM US\$) GEO INTER ECO INTER	VPL (MM US\$) GEO INTER ECO OTIM	VPL (MM US\$) GEO OTIM ECO PESS	VPL (MM US\$) GEO OTIM ECO INTER	VPL (MM US\$) GEO OTIM ECO OTIM	Poços	PRODUTORES	INJETORES
E_MADI	850,00	-526,00	35,60	1520	-254,00	550,00	2600,00	-156,00	791,00	3110,00	18	11	7
E_GPEP	705,00	-469,00	12,00	1320	-258,00	416,00	2160,00	-138,00	657,00	2670,00	13	7	6
E_GPEI	777,00	-485,00	56,80	1500	-287,00	484,00	2410,00	-213,00	694,00	2860,00	16	9	7
E_GPEO	756,00	-638,00	-17,40	1600	-450,00	425,00	2530,00	-337,00	673,00	3050,00	24	13	11
E_GIEP	687,00	-541,00	-133,00	989	-187,00	471,00	2240,00	-85,20	706,00	2740,00	12	7	5
E_GIEI	764,00	-633,00	-156,00	1130	-238,00	557,00	2610,00	-173,00	758,00	3040,00	18	11	7
E_GIEO	779,00	-710,00	-95,90	1520	-437,00	489,00	2750,00	-385,00	700,00	3210,00	27	14	13
E_GOEP	666,00	-566,00	-203,00	787	-195,00	413,00	2060,00	32,70	811,00	2880,00	10	6	4
E_GOEI	780,00	-619,00	-175,00	1020,00	-219,00	532,00	2490,00	-29,60	862,00	3170,00	16	10	6
E_GOEO	761,00	-737,00	-172,00	1330,00	-408,00	443,00	2610,00	-266,00	771,00	3300,00	26	14	12

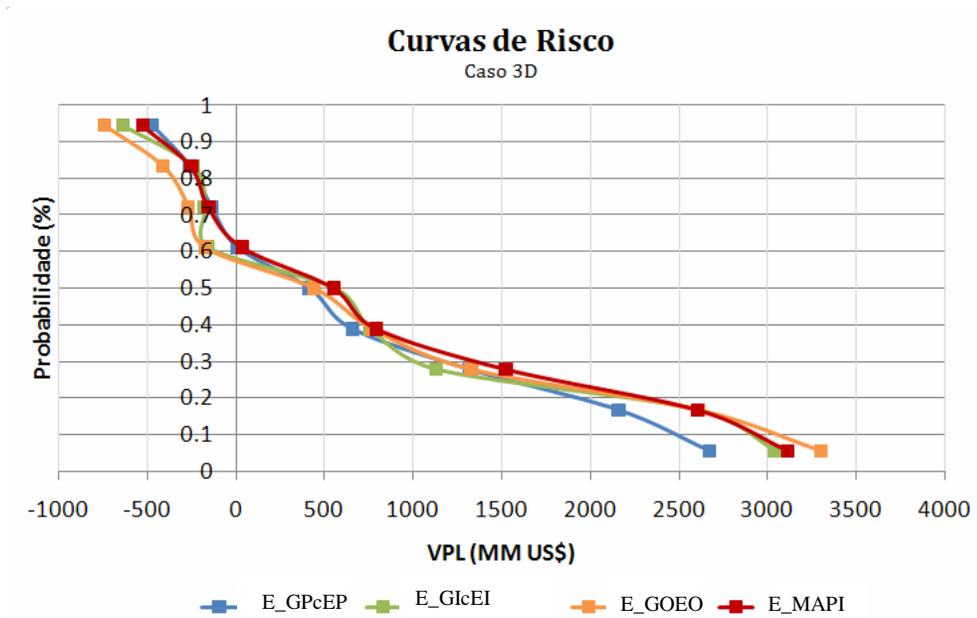


Figura 6.22 – Curvas de Risco Caso 3D

6.4 Etapa 4 – Estudo para Indicação da Seqüência de Perfuração de Poços

Neste item, é apresentado um estudo que visa auxiliar a definição da seqüência de perfuração dos poços de desenvolvimento considerando incertezas geológicas. Este estudo possui como premissa a realização de teste de formação, com a finalidade de obter o índice de produtividade e a permeabilidade horizontal na região do poço, logo após a sua perfuração. O estudo é realizado utilizando a estratégia otimizada para o Caso 3A.

6.4.1 Caso 4

Estratégia Inicial

A Figura 6.23 mostra a estratégia estudada neste caso. Ela é apresentada no mapa de permeabilidade do modelo intermediário do grupo MGR1. Inicialmente somente o poço P-17 está perfurado e testado. A permeabilidade, espessura e índice de produtividade inicial do poço são iguais para os três modelos geológicos (pessimista, intermediário e otimista). Esta estratégia é

composta por 9 poços produtores e 7 injetores totalizando 16 poços. A Tabela 6.29 apresenta o VME da estratégia inicial bem como o seu desempenho nos MGR. A Figura 6.24 mostra a curva de risco inicial para esta estratégia.

Objetivo do Caso em Estudo

O planejamento da seqüência da perfuração dos poços pode ter por finalidade atingir diferentes objetivos. A perfuração dos poços e realização de testes de formação permite que se reduza o nível de incerteza do campo. Como, durante o desenvolvimento do campo, os poços não são perfurados simultaneamente, pode-se estudar uma seqüência de perfuração que permita realizar re-otimizações do posicionamento dos poços.

O caso que será estudado para exemplificar esta etapa da metodologia atua no sentido de acelerar o processo de mitigação da exposição ao risco. Assumindo que a realidade do reservatório possa ser representada por um modelo intermediário entre o modelo otimista e o pessimista, o processo de redução de risco segue a tendência indicada pela seta de cor verde da Figura 6.24.

Tabela 6.29 - Desempenho da estratégia inicial

VME (MM US\$)	567,77
VPL Otimista (MM US\$)	885,28
VPL Intermediário (MM US\$)	636,65
VPL Pessimista (MM US\$)	179,30

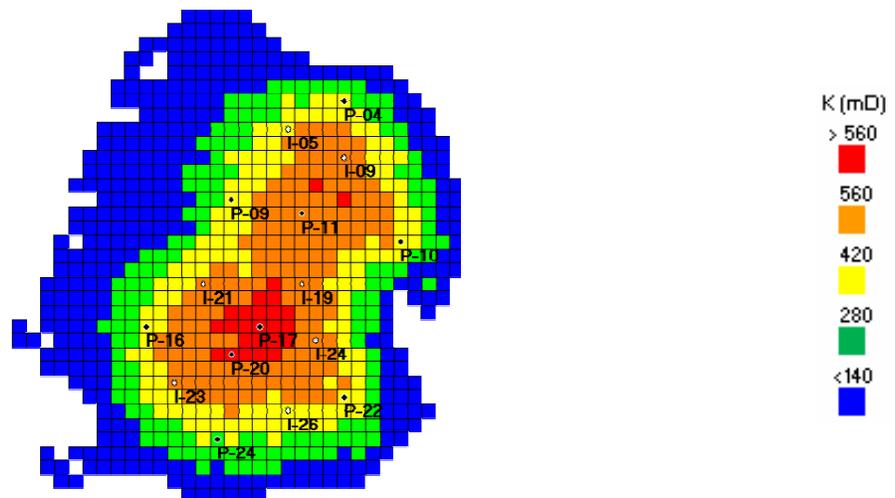


Figura 6.23 – Estratégia otimizada pelo VME no modelo intermediário

O procedimento utilizado a seguir poderia ter outros objetivos dependendo da política de exposição ao risco da empresa, importância do campo em análise, nível de complexidade das incertezas, entre outros. Dependendo dos objetivos de cada estudo, então, a seqüência de perfuração de poços seria diferente. É importante citar, desta forma, que a ferramenta utilizada é flexível para se adaptar a esses objetivos.

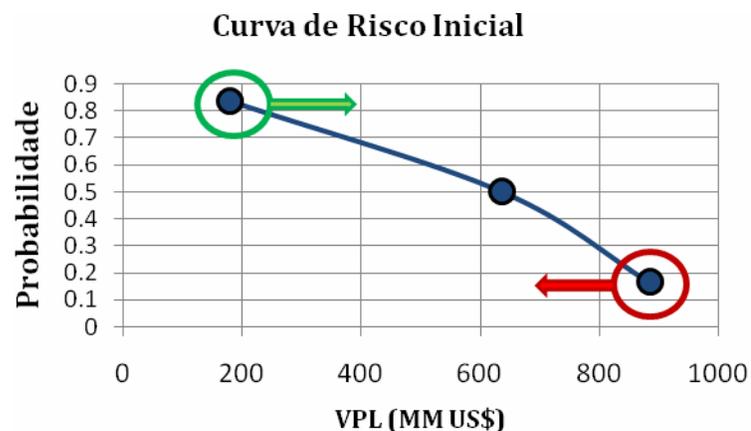


Figura 6.24 – Curva de risco para a estratégia inicial

A Tabela 6.30 apresenta os IDC e os IDC esperados dos poços da estratégia. Na última coluna desta tabela são calculadas as diferenças entre os IDC dos poços nos modelos pessimista e otimista.

Tabela 6.30 – IDC dos poços para a estratégia inicial

POÇO	IDC ESPERADO (US\$)	IDC_INT (US\$)	IDC_PESS (US\$)	IDC_OTIM (US\$)	DIFERENÇA IDC _{OTIM} - IDC _{PESS} (US\$)
P-10	1.07E+08	1.18E+08	7.38E+07	1.30E+08	5.58E+07
P-09	6.27E+07	6.83E+07	3.61E+07	8.36E+07	4.75E+07
P-16	4.84E+07	5.42E+07	2.96E+07	6.12E+07	3.16E+07
P-24	3.62E+07	4.17E+07	1.76E+07	4.91E+07	3.14E+07
P-22	5.95E+07	6.30E+07	4.21E+07	7.35E+07	3.14E+07
P-04	3.09E+07	3.57E+07	1.87E+07	3.82E+07	1.95E+07
I-23	9.83E+07	1.03E+08	9.04E+07	1.01E+08	1.09E+07
I-05	4.32E+07	5.18E+07	3.36E+07	4.40E+07	1.04E+07
I-26	6.08E+07	6.69E+07	5.26E+07	6.26E+07	9.96E+06
I-21	1.07E+08	1.10E+08	1.02E+08	1.08E+08	5.57E+06
P-20	3.32E+07	3.25E+07	3.46E+07	3.25E+07	-2.13E+06
I-09	1.06E+08	1.02E+08	1.10E+08	1.06E+08	-4.24E+06
P-17	1.57E+07	1.36E+07	2.42E+07	9.30E+06	-1.49E+07
P-11	4.31E+07	3.78E+07	5.58E+07	3.60E+07	-1.98E+07
I-24	5.15E+07	5.28E+07	6.26E+07	3.89E+07	-2.37E+07
I-19	6.31E+07	5.75E+07	7.93E+07	5.27E+07	-2.67E+07

Para aplicar a Etapa 4 da metodologia de trabalho, o primeiro passo é construir um mapa com as diferenças de qualidade entre os modelos otimista e pessimista.

Mapa de Diferença de Qualidade

Por se tratar de uma estratégia composta por apenas poços verticais em um reservatório sem presença de aquífero, a adoção de uma formulação simples para a qualidade já é o suficiente. Desta forma, adota-se como qualidade de uma célula o valor de sua transmissibilidade $k \cdot h$. Para considerar os efeitos de borda¹¹, será feita uma média aritmética com a qualidade das células vizinhas¹².

Como diferença de qualidade entre o modelo pessimista e o otimista é adotada a diferença relativa conforme a equação:

$$\Delta Q = \frac{Q_{OTIM} - Q_{PESS}}{Q_{PESS}} \quad \text{Eq. 6.1}$$

¹¹ A qualidade de uma célula deve ser penalizada caso ela esteja próximo à fronteira do reservatório

¹² A média é feita considerando a própria célula e as oito que a cercam.

Desta forma, é construído o mapa indicado na Figura 6.25. A região em vermelho a esquerda do mapa, apesar de apresentar grande diferença relativa de qualidade, não é impactante no desempenho do campo. A grande diferença é decorrente do “*pinch-out*” que ocorre nesta região. O estreitamento do reservatório possui comportamento diferente no modelo pessimista e otimista. No modelo pessimista ele ocorre mais abruptamente que no modelo otimista, mas nos dois modelos a qualidade absoluta é baixa.

Neste mapa, pode-se identificar uma região indicada na cor laranja onde a diferença relativa de qualidade ocorre em uma região de grande diferença absoluta, conforme pode ser observado no mapa de diferença de qualidade absoluta, mostrado na Figura 6.26.

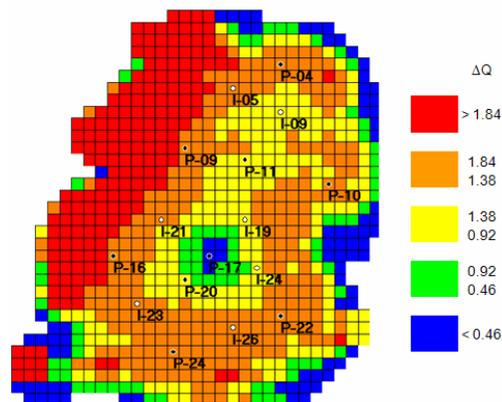


Figura 6.25 – Mapa de diferença relativa de qualidade

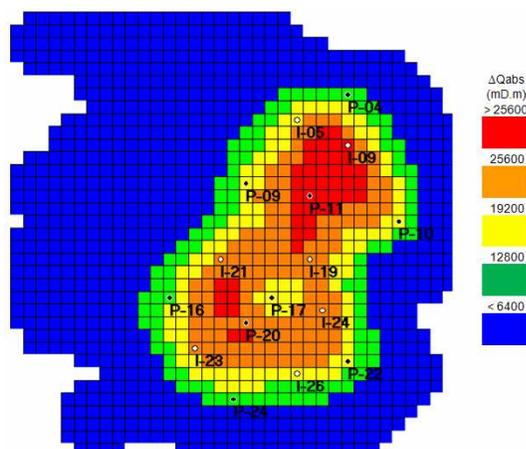


Figura 6.26 – Mapa de diferença absoluta de qualidade

Mapas Relativos aos Desempenhos dos Poços

Conforme descrito anteriormente, o tipo de mapa a ser construído neste estágio da metodologia depende do objetivo que se pretende alcançar. O objetivo que está sendo exemplificado neste trabalho é a aceleração da exposição ao risco para realização de otimizações em modelos cada vez mais realistas. Sendo assim, o segundo passo desta etapa metodologia é a construção de mapas com a diferença de desempenhos dos poços nos modelos pessimista e otimista. A Figura 6.27 mostra o mapa construído com as diferenças calculadas na Tabela 6.30.

Neste mapa, dois aspectos de relevância devem ser observados. O primeiro se refere à região onde estão ocorrendo as maiores diferenças de desempenho dos poços nos modelos em questão. As maiores diferenças de desempenho ocorrem na mesma região onde se situam as maiores diferenças de qualidade relativa, fato que indica uma relação entre estas duas grandezas.

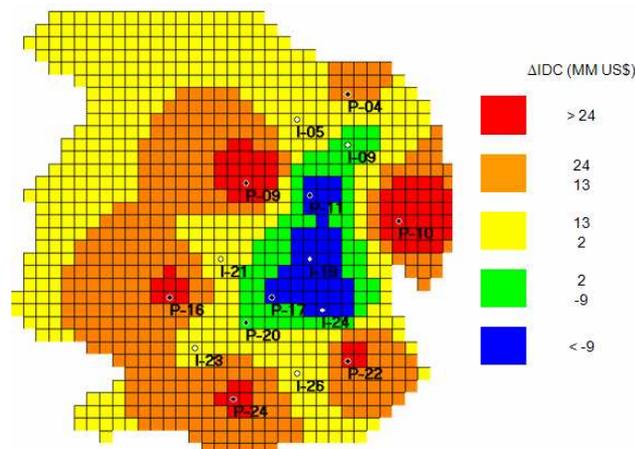


Figura 6.27 – Mapa de diferença de IDC

Outro aspecto de interesse se refere à existência de uma região onde a diferença de IDC é negativa. Isto indica que os poços nesta região possuem uma importância maior no modelo pessimista que no modelo otimista. Como o fundamento desta metodologia é atacar as diferenças entre o modelo pessimista e otimista, torna-se interessante construir um mapa de valor absoluto da diferença de desempenho. Este mapa é mostrado na Figura 6.28.

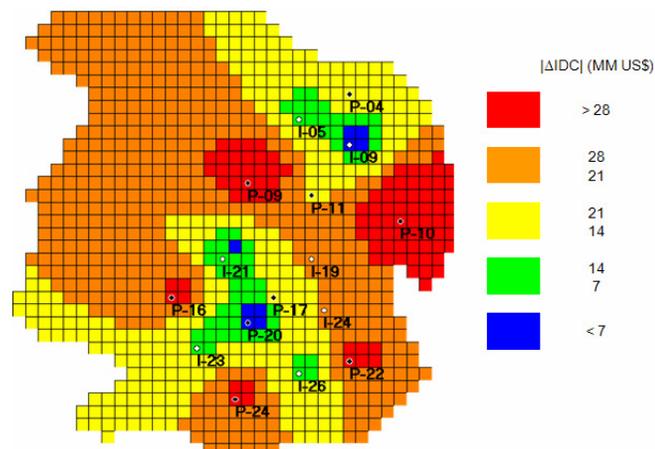


Figura 6.28 – Mapa do valor absoluto da diferença de IDC

O mapa da Figura 6.28 evidencia as regiões dos poços P-10 e P-09 como sendo as regiões onde ocorrem as maiores diferenças de desempenho e as regiões dos poços P-17 e I-09, onde ocorrem as menores diferenças. Para a região do P-17, este comportamento é esperado, já que este é um poço perfurado e, portanto, todos os modelos são iguais nesta região (como pode ser visto no mapa de diferença de qualidade). Já para a região do I-09, este comportamento foge do previsto, já que esta região apresenta diferença relevante de qualidade. Este aspecto revela um fato interessante: os MGR podem possuir regiões onde existem incertezas geológicas que não são impactantes no risco do projeto, pois não afetam significativamente os desempenhos dos poços.

Para completar a série de mapas que irão auxiliar no planejamento da aquisição de informações do reservatório, é construído o mapa de diferença de IDF dos poços, conforme mostrado na Figura 6.29. Apesar de ter sido construído apenas com informações de poços produtores, (injetores não possuem IDF), este mapa traz informações qualitativamente semelhantes aos anteriores.

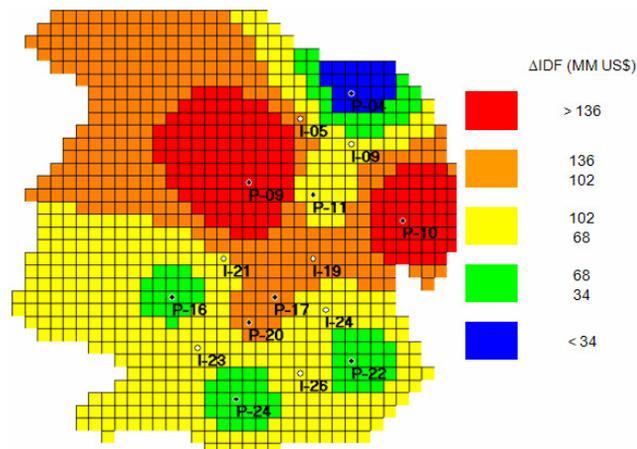


Figura 6.29 – Mapa de diferença de IDF

Análise Cruzada – Diferença de Qualidade X Diferença de Desempenho

O passo seguinte da metodologia é estudar esta série de mapas construídos para auxiliar no planejamento de aquisição de informações do reservatório. Como citado anteriormente, esta etapa é flexível, podendo-se dar ênfase a objetivos definidos pelas diretrizes da empresa.

Um estudo que pode auxiliar no planejamento de aquisição de informações do reservatório é o de realizar uma análise cruzada dos mapas de diferenças de qualidade e desempenho dos poços. Através dele, pode-se evidenciar regiões do reservatório que possuam incertezas geológicas impactantes nos desempenhos dos poços.

A necessidade de se realizar a análise cruzada surge da possibilidade de um poço possuir desempenhos discrepantes nos MGR, sem que haja diferença significativa de qualidade entre eles. Isso pode ocorrer caso este poço esteja fortemente influenciado por poços vizinhos. Portanto, apesar da diferença de desempenhos, a perfuração deste poço não irá contribuir com informações relevantes para diminuir a diferença de seus desempenhos nos diferentes MGR.

Por outro lado, a diferença de qualidade entre determinadas regiões dos MGR pode não causar impacto significativo no risco do projeto. Portanto, uma análise cruzada destas duas informações permite que se possa planejar adequadamente a aquisição de informações do reservatório.

Um exemplo de aplicação que se pode fazer com este tipo de ferramenta é priorizar a aquisição de informação em regiões do reservatório onde há incertezas geológicas associadas a diferenças de desempenho dos poços nos MGR. Com esta abordagem existe a tendência de aceleração da redução do risco, ou seja, é priorizada a perfuração do poço que maior contribuição tem na redução do risco. Com o risco minimizado, as re-otimizações dos posicionamentos dos poços ainda não perfurados são feitas em cenários cada vez mais reais (menos incertos), favorecendo uma previsão de desempenho mais próxima da realidade. É importante observar que o procedimento visa melhorar o processo decisório, induzindo a um aumento do desempenho do campo. Entretanto, se o caso real estiver no lado pessimista da curva, as informações coletadas ao longo do processo levarão a menores VME a cada passo. O importante é a constatação que o desempenho final do campo será melhor com a aquisição das informações e tomada de decisões mais consistentes.

O primeiro mapa da análise cruzada é construído multiplicando os valores da diferença relativa de qualidade e a diferença de IDC. A Figura 6.30 mostra o mapa construído, onde é possível observar as regiões dos poços P-10 e P-09 como sendo as regiões do reservatório onde há incertezas geológicas associadas a diferenças de desempenho dos poços. A Figura 6.31 mostra o gráfico que cruza as informações de diferença de qualidade com diferença de desempenho dos poços. É possível observar os poços P-09 e P-10 se destacando dos demais. O P-10 possui maior variação de desempenho enquanto a região do P-09 possui a maior variação de qualidade. Em uma análise quantitativa deste cruzamento (Figura 6.32) de informações, observa-se novamente os poços P-10 e P-09 se destacando dos demais.

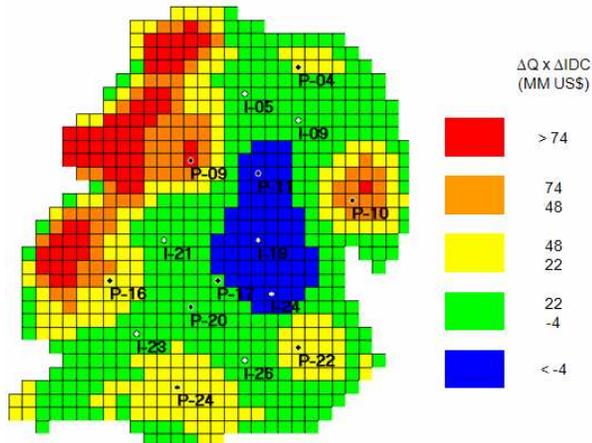


Figura 6.30 – Mapa $\Delta Q \times \Delta IDC$

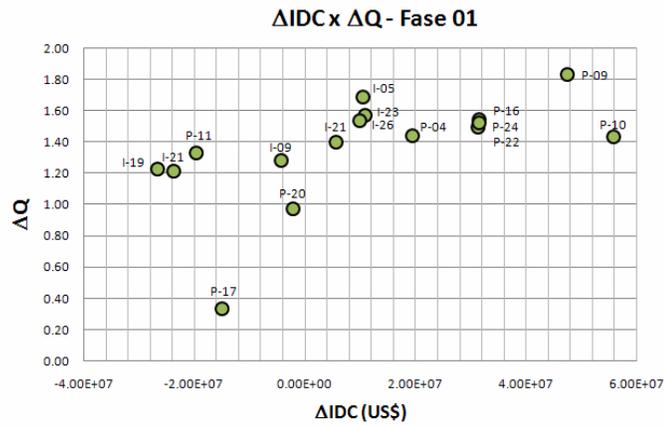


Figura 6.31 – Gráfico $\Delta Q \times \Delta IDC$

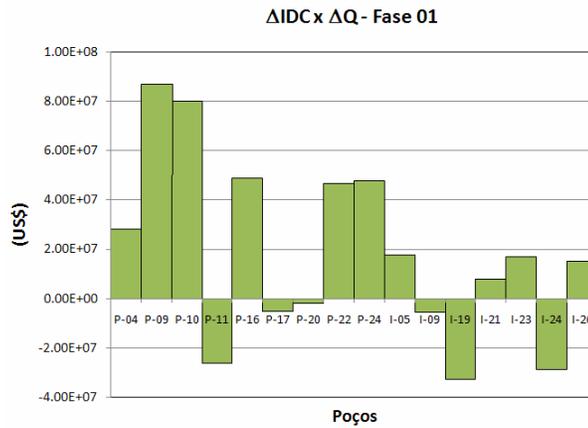


Figura 6.32 – Valores de $\Delta Q \times \Delta IDC$

A existência de poços com variação negativa de IDC motiva a construção de um mapa que multiplica a variação de qualidade pelo valor absoluto da variação de desempenho, conforme feito e apresentado na Figura 6.33. Com a análise das Figuras 6.34 e 6.35, é possível chegar à mesma conclusão anterior. Os poços P-09 e P-10 possuem as maiores diferenças de desempenho associadas a significantes diferenças de qualidade dos modelos MGR.

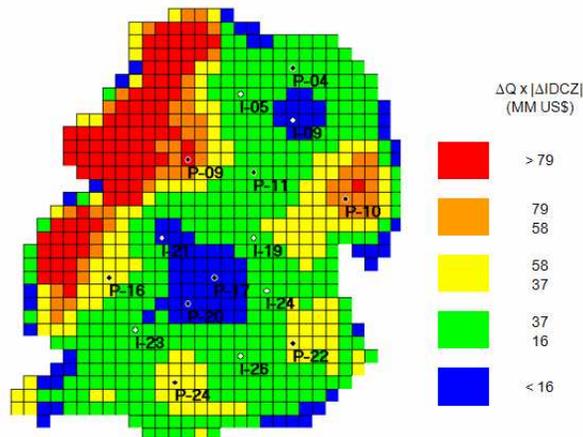


Figura 6.33 – Mapa $\Delta Q \times |\Delta IDC|$

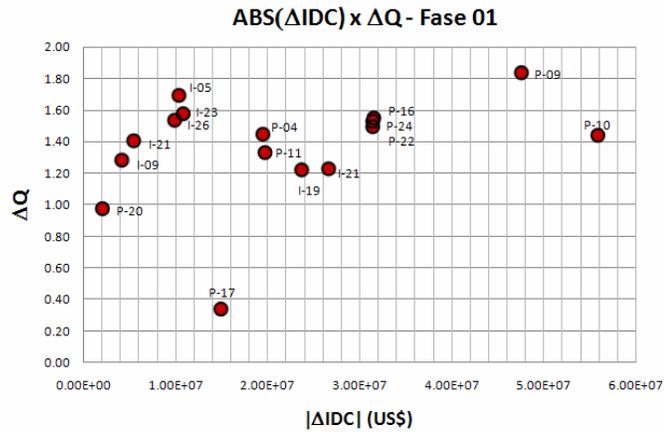


Figura 6.34 – Gráfico $\Delta Q \times |\Delta IDC|$

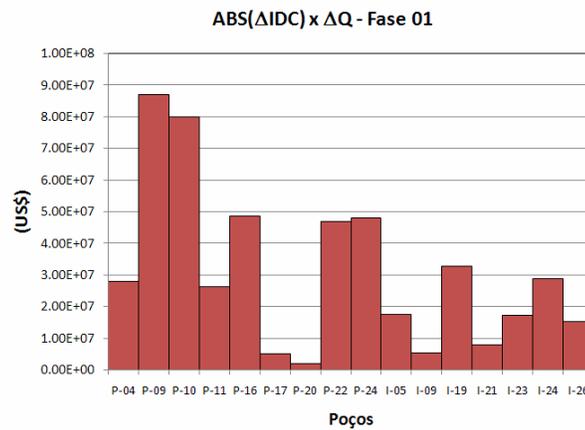


Figura 6.35 – Valores de Δ Q x $|\Delta$ IDC|

Um novo conjunto de dados é construído com a utilização do IDF dos poços produtores. Estes dados são apresentados nas Figuras 6.36, 6.37 e 6.38. As mesmas conclusões obtidas com os dados anteriores podem ser tiradas deste grupo de dados. A análise dos dados indica a perfuração dos poços P-10 e P-09.

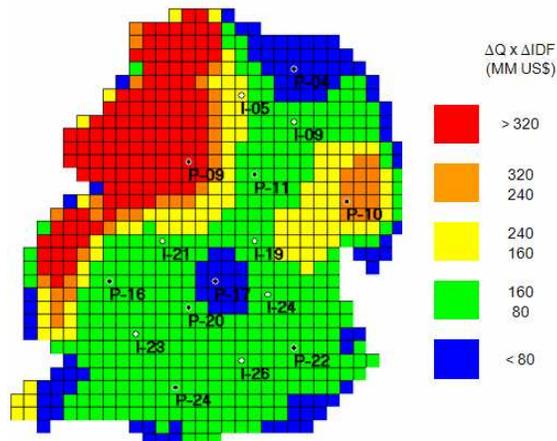


Figura 6.36 – Mapa Δ Q x Δ IDF

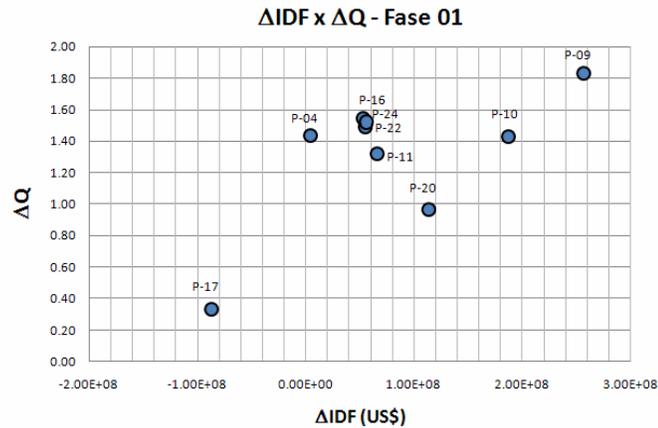


Figura 6.37 – Gráfico ΔQ x ΔIDF

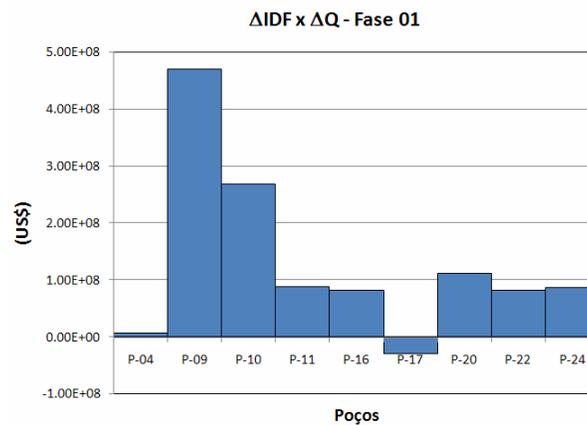


Figura 6.38 – Valores de ΔQ x ΔIDF

Perfuração dos Poços

Para exemplificar o emprego da Etapa 4 da metodologia de trabalho na fase de desenvolvimento de um campo, é desenvolvido o procedimento proposto pela Figura 4.8 para a perfuração de dois poços.

Após a realização da primeira fase da análise cruzada, optou-se por perfurar o poço P-10. Com a perfuração deste poço os MGR são alterados para que todos fiquem iguais na região deste poço. A alteração dos MGR faz com que o nível de incerteza do campo diminua, justificando a realização de uma re-otimização dos poços ainda não perfurados. Após a realização da re-otimização é possível fazer uma nova análise cruzada (segunda fase) das diferenças de qualidade

e de desempenho dos poços, para que se possa indicar o próximo poço a ser perfurado. A análise cruzada nesta fase indicou a perfuração do P-16.

O processo foi interrompido neste ponto. O campo, neste momento, possui três poços perfurados P-17, P-10 e P-16. Os dois últimos tiveram a perfuração indicada pela metodologia proposta. A cada poço perfurado, os modelos geológicos representativos são atualizados incorporando as informações obtidas na perfuração e teste de formação deste poço. Os MGR vão se igualando a cada poço perfurado, se aproximando cada vez mais do modelo hipotético (caso “real”). Portanto, a cada poço perfurado uma nova curva de risco pode ser construída. Nos parágrafos seguintes, é realizada uma análise da evolução do desempenho das estratégias otimizadas e do risco do projeto.

A Figura 6.39 mostra a evolução da curva de risco do projeto antes (curva de risco inicial¹³) e após a perfuração de cada um destes dois poços, P-10 e P-16.

Usando como métrica de risco a diferença entre os VPL otimista e pessimista, pode-se mostrar, através da Figura 6.40, que a evolução do risco ao longo do desenvolvimento do campo, atinge o objetivo previamente definido. Nesta figura, são indicados os riscos iniciais, após a perfuração do P-10 e após a perfuração do P-16.

O processo de re-otimização tem por objetivo otimizar o VME do projeto para cada nível de incerteza. O nível de incerteza é alterado continuamente durante o desenvolvimento do campo revelando uma realidade que pode ser otimista ou pessimista. Sendo a realidade otimista ou pessimista, o procedimento proposto deve otimizar o VME para aquele nível de incerteza. A tendência da variação do VME ao longo do processo depende exclusivamente da Natureza. Como consequência disso, caso a realidade do campo venha se revelar mais próxima do modelo pessimista a tendência de redução do VME ao longo do desenvolvimento do campo é inevitável. Apesar do impacto negativo desta constatação, a antecipação desta informação permite que providências com relação aos poços não perfurados sejam tomadas. Mesmo com a diminuição do VME do projeto, como mostra a Figura 6.41, este procedimento é extremamente importante e benéfico para o desempenho do campo, como pode ser observado na Figura 6.42. Esta figura mostra a evolução do VPL da estratégia no modelo hipotético. Observa-se que apesar da

¹³A curva de risco inicial é construída com os VPL da estratégia otimizada no caso 3A nos modelos pessimista, intermediário e otimista. Neste estágio do desenvolvimento do campo somente o poço P-17 encontra-se perfurado.

diminuição do VME (a variação do VME vai ser influenciada por quanto o modelo é pessimista ou otimista), o VPL no modelo hipotético (que representa a “realidade” da geologia) vem aumentando. Ao acelerar a revelação da realidade do reservatório, o processo atua no sentido de maximizar o VPL “real” do campo.

Como conclusão desta etapa da metodologia, pode-se afirmar que a análise cruzada pode ser realizada com o propósito de se atingir um determinado objetivo durante o desenvolvimento do campo.

A aplicação da análise cruzada nesta aplicação da metodologia permitiu indicar a perfuração dos poços que evidenciassem mais rapidamente a realidade do reservatório com o propósito de maximizar o desempenho do campo ao final da sua fase de desenvolvimento. Como citado anteriormente, poder-se-ia construir outros mapas com o intuito de guiar o desenvolvimento do campo no sentido de se atingir outro objetivo, por exemplo, a redução do risco de haver VPL negativo (quando o modelo pessimista possuir VPL inicial negativo).

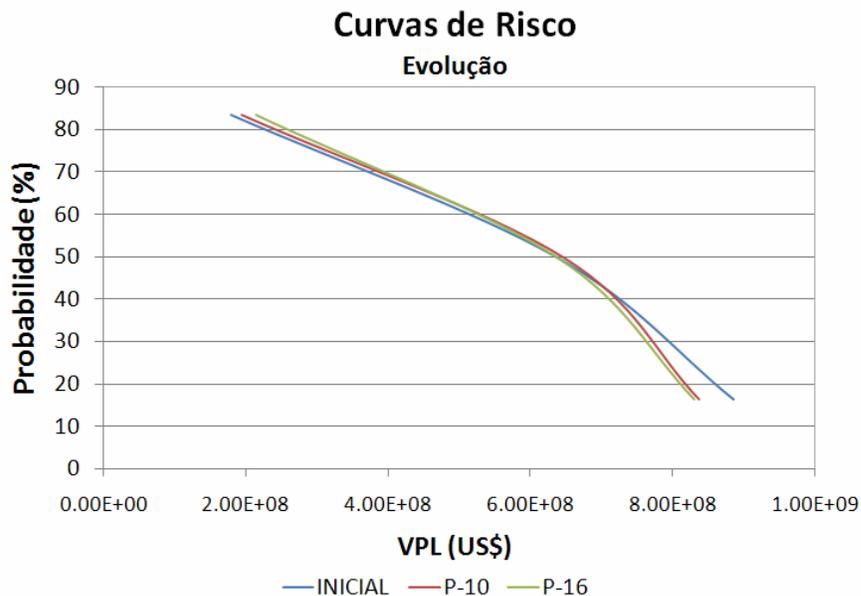


Figura 6.39 – Evolução das curvas de risco com o desenvolvimento do campo

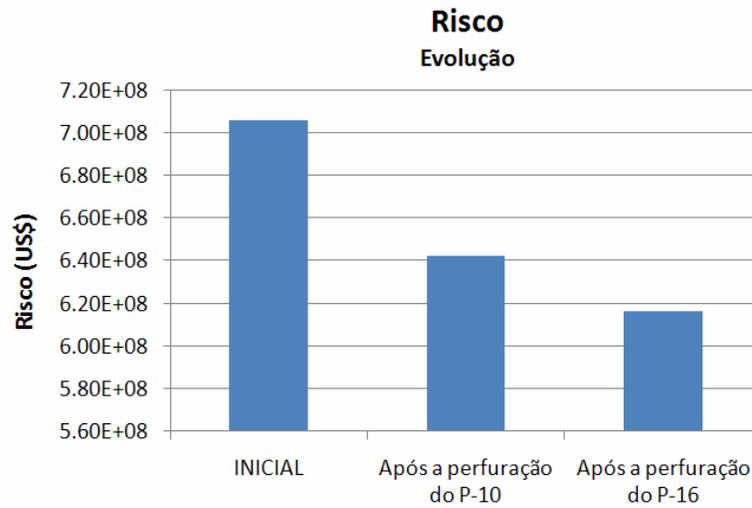


Figura 6.40 – Evolução do risco com o desenvolvimento do campo

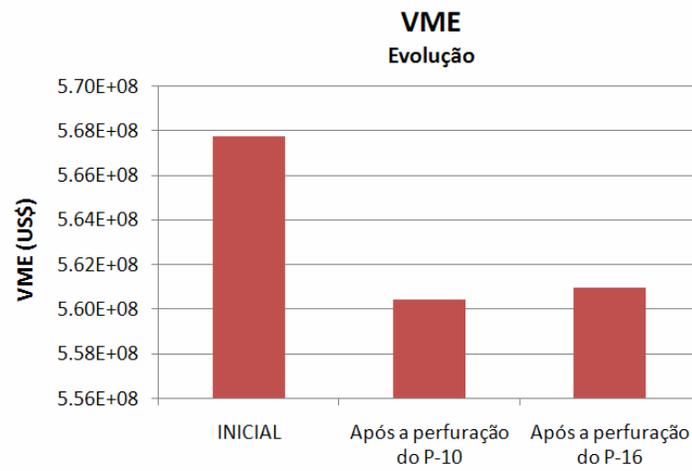


Figura 6.41 – Evolução do VME com o desenvolvimento do campo

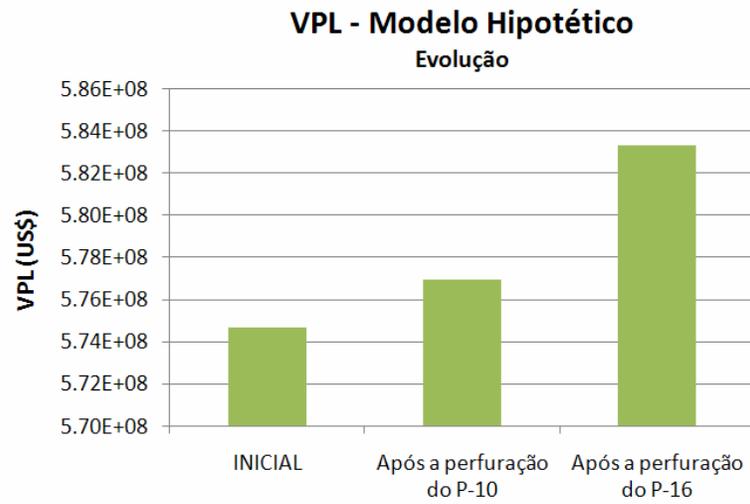


Figura 6.42 – Evolução do VPL da estratégia otimizada no modelo hipotético com o desenvolvimento do campo

Capítulo 7 - Conclusões

Neste trabalho, foram desenvolvidas metodologias e ferramentas para otimização de exploração de campos de petróleo. A otimização, com a utilização de algoritmos genéticos, é realizada através de uma abordagem rigorosa para a consideração das incertezas. Ao final utilizaram-se as ferramentas criadas para o desenvolvimento da metodologia, com a finalidade de otimizar o desempenho do campo durante a sua fase de desenvolvimento. Após as aplicações da metodologia proposta, pode-se chegar as seguintes conclusões:

- A existência de regiões de máximos locais na superfície de resposta de do problema de otimização da estratégia de produção para o Caso 1A contra-indica a aplicação de métodos de otimização baseados no cálculo dos gradientes da função-objetivo. Como o número de máximos locais tende a aumentar devido ao aumento da complexidade do problema e do número de variáveis do problema, a utilização de métodos de busca dispersa na sua resolução deste tipo de problema, pode se tornar interessante.
- Os algoritmos genéticos, apesar de possuírem um custo computacional elevado, são adequados para otimização de problemas com estas características, conferindo maior confiabilidade na resposta.
- A concepção adequada de uma estrutura cromossômica para o problema de otimização do posicionamento dos poços confere maior eficiência ao processo de otimização por algoritmos genéticos.
- A aplicação da metodologia assistida de otimização de estratégia de produção usando métodos que buscam a diversificação tem maior probabilidade de encontrar soluções mais adequadas ao problema devido à busca de estratégias não investigadas por processos manuais. A tendência é que a diferença de desempenho entre o processo assistido e o manual aumente com o aumento da complexidade do problema.
- Um problema associado aos métodos que buscam a diversificação, como os algoritmos genéticos, é o elevado custo computacional. Mostrou-se neste trabalho que a utilização de conceitos da engenharia do problema de otimização de estratégias de produção, como por

exemplo, o desempenho dos poços, é possível acelerar a evolução da otimização por algoritmos genéticos.

- A aplicação da metodologia proposta para otimização de estratégia de produção usando algoritmo genético pode indicar o esquema de injeção mais adequado a ser adotados na produção de um campo.
- Ferramentas de otimização assistida são úteis não apenas no refinamento de uma estratégia de produção, como também no processo de seleção de estratégias.
- A metodologia proposta para a abordagem de incertezas geológicas e econômicas tende a produzir estratégias mais adaptáveis aos diversos cenários econômicos e modelos geológicos possíveis.
- As MADI e MADC para abordagem de incertezas tenderam a ter desempenhos semelhantes no Caso 2A onde foram consideradas apenas incertezas geológicas de baixa complexidade. Nestes casos, a MADI teve um desempenho ligeiramente superior. No Caso 2B onde havia incertezas geológicas de maior complexidade (como é o caso da dúvida da existência de compartimentação do reservatório), a diferença de desempenho entre as metodologias foi maior.
- As MADI e MADC para abordagem de incertezas tenderam a ter desempenhos semelhantes quando são consideradas apenas incertezas econômicas (Caso 2B). Nestes casos, também, a MADI teve um desempenho ligeiramente superior.
- As MADI e MADC para abordagem de incertezas tenderam a ter desempenhos discrepantes quando foram consideradas incertezas econômicas juntamente com incertezas geológicas de maior complexidade. Nestes casos, MADI teve um desempenho consideravelmente superior.
- A MADI pode ser utilizada, com ganhos em relação à MADC, em qualquer caso que envolva incertezas, se estabelecendo como uma abordagem mais rigorosa.
- O custo computacional associado à execução da MADI nos casos estudados tendeu a ser inferior ao custo computacional associado à execução da MADC de abordagem de incertezas.
- A análise cruzada de informações geológicas e referentes aos desempenhos dos poços pode guiar o desenvolvimento do campo no sentido de se atingir um determinado objetivo.

- A análise cruzada das diferenças de qualidade e de diferenças desempenho dos poços nos MGR pessimista e otimista pode ser utilizada para a maximização do VPL do campo ao final do seu desenvolvimento.
- Pode-se montar o cruzamento de outras informações visando atingir objetivos, durante o desenvolvimento do campo, distintos do exemplificado neste trabalho.

Referências

ALMEIDA, L. F., Sistema Híbrido de otimização de Estratégia de Controle de Válvulas de Poços Inteligentes sob Incertezas, Tese de Doutorado, Pontifícia Universidade Católica do Rio de Janeiro, 2007

ARPS, J. J. *et al.*, A Statistical Study of Recovery Efficiency, American Petroleum Institute – API, Outubro, 1967, 1º Edição.

BECKNER, B. L. and SONG X., Field Development Using Simulated Annealing – Optimal - Economical Well Scheduling and Placement, SPE 38895, 1997 SPE Annual Technical - Conference and Exhibition, San Antonio, TX, Outubro, 1997.

BITTENCOURT, A. C., Optimizing Hydrocarbon Field Development Using a Genetic Algorithm Based Approach, Petroleum Engineering Department, Stanford University, 1997, 154 P., PhD Thesis.

CLARK, S.K., TOMLISON, C.W. e ROYDS, J.S., Well Spacing – Its Effects on Recoveries and Profits, AAPG. Fevereiro, 1944.

DAMSLETH, E., HAGE, A., VOLDEN, R., Maximum Information at Minimum Cost: A North Sea Field Development Study Using Experimental Design. SPE 23139, 1991 Offshore Europe Conference, Aberdeen, Setembro, 1991.

FUTUYMA, D. J. - Evolutionary Biology, Second Edition, Sinauer Associates, Inc. 1986

GOLDBERG, D.E. – Genetic Algorithms in Search, Optimization, and Machine Learning Addison-Wesley Publishing Company, Inc – First Edition, Reprinted with corrections- 1989.

GÜYAGÜLER, B., HORNE R. N., ROGERS, L. and ROSENZWEIG, J. J., Optimization of Well Placement in a Gulf of Mexico Waterflooding Project, SPE 63221, 2000 Annual Technical Conference and Exhibition, Dallas, TX, Outubro, 2000.

HAYASHI, S. H. D., Valor da Flexibilização e Informação em Desenvolvimento de Campo por Módulos, Dissertação de Mestrado, UNICAMP, 2006.

MEZZOMO, C. C. - Seleção de Projetos de Desenvolvimento Integrada à Análise de Risco – Tese de Doutorado – UNICAMP 2005

MICHALEWICZ, Z. – Genetic Algorithms + Data Structures = Evolution Programs. 3rd edition. Spring-Verlag, 1996.

MITCHELL, M. – An Introduction to Genetic Algorithms, – A Bradford Book – Massachusetts Institute of Technology Press - 1996

NAKAJIMA, Lincoln – Otimização de Desempenho de poços Horizontais no Desenvolvimento de Campos de Petróleo – Tese de Mestrado – UNICAMP 2005

NEMHAUSER, G. L.; WOLSEY, L. A. – Integer and Combinatorial Optimization – Wiley – Interscience Series in Discrete Mathematics and Optimization – Second Edition – 1999.

NEWENDORP, P. D., Decision Analysis for Petroleum Exploration. Penn Well Publishing Co., Tulsa, Oklahoma, 1975.

NYSTAD, A. N., Reservoir Economic Optimization. SPE 13775. Fevereiro, 1985.

PEDROSO JR., C. and SCHIOZER, D. J., Optimizing Location of Wells in Field Development Using Reservoir Simulation and Parallel Computing (PVM), Rio Oil and Gas, 2000, Rio de Janeiro.

PEDROSO JR., C – Otimização de Locações de Poços Usando Simulação Numérica de Reservatórios, UNICAMP - Tese de Mestrado, 1999.

SCHIOZER, D. J., LIGERO, E. L., SUSLICK, S. B., COSTA, A. P. A. e SANTOS, J. A. M.: "Use of Representative Models in the Integration of Risk Analysis and Production Strategy

Definition", Journal of Petroleum Science and Engineering, pág. 131-141, nros. 1-2, vol. 44, Outubro, 2004.

SCHIOZER, D. J. *et al.* – Otimização de Estratégias de Produção Através de Simulação Numérica de Reservatórios, Campinas, Departamento de Engenharia de Petróleo, UNICAMP, relatórios internos, 2002.

STEAGALL D. E., Análise de Risco nas Previsões de Produção com Simulação Numérica de Fluxo – Exemplo de um Campo na Fase de Delimitação, Dissertação de Mestrado, UNICAMP, 2001.

TÚPAC, ALMEIDA, L. F., VELLASCO, M. - Pontifícia Universidade Católica do Rio de Janeiro - Evolutionary Optimization of Oilfield Development, SPE 107552.

XAVIER, A. M., Análise do Valor da Informação na Avaliação e Desenvolvimento de Campos de Petróleo, Dissertação de Mestrado, UNICAMP, 2004.