



Guilherme Cesário Strachan

**Aproximadores de Simuladores de Reservatório de Petróleo
por Programação Genética e Aplicação na Otimização de
Alternativas de Produção**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para
obtenção do título de Mestre pelo Programa de Pós-
Graduação em Engenharia Elétrica da PUC-Rio.

Orientador: Prof. Marco Aurelio Cavalcanti Pacheco
Co-orientador: Dr. Douglas Mota Dias

Rio de Janeiro
Setembro de 2014



Guilherme Cesário Strachan

Aproximadores de Simuladores de Reservatório de Petróleo por Programação Genética e Aplicação na Otimização de Alternativas de Produção

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Marco Aurélio Cavalcanti Pacheco

Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Dr. Douglas Mota Dias

Co-Orientador

Departamento de Engenharia Elétrica – PUC-Rio

Prof. Amit Bhaya

UFRJ

Dr. Alexandre Anozé Emerick

Petróleo Brasileiro

Dr. Regis Kruel Romeu

Centro de Pesquisa e Desenvolvimento Leopoldo Américo Miguêz de Mello

Prof. José Eugenio Leal

Coordenador Setorial do Centro

Técnico Científico

Rio de Janeiro, 08 de setembro de 2014

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Guilherme Cesário Strachan

Graduou-se em Engenharia de Controle e Automação pela Universidade Federal do Rio de Janeiro (UFRJ) em 2012.

Ficha Catalográfica

Strachan, Guilherme Cesário

Aproximadores de simuladores de reservatório de petróleo por programação genética e aplicação na otimização de alternativa de produção / Guilherme Cesário Strachan ; orientador: Marco Aurélio C. Pacheco – 2014.

118 f. : il. (color.) ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2014.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Aproximador. 3. Simulador de reservatório. 4. Programação genética. 5. Inspiração quântica. 6. Hipercubo latino. 7. Otimização de poços. 8. Incerteza geológica. I. Pacheco, Marco Aurélio C. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. III. Título.

CDD: 621.3

Agradecimentos

À meu orientador Professor Marco Aurélio C. Pacheco, pela parceria e apoio na elaboração deste trabalho.

Ao meu co-orientador Douglas, pelo estímulo e pela inestimável contribuição.

Aos meus pais, Fabia e Michael, pela educação, paciência, carinho e compreensão.

Aos meus irmãos e amigos Anna, Yuri, Yves, Alexandre, Michelle e Yasmim por todo apoio, carinho e motivação.

À todos os familiares e amigos que de alguma forma me ajudaram ou estimularam.

À todos os meu colegas do ICA pelo conhecimento compartilhado, em especial a Manoela, pela imensa ajuda.

Aos colegas da Petrobras pela disponibilidade e contribuições.

Aos participantes da Comissão examinadora.

Ao CNPq, à PUC-Rio e à Petrobras, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

Resumo

Strachan, Guilherme Cesário; Pacheco, Marco Aurélio Cavalcanti; Dias, Douglas Mota. **Aproximadores de Simuladores de Reservatório de Petróleo por Programação Genética e Aplicação na Otimização de Alternativas de Produção**. Rio de Janeiro, 2014. 118p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

A definição da estratégia de produção de petróleo é uma tarefa muito importante que consiste em um processo bastante complexo devido à grande quantidade de variáveis envolvidas. Estas variáveis estão relacionadas com características geológicas, fatores econômicos e decisões como alocação de poços, número de poços produtores e injetores, condições operacionais e cronograma de abertura de poços. No contexto da otimização da produção de petróleo, o objetivo é encontrar a melhor configuração de poços que contribua para maximizar, na maioria dos casos, o valor presente líquido (VPL). Esse valor é calculado, principalmente, a partir do óleo, gás e água produzidos do campo, que são encontrados através do uso do simulador de reservatórios. Porém, vários parâmetros e variáveis devem ser prefixados e inseridos no sistema de simulação para que esses valores de produção sejam previstos. Esse processo geralmente exige um alto custo computacional para modelar as transferências de fluidos dentro do reservatório simulado. Assim, o uso de simuladores pode ser substituído por aproximadores. Neste estudo, eles são desenvolvidos através da Programação Genética Linear com Inspiração Quântica, uma técnica da Computação Evolucionária. Esses aproximadores serão utilizados para substituir a simulação do reservatório no processo de otimização da localização e tipo de poços a serem perfurados em um campo petrolífero. Para a construção dos *proxies* de reservatório, as amostras, originadas utilizando a técnica do Hipercubo Latino, foram simuladas para a criação da base de dados. O modelo para criação de aproximadores foi testado em um reservatório sintético. Dois tipos de otimização foram realizados para a validação do modelo. A primeira foi a otimização determinística e a segunda uma otimização sob incerteza considerando três diferentes cenários geológicos, um caso onde o número de simulações é

extremamente alto. Os resultados encontrados apontam que o modelo para a criação de proxies consegue bom desempenho na substituição dos simuladores devido aos baixos erros encontrados e na considerável redução do custo computacional.

Palavras-chave

Aproximador; Simulador de Reservatório; Programação Genética; Inspiração Quântica; Hipercubo Latino; Otimização de Poços; Incerteza Geológica

Abstract

Strachan, Guilherme Cesário; Pacheco, Marco Aurélio Cavalcanti (Advisor); Dias, Douglas Mota. **Approximators of Oil Reservoir Simulators by Genetic Programming and Application in Production Optimization Alternatives**. Rio de Janeiro, 2014. 118p. MSc. Dissertation – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

The purpose of oil production strategy in the context of production optimization is to find the best configuration of wells that contributes to maximizing the Net Present Value. This value is calculated mainly from the amount of oil, gas, and water recovered from the field, which can be obtained by running the reservoir simulator. However, many parameters and variables must be prefixed and inserted into the simulation system in order to generate these production values. This process involves a high computational cost for modeling the transfer of fluids within the simulated reservoir. Thus, the use of simulators may be substituted by approximators. In this thesis, we aim to develop these approximators using Quantum-Inspired Linear Genetic Programming, a technique of Evolutionary Computation. These approximators were used to replace the reservoir simulation in the process of optimizing the location and type of wells to be drilled in a field. For the reservoir proxies' construction, samples obtained from the technique of Latin Hypercube were simulated to create the database. The model for creating approximators was tested on a synthetic reservoir. Two types of optimization were performed to validate the model. The first was a deterministic optimization and the second an optimization under uncertainty considering three different geological settings, a situation in which the number of simulations becomes extremely high. Our results indicated that the model for the creation of proxies achieves a satisfactory performance in the replacement of simulators due to low levels of errors and a considerable reduction of the computational cost.

Keywords

Approximator; Reservoir Simulation; Genetic Programming; Quantum Inspiration; Latin Hypercube; Well Optimization; Geological Uncertainty

Sumário

1 . Introdução	16
1.1. Motivações	16
1.2. Objetivos	17
1.3. Descrição do Trabalho	17
1.4. Organização do Trabalho	18
2 . Sistema de Produção de Petróleo	20
2.1. Geologia e Origem do Petróleo	20
2.1.1. Rochas geradoras	20
2.1.2. Rochas Reservatórios	21
2.1.3. Rochas Selantes	22
2.2. Produção de Petróleo	22
2.2.1. Mecanismo de gás em solução	23
2.2.2. Mecanismo de Capa de Gás	24
2.2.3. Mecanismo de Influxo de Água	26
2.2.4. Métodos de Recuperação Avançados	29
2.3. Desenvolvimento de Campos de Petróleo	29
2.3.1. Caracterização do Reservatório	30
2.3.2. Poços de Petróleo	31
2.3.3. Otimização do Plano de Desenvolvimento	32
2.3.4. Alternativas Econômicas	32
2.4. Simuladores de Reservatório	33
2.5. Revisão Bibliográfica	34
3 . Programação Genética	40
3.1. Introdução	40
3.2. Conceitos	41
3.2.1. Algoritmo Básico	41
3.2.2. Funções e Terminais	42
3.2.3. Avaliação e Seleção	43
3.2.4. Operadores Genéticos	44
3.2.5. População	44

3.3. Estruturas de Representação	45
3.3.1. Programação Genética em Árvore	45
3.3.2. Programação Genética Linear	46
3.4. Programação Genética Linear com Inspiração Quântica	47
3.4.1. Computação Quântica	47
3.4.2. Plataforma	48
3.4.3. Representação	48
3.4.4. Programas Evoluídos	51
3.4.5. Avaliação	51
3.4.6. Operador Quântico	52
3.4.7. Estrutura e Funcionamento do Modelo	52
4 . Modelagem do Aproximador	54
4.1. Introdução	54
4.2. Aproximador de Reservatório	55
4.2.1. Seleção de Variáveis do Aproximador	55
4.2.2. Cenários de Poços	56
4.2.3. Simulação dos Cenários de Poços	58
4.2.4. Criação das Bases	61
4.2.5. Pós-Processamento da Base	63
4.2.6. Geração do Aproximador	65
4.2.7. Função de Avaliação	67
4.2.8. Alterações na Evolução do Aproximador	69
5 . Estudo de Casos	72
5.1. Descrição do reservatório	72
5.2. Métricas de avaliação	73
5.3. Parâmetros da PGLIQ e Especificações das Máquinas	74
5.4. Teste de Conceito	75
5.5. Teste de Sensibilidade	76
5.6. Aproximadores	81
5.6.1. Cenário Geológico 1	81
5.6.2. Cenário Geológico 2	87
5.6.3. Cenário Geológico 3	92

5.7. Otimização de Localização de Poços com Aproximadores	95
5.7.1. Parâmetros	96
5.7.2. Comparação entre o Uso do Simulador e dos Aproximadores para a Otimização Determinística	97
5.7.3. Comparação entre o Uso do Simulador e dos Aproximadores para a Otimização Sob Incerteza	100
6 . Conclusões e Trabalhos Futuros	104
6.1. Conclusões	104
6.2. Trabalhos Futuros	105
Referências Bibliográficas	107
Apêndice A	112
A.1. Modelo de reservatório	112
A.2. Resultados do Aproximador	113
Apêndice B	115

Lista de Figuras

Figura 1 – Tipos de rochas geológicas [9].....	20
Figura 2 – Visão microscópica da rocha reservatório [11].....	21
Figura 3 – Reservatório com mecanismo de gás em solução	23
Figura 4 – Características do mecanismo do gás em solução.....	24
Figura 5 – Reservatório com mecanismo de capa de gás	25
Figura 6 – Características do mecanismo de capa de gás.....	26
Figura 7 – Reservatório com mecanismo de influxo de água.....	27
Figura 8 – Características do mecanismo de influxo de água	27
Figura 9 – Cenários com porosidade e permeabilidade diferentes [21].	31
Figura 10 – Discretização de um reservatório.	34
Figura 11 – Fluxograma do algoritmo básico da PG.....	42
Figura 12 – Representação de um programa na estrutura de árvore [48].....	45
Figura 13 – Estrutura de cromossomos da PG Linear	46
Figura 14 – Exemplo de implementação de um <i>qudit</i> [6]	49
Figura 15 - Qudit representado como roleta.....	50
Figura 16 – Observação de um IQ gerando um IC [6]	51
Figura 17 – Diagrama básico do modelo PGLIQ [6]	53
Figura 18 – Etapas do processo de construção de aproximadores	55
Figura 19 – Entradas externas do aproximador	56
Figura 20 – Configuração de poços de uma otimização livre da quantidade	59
Figura 21 - Curva de óleo, gás e água acumulados da otimização	60
Figura 22 – Seleção do programa de acordo com a alternativa (programas meramente ilustrativos)	60
Figura 23 – Ideia do entrelaçamento para uma variável.....	61
Figura 24 – Janela Deslizante para Previsão de Produção por 6 Anos.....	62
Figura 25 – Previsão da produção de uma alternativa.....	63
Figura 26 – Retirada dos primeiros anos	64
Figura 27 – Exemplo de ordenação para dois poços produtores e um injetor.....	64
Figura 28 – Esquema de geração dos aproximadores.....	65
Figura 29 – Previsão Multi-Step.....	68

Figura 30 – Reservatório Sintético com profundidade em metros.	72
Figura 31 - Porosidade da primeira camada dos três cenários geológicos escolhidos	73
Figura 32 - Permeabilidade da primeira camada dos três cenários geológicos escolhidos	73
Figura 33 - BoxPlot dos Erros MAPE de Teste do Último Teste de Sensibilidade	80
Figura 34 - Curva do Óleo Acumulado para o Aproximador com 6 Poços Produtores no Cenário 1	83
Figura 35 - Curva de Gás Acumulado para o Aproximador com 6 Poços Produtores no Cenário 1	83
Figura 36 – Curva de Água Acumulada para o Aproximador com 6 Poços Produtores no Cenário 1	84
Figura 37 - Curva de Óleo Acumulado para o Aproximador com 5 Poços Produtor e 1 Injetor no Cenário 2	89
Figura 38 - Curva de Óleo Acumulado para o Aproximador com 1 Poço Produtor e 5 Injetores no Cenário 2	90
Figura 39 - Curva de Gás Acumulado para o Aproximador com 1 Poço Produtor e 5 Injetores no Cenário 2	91
Figura 40 - Curva de Água Acumulada para o Aproximador com 1 Poço Produtor e 5 Injetores no Cenário 2	91
Figura 41 - Curva de Óleo Acumulado para o Aproximador com 5 Poços Produtores e 1 Injetor no Cenário 3	94
Figura 42 - Curva de Gás Acumulado para o Aproximador com 5 Poços Produtores e 1 Injetor no Cenário 3	94
Figura 43 - Curva de Água Acumulada para o Aproximador com 5 Poços Produtores e 1 Injetor no Cenário 3	95
Figura 44 - Curva de Evolução da Otimização Determinística com Simulador ...	98
Figura 45 - Curva da Evolução da Otimização Determinística com Aproximadores	99
Figura 46 - Comparação das Configurações de Poços na Otimização Determinística	99
Figura 47 - Curva de Evolução da Otimização sob Incerteza com Simulador	102

Figura 48 - Curva de Evolução da Otimização sob Incerteza com Aproximadores	102
Figura 49 – Configuração de Poços para a Otimização sob Incerteza utilizando o simulador	103
Figura 50 – Configuração de Poços para a Otimização sob Incerteza utilizando o aproximador.....	103
Figura 51 - Modelo de Reservatório UNISIM-I.....	112

Lista de Tabelas

Tabela 1 – Descrição das Instruções [6]	49
Tabela 2 – Constantes escolhidas para a PGLIQ.....	66
Tabela 3 – Instruções usadas para evoluir o aproximador.....	67
Tabela 4 – Parâmetros da PGLIQ.....	75
Tabela 5 – Resultados do Teste de Conceito	76
Tabela 6 – Resultados do Teste de Sensibilidade para 11.500 Simulações	77
Tabela 7 – Resultados do Teste de Sensibilidade para 5.800 Simulações	77
Tabela 8 – Resultados do Teste de Sensibilidade para 2.900 Simulações	78
Tabela 9 – Resultados do Teste de Sensibilidade para 1.500 Simulações	79
Tabela 10 - Resultados do Teste de Sensibilidade para 740 Simulações	79
Tabela 11 - Resultados do Teste de Sensibilidade para 370 Simulações	79
Tabela 12 – Comparação entre Média e Mediana do Teste de Sensibilidade	80
Tabela 13 – Resultados dos Aproximadores para 6 Poços Produtores para o Cenário 1.....	81
Tabela 14 – R^2 para os Aproximadores com 6 Poços Produtores para o Cenário 1	82
Tabela 15 - Resultados dos Aproximadores com 5 Poços Produtores e 1 Injetor para o Cenário 1	84
Tabela 16 - Resultados dos Aproximadores com 4 Poços Produtores e 2 Injetores para o Cenário 1.....	85
Tabela 17 - Resultados dos Aproximadores com 3 Poços Produtores e 3 Injetores para o Cenário 1.....	85
Tabela 18 - Resultados dos Aproximadores com 2 Poços Produtores e 4 Injetores para o Cenário 1.....	85
Tabela 19 - Resultados dos Aproximadores com 1 Poço Produtor e 5 Injetores para o Cenário 1.....	86
Tabela 20 - Resultados dos Aproximadores com 6 Poços Produtores para o Cenário 2	87

Tabela 21 - Resultados dos Aproximadores com 5 Poços Produtores e 1 Injetor para o Cenário 2.....	87
Tabela 22 - Resultados dos Aproximadores para 4 Poços Produtores e 2 Injetores para o Cenário 2.....	87
Tabela 23 - Resultados dos Aproximadores para 3 Poços Produtores e 3 Injetores para o Cenário 2.....	88
Tabela 24 - Resultados dos Aproximadores para 2 Poços Produtores e 4 Injetores para o Cenário 2.....	88
Tabela 25 - Resultados dos Aproximadores com 1 Poço Produtor e 5 Injetores para o Cenário 2.....	88
Tabela 26 - Análise dos Aproximadores com 4 Poços Produtores e 2 Injetores para o Cenário 2.....	88
Tabela 27 - Resultados dos Aproximadores com 6 Poços Produtores para o Cenário 3	92
Tabela 28 - Resultados dos Aproximadores com 5 Poços Produtores e 1 Injetor para o Cenário 3	92
Tabela 29 - Resultados dos Aproximadores com 4 Poços Produtores e 2 Injetores para o Cenário 3.....	92
Tabela 30 - Resultados dos Aproximadores com 3 Poços Produtores e 3 Injetores para o Cenário 3.....	93
Tabela 31 - Resultados dos Aproximadores com 2 Poços Produtores e 4 Injetores para o Cenário 3.....	93
Tabela 32 - Resultados dos Aproximadores com 1 Poço Produtor e 5 Injetores para o Cenário 3.....	93
Tabela 33 - Parâmetros Econômicos	96
Tabela 34 - Parâmetros do AG	96
Tabela 35 - Resultados da Otimização Determinística.....	97
Tabela 36 - Estatísticas dos Resultados da Simulação Determinística.....	98
Tabela 37 - Resultados da Otimização sob Incerteza	101
Tabela 38 - Estatísticas dos Resultados da Simulação sob Incerteza	101
Tabela 39 - Resultados do Aproximador de Óleo para 4 Poços	113
Tabela 40 - Resultados do Aproximador de Gás para 4 Poços	114
Tabela 41 - Resultados do Aproximador de Água para 4 Poços	114

1. Introdução

1.1. Motivações

A exploração e produção (E&P) de petróleo no Brasil e no mundo estão associadas a grandes desafios ambientais, políticos, sociais, técnicos e econômicos. Essas adversidades dificultam companhias petrolíferas de aumentarem a oferta do produto, cuja demanda tem alto crescimento.

Apesar de outras fontes de energia estarem em processo de desenvolvimento para aumentar a oferta e diversificar a matriz energética, o petróleo continuará sendo por algum tempo a principal fonte de energia mundial [1]. Além disso, o petróleo não é utilizado apenas como fonte energética, mas também como insumo dos produtos fabricados pela indústria petroquímica. Por isso, o estudo da E&P é de suma importância.

Grande parte das decisões na exploração e produção de petróleo não pode ser testada diretamente em um reservatório físico devido a investimentos extremamente altos. Para auxiliar nessa etapa de tomada de decisão, simuladores são amplamente utilizados nessa área.

Simulação de reservatório é uma das principais áreas da engenharia de reservatórios na qual modelos computacionais são usados para prever o fluxo de fluidos (principalmente petróleo, gás e água) através de meios porosos [2]. Tais modelos computacionais utilizam expressões matemáticas com o propósito de imitar o comportamento da dinâmica dos fluidos dentro do reservatório em diversas condições [3].

A modelagem de um sistema de reservatório é complexa, pois envolve um grande número de variáveis e equações diferenciais para descrever o escoamento do fluido. Assim, existe um alto custo computacional na utilização de um simulador de reservatório, uma vez que são aplicados métodos de diferenças finitas para resolver essas equações. Esse esforço computacional pode tornar certos processos inviáveis [4], como a otimização da localização de poços.

Para que o número de simulações necessárias de um sistema não se torne um fator limitante para a realização de certos processos, diversas técnicas podem ser utilizadas para reduzir o tempo necessário das simulações. Muitas dessas técnicas conseguem aproximar o simulador por automatizarem a regressão simbólica.

A regressão simbólica é um processo de busca de funções para um modelo matemático, que é descrito no formato de dados de entrada e saída. Ou seja, a regressão simbólica visa achar uma função geradora a partir dos dados de entrada que resultem nos dados de saída com o menor erro possível.

1.2. Objetivos

Esta pesquisa descreve a modelagem, implementação e a avaliação de um aproximador de função que seja capaz de substituir com eficiência e precisão o simulador de reservatório (simulador IMEX [5]) na otimização da localização de poços, considerando um reservatório com um número fixo de poços.

Uma técnica da computação de alto desempenho usada para a regressão simbólica, chamada Programação Genética Linear com Inspiração Quântica [6], será usada no desenvolvimento do modelo proposto. Nele deve se considerar a possibilidade de variações na localização e no tipo de cada poço, respeitando um conjunto de restrições operacionais.

No processo de validação do aproximador, este será comparado com os resultados do simulador assim como de outro *proxy* desenvolvido para um reservatório na pesquisa apresentada em [7].

Nesta dissertação pretende-se ainda analisar o desempenho dos *proxies* de reservatório em uma otimização sob incerteza da localização dos poços considerando três cenários geológicos distintos, ou seja, em uma otimização onde o número de simulações é elevado.

1.3. Descrição do Trabalho

O desenvolvimento do modelo de solução foi realizado em diversas etapas. Inicialmente um levantamento bibliográfico sobre a Exploração & Produção de

Petróleo foi realizado. Através desse levantamento, o conhecimento da área foi adquirido para o estudo do simulador de reservatórios IMEX, para a escolha e análise de características importantes a serem levadas em conta no desenvolvimento do aproximador, restrições do problema, limites do modelo e compreensão da lógica da otimização da localização dos poços. Posteriormente artigos e trabalhos relevantes ao tema desta dissertação foram estudados.

Dissecou-se a técnica de computação utilizada (Programação Genética Linear com Inspiração Quântica), aprofundando o conhecimento em inteligência computacional e mineração de dados e, portanto, na área de métodos de apoio à decisão.

Com os fundamentos dominados e utilizando a técnica de Hipercubo Latino para a amostragem, o simulador foi usado para obtenção dos dados de saída: óleo, água e gás acumulados produzidos pelo reservatório durante um determinado período de tempo. Através desses dados, um modelo inicial de solução foi desenvolvido para criar um aproximador desse reservatório.

Através de algumas modificações, o modelo final foi desenvolvido e vários testes, incluindo uma análise de sensibilidade, foram elaborados como estudos de caso. Uma otimização da localização de poços também foi executada substituindo parcialmente o simulador pelo aproximador desenvolvido.

1.4. Organização do Trabalho

Esta dissertação possui seis capítulos, dos quais os próximos cinco estão organizados da seguinte forma:

No Capítulo 2 é feita a fundamentação teórica com o intuito de contextualizar o problema em questão. Descreve-se sobre a formação do petróleo, os mecanismos de produção e como é realizado o desenvolvimento dos campos de petróleo. Também é feita uma breve explicação do funcionamento dos simuladores de reservatório de petróleo. Por fim, os trabalhos publicados relacionados ao tema desta dissertação são tratados neste capítulo.

Já o Capítulo 3 traz uma breve introdução a Programação Genética e introduz a Programação Genética Linear com Inspiração Quântica, a técnica utilizada neste trabalho.

O Capítulo 4 apresenta a metodologia utilizada. A modelagem do aproximador é detalhada, desde a criação das bases de dados até o programa final gerado, passando pela função de avaliação utilizada na evolução dos aproximadores.

O Capítulo 5 contém todos os resultados desta dissertação. Nele é descrito o reservatório utilizado, assim como as métricas de avaliação do desempenho. Um teste de conceito é realizado, além de um teste de sensibilidade para indicar o número de simulações necessárias para a geração do aproximador. Os resultados obtidos são apresentados e discutidos. Por fim, uma otimização da localização dos poços é realizada.

O Capítulo 6 possui a conclusão do trabalho e sugestões de trabalhos futuros.

2. Sistema de Produção de Petróleo

2.1. Geologia e Origem do Petróleo

O óleo e o gás, que são produzidos nos campos, residem em rochas porosas e permeáveis, chamadas de reservatório, onde esses líquidos são coletados e acumulados através de um vasto período de tempo geológico. Os campos de petróleo são resultantes da ocorrência simultânea de quatro tipos de estruturas geológicas: rochas geradoras, rochas reservatórios, rochas selantes e armadilhas [8]. A Figura 1 ilustra essas estruturas.

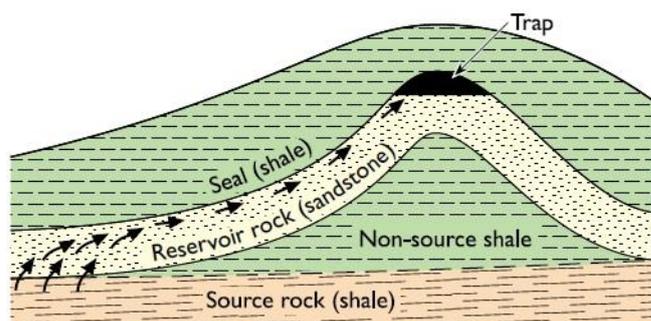


Figura 1 – Tipos de rochas geológicas [9].

2.1.1. Rochas geradoras

O petróleo tem sua origem nas rochas geradoras. Rochas geradoras são rochas sedimentares formadas pelo depósito de sedimentos em águas bem calmas, normalmente pântanos ou configurações marinhas profundas. Essas rochas são compostas de pequenos fragmentos minerais. Entre esses fragmentos existem restos de material orgânico, geralmente algas e micro-organismos, pequenos fragmentos de madeira, etc.

Quando esses pequenos sedimentos são cobertos por outros sedimentos, a temperatura e pressão aumentam transformando os sedimentos antes flexíveis em

camadas rígidas de rochas. Com o contínuo acúmulo de sedimentos, a temperatura continua crescendo. Quando a temperatura das rochas sedimentares ricas em material orgânico ultrapassa certo valor, os restos orgânicos dentro dos sedimentos começam a sofrer transformações termoquímicas e o óleo e gás natural começam a ser produzidos. Milhões de anos são necessários para que as rochas geradoras sejam enterradas profundas o bastante para atingir essa temperatura de maturação. E mais alguns milhões de anos para acumular óleo e gás e migrar para as rochas reservatório.

O tipo de hidrocarboneto gerado é determinado pela constituição da matéria orgânica original e pela intensidade do processo térmico atuante sobre a mesma. Se a maior parte do material orgânico dentro das rochas geradoras for fragmentos de madeira, então o hidrocarboneto gerado na maturação será o gás natural. Porém, se a maior parte do material orgânico for algas, então óleo e gás serão gerados [9].

2.1.2. Rochas Reservatórios

Rochas reservatórios são porosas e permeáveis, pois contém espaços entre os grãos minerais da rocha e interconexão entre esses espaços. Quando o óleo e o gás natural são expelidos das rochas geradoras, eles migram para as rochas reservatórios adjacentes [10]. A Figura 2 mostra uma imagem microscópica de uma rocha reservatório, indicando claramente a porosidade desse tipo de rocha.

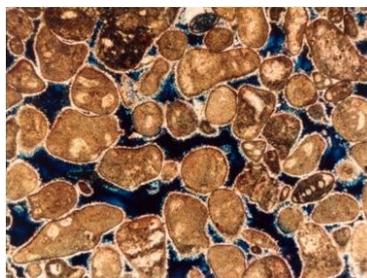


Figura 2 – Visão microscópica da rocha reservatório [11]

Uma vez dentro das rochas reservatórios, o petróleo se movimenta em direção à superfície. Ao encontrar com uma rocha impermeável, a migração é interrompida. Essa rocha impermeável é chamada de rocha selante.

2.1.3. Rochas Selantes

Rochas selantes são rochas cujos grãos não têm poros ou onde os espaços porosos são tão pequenos que não permitem a entrada de fluidos. Por isso, o óleo e o gás natural são bloqueados e a migração é cessada. Considerando que o processo de migração é lento, é esperado que os fluidos acumulados estejam gravitacionalmente separados de acordo com suas densidades. Assim, o gás natural geralmente é acumulado na parte superior, o óleo na parte central e a água abaixo dos outros dois.

O arranjo de rochas reservatórios e rochas selantes pode formar uma armadilha, como é mostrada na Figura 1. Nessa armadilha ocorre o acúmulo de óleo e gás e, conseqüentemente, o campo de petróleo é formado. Sem esse mecanismo geológico, o petróleo continuaria migrando em busca de zonas de menor pressão até se perder na superfície através de exsudações, oxidação ou degradação bacteriana [9].

2.2. Produção de Petróleo

Para que os fluidos, contidos em uma armadilha, possam ser produzidos é necessária certa quantidade de energia para conseguir vencer toda a resistência oferecida pelos canais porosos e se deslocar para os poços de produção. Essa energia é denominada energia natural ou primária, manifestada por certa quantidade de pressão, e se origina de todos os fenômenos geológicos que a jazida passou até se formar completamente [12].

O conjunto de fatores que fazem desencadear efeitos que resultam em produção de fluidos é conhecido como mecanismos de produção de reservatório. Os mecanismos de produção fundamentais são o mecanismo de gás em solução, o mecanismo de capa de gás e o mecanismo de influxo de água. Já os efeitos considerados principais são a descompressão, que causa a expansão dos fluidos contidos no reservatório e a contração do volume poroso, e o deslocamento de um fluido por outro fluido.

2.2.1. Mecanismo de gás em solução

O mecanismo de gás em solução ocorre em um reservatório onde não existe a possibilidade de interferência do ambiente externo, ou seja, toda a energia disponível para a produção se encontra armazenada na própria zona de óleo. A Figura 3 ilustra um reservatório com esse mecanismo.

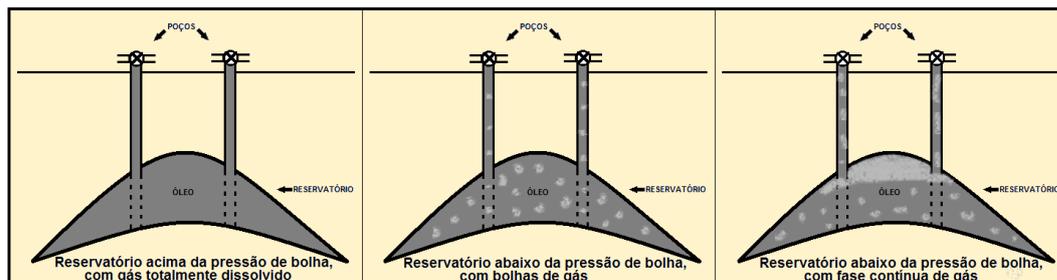


Figura 3 – Reservatório com mecanismo de gás em solução

Conforme o óleo vai sendo retirado do reservatório, a pressão interna do mesmo diminui. Como consequência, os fluidos dentro do reservatório se expandem e o volume dos poros diminui. Assim, um processo cíclico é iniciado, pois com a expansão dos fluidos e a redução do volume dos poros não há espaço suficiente para conter o volume atual do fluido, resultando em mais produção. Produzindo mais, a pressão diminui causando novamente a expansão dos fluidos.

Essa redução da pressão continua até atingir a pressão de bolha do óleo onde o processo cíclico sofre uma alteração. Além da expansão dos fluidos, ocorre a vaporização das frações mais leves do óleo. A partir deste ponto é que começa a atuar o mecanismo de gás em solução, pois, como o gás é mais expansível que o líquido, ao sofrer expansão irá deslocar o líquido para fora do meio poroso.

Porém, conforme a pressão cai, mais hidrocarbonetos vão sofrendo gaseificação e começam a formar uma fase contínua. Assim, o gás começa a fluir no meio poroso e a ser produzido juntamente com o óleo. Como a produção é consequência da expansão do gás, quando parte de seu volume for produzido, a energia do reservatório vai se esgotando [12].

A pressão do reservatório declina rápida e continuamente, reduzindo drasticamente a vazão de óleo produzida a valores antieconômicos. Por isso, a

razão entre o volume produzido de óleo e o volume total presente de óleo no reservatório, chamada de fator de recuperação, é baixa, por volta de 20% do volume original de óleo.

Nos reservatórios com este mecanismo de produção a relação entre a produção de gás e a produção de óleo, chamada razão gás/óleo, é baixa no início e aumenta rapidamente até chegar ao máximo valor, e com o decréscimo da pressão a vazão de produção de gás é reduzida e conseqüentemente a razão gás/óleo também, como mostra a Figura 4. A redução na razão gás/óleo logo após a pressão atingir valores menores que a pressão de bolha é devido ao fato de que a saturação de gás existente no reservatório ainda é menor que a saturação crítica, ou seja, a saturação de gás está abaixo do mínimo necessário para que esse gás possa fluir, sendo portanto insuficiente para haver fluxo de gás em direção aos poços produtores [12].

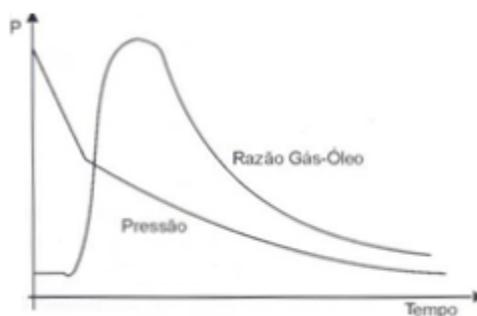


Figura 4 – Características do mecanismo do gás em solução

2.2.2. Mecanismo de Capa de Gás

Em um reservatório de petróleo, dependendo das condições de temperatura e pressão, pode haver duas fases em equilíbrio, uma líquida e outra vapor (gás livre). Como a fase vapor é menos densa que a fase líquida, o gás tende a se depositar na parte superior da superfície porosa do reservatório, formando a chamada capa de gás [12], e a própria compressibilidade do gás é responsável por fornecer energia para a produção do óleo [13].

A Figura 5 ilustra um reservatório com mecanismo de capa de gás. Nos reservatórios com este tipo de estrutura, a zona do líquido é colocada em

produção, enquanto a zona do gás é preservada, já que a principal fonte de energia para a produção está no gás da capa [12].

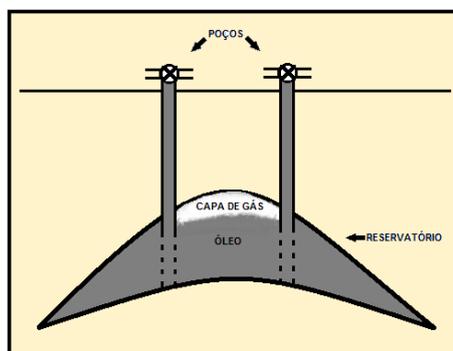


Figura 5 – Reservatório com mecanismo de capa de gás

Quando se inicia a produção de óleo, a pressão dentro do reservatório é gradativamente reduzida para retirada do fluido e, em contrapartida, o gás da capa se expande e penetra gradativamente na zona de óleo, empurrando o óleo em direção as facilidades de produção. Como o gás possui uma compressibilidade muito alta, sua expansão ocorre sem que haja queda substancial da pressão e com isso os espaços que antes eram ocupados pelo óleo passam a ser ocupados pelo gás [14][15].

Segundo [15], o tamanho da capa de gás tem uma influência muito grande. Quanto maior o volume da capa de gás quando comparado ao volume de óleo (ambos medidos nas condições de reservatório) maior será a atuação da capa, ou seja, poderá ser mantida a pressão no reservatório por mais tempo.

Em [13] é explicado que o posicionamento dos poços tem como critério escolher os intervalos de completação o mais distante possível da capa de gás (que se expandirá com o tempo), mas não tão próximo do contato óleo-água (se houver) para não gerar uma grande produção de água.

O mecanismo de capa de gás apresenta uma queda de pressão muito mais lenta quando comparado ao mecanismo de gás em solução. A razão gás/óleo na superfície aumenta conforme a capa de gás em expansão se aproxima dos poços produtores. A Figura 6 mostra o gráfico com as características deste mecanismo. De acordo com [13], o grau de atenuação na diminuição de pressão é função do volume de gás produzido e do volume da capa de gás.

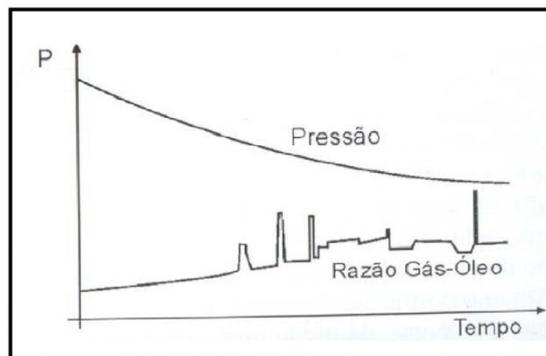


Figura 6 – Características do mecanismo de capa de gás

Em reservatórios com mecanismo de capa de gás o fator de recuperação se encontra entre 20 e 30% [12]. Todavia [13] afirma que este fator pode chegar até 60% dependendo do mergulho do reservatório e do tamanho da capa de gás.

2.2.3. Mecanismo de Influxo de Água

Outro mecanismo é o de influxo de água que ocorre quando o reservatório de petróleo se encontra em contato direto com uma grande acumulação de água [16], e a essa formação saturada de água dá-se o nome de aquífero, que podem estar subjacentes ou ligadas lateralmente ao reservatório [14]. Na Figura 7 é possível observar um reservatório com mecanismo de influxo de água.

Quando o óleo começa a ser produzido, a pressão no reservatório cai e depois de certo tempo transmite para o aquífero, que responde a queda de pressão através da expansão da água nele contida e também através da redução do seu volume poroso. Com isso o espaço poroso do aquífero não consegue manter toda água contida inicialmente, causando uma invasão da zona de óleo pelo volume excedente de água, deslocando o óleo até os poços de produção e mantendo a pressão do reservatório.

Este processo é contínuo, ou seja, a queda de pressão na zona de óleo causada pela produção desse fluido se transmite para o aquífero, que responde com invasão de água na zona de óleo, o que acarreta a produção de mais óleo, e assim por diante. Para que este mecanismo atue é necessário que as alterações das condições de reservatório causem alterações no aquífero e vice-versa, e essas influências só ocorrem se o reservatório e o aquífero estiverem intimamente ligados [14].

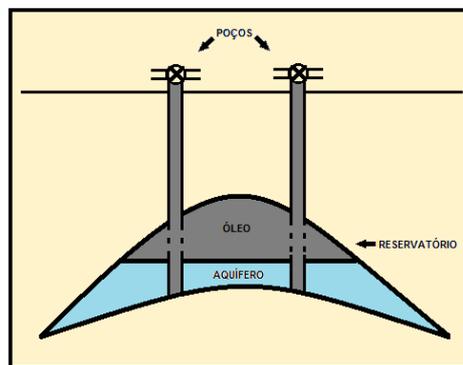


Figura 7 – Reservatório com mecanismo de influxo de água

Para o funcionamento correto deste mecanismo é necessário que o aquífero tenha grandes proporções, visto que as compressibilidades da água e da rocha são pequenas, e apenas grandes volumes de água e de rocha são capazes de produzir um grande influxo de água necessários para manter a pressão do reservatório em níveis elevados e com boas vazões de produção quando existe uma redução de pressão no reservatório [15].

É necessário o controle da produção de óleo, visando minimizar a formação de caminhos preferenciais da água no seu percurso em direção ao poço, pois estes caminhos preferenciais, uma vez formados, dificilmente podem ser dissipados [13].

Neste tipo de mecanismo a pressão decresce lenta e continuamente no tempo, enquanto a razão água/óleo se comporta de forma inversa, como se pode observar no gráfico da Figura 8.



Figura 8 – Características do mecanismo de influxo de água

O fator de recuperação de reservatórios com este tipo de mecanismo é normalmente alto, cerca de 30 a 40%, podendo chegar a valores de até 75%, dependendo do aquífero natural ou da eficiência com que a água desloca o óleo. Esse valor relativamente alto deve-se principalmente ao fato de que a pressão permanecendo alta, além das vazões também permanecerem altas, mantém as características dos fluidos próximas às originais [13], [14].

Devido à grande quantidade de óleo que pode ser deixada no reservatório com esses mecanismos, é feita uma busca por técnicas mais eficientes para aumentar a recuperação de óleo. Entre as técnicas desenvolvidas, destacou-se a injeção de água, que se tornou um dos métodos de recuperação mais utilizados no mundo pela indústria do petróleo, devido à maior disponibilidade de água e a maior relação custo-benefício [17].

A injeção de água é usada na produção de petróleo para melhorar e acelerar a recuperação de óleo [18]. Esse método é conhecido como “recuperação secundária” e é empregado quando a pressão do poço torna-se insuficiente para expulsar naturalmente o petróleo [19]. Fisicamente o processo de recuperação pela injeção de água é feito através do deslocamento dos fluidos não miscíveis contidos no reservatório pela água, com o intuito de aumentar a produção de óleo [17]. Poços injetores são posicionados no reservatório de modo a maximizar o efeito da injeção de água na otimização da produção.

Para que o processo de injeção de água seja bem sucedido na recuperação do óleo, é necessário que haja um controle eficiente nas vazões de injeção e de produção para conservar ao máximo a pressão dentro do reservatório, conseguindo assim recuperar o máximo de óleo possível. A eficiência da injeção relaciona a produção de óleo com a injeção de água que influencia esta produção, ou seja, relaciona o volume de óleo produzido com volume de água injetado [12].

À medida que a água vai penetrando no meio poroso o óleo vai sendo empurrado de baixo para cima, na direção dos poços de produção que estão situados na parte mais alta da estrutura. É como se fosse criando um aquífero artificial. Dá-se a esse esquema o nome de injeção na base. Em algumas situações, podem-se converter poços produtores em injetores. Quando o contato óleo/água avança, atinge os poços de produção que estão completados na parte mais baixa da estrutura. Ao ser atingido pela água, além de óleo, o poço começa a produzir água, aumentando a razão água/óleo. Com o tempo, essa razão se torna excessiva,

podendo simplesmente fechar o poço ou transformá-lo em injetor, evitando os custos elevados de perfuração [19].

Esse método pode não ser adequado para alguns casos. Entre os reservatórios mais comuns para os quais não é indicado o uso de injeção de água estão os heterogêneos e os que apresentam pouca continuidade, pois o efeito da injeção de água pode não chegar ao produtor, ou pode ocorrer o processo inverso, no qual a água escoar por fraturas ou caminhos preferenciais causando uma produção de água elevada desde o início da injeção [19].

2.2.4. Métodos de Recuperação Avançados

São processos mais complexos cujas tecnologias ainda estão em constante desenvolvimento. Esses métodos podem ser empregados para atuar nos pontos onde o processo convencional não conseguiu atingir as taxas de recuperação desejadas.

As baixas recuperações obtidas de um reservatório podem ter como causas: a alta viscosidade do óleo do reservatório e as elevadas tensões interfaciais entre o fluido injetado e o óleo. Estes fatores podem vir a definir a forma de atuação dos métodos especiais de recuperação e é o ponto de partida para sua distribuição em três categorias: métodos químicos, métodos miscíveis e métodos térmicos.

2.3. Desenvolvimento de Campos de Petróleo

Durante o ciclo de vida, desde a exploração até o abandono, um campo de petróleo requer participação de diferentes especialistas para tomar importantes decisões de investimento e decisões operacionais. Estas decisões devem ser tomadas em condições onde os dados do reservatório são escassos e há existência de incerteza não só sobre os custos e desempenho futuro do campo, mas também com relação ao preço futuro e demanda do mercado para o petróleo e gás produzidos.

O desenvolvimento de um campo petrolífero pode ser dividido em alguns estágios. O primeiro seria a identificação e avaliação de oportunidades, ou seja, o processo de exploração. O segundo estágio é o planejamento do desenvolvimento,

onde especialistas realizam estudos de viabilidade a fim de definir o plano de desenvolvimento ótimo para o campo, incluindo custos, cronogramas e projetos econômicos. O próximo estágio é a execução do plano de desenvolvimento, ou seja, é o período de construção do campo. O último estágio é a gestão das operações de produção, cujos objetivos são otimizar a produção, melhorar a eficiência e maximizar o valor presente líquido do ativo realizando investimentos adicionais para recuperar reservas incrementais.

2.3.1. Caracterização do Reservatório

Na identificação e avaliação de oportunidades, é realizado o estudo da caracterização do reservatório. A caracterização consiste em descrever as propriedades básicas das rochas e dos fluidos do reservatório, tais como porosidade, permeabilidade, saturações, etc. A análise dessas propriedades permite obter parâmetros importantes para determinar a viabilidade técnico-econômica do campo de produção em questão.

Uma ferramenta principal para a caracterização do reservatório é a sísmica. Na exploração marinha, técnicas que utilizam propagação de ondas acústicas, como sonografia e batimetria, são usadas para fornecer informações sobre o solo marinho, as correntes marinhas e a presença de objetos no fundo do mar [20].

A sísmica apresenta uma importância maior na indústria do petróleo por fornecer dados sobre a disposição estrutural das camadas sedimentares. Ela proporciona uma alta taxa de aquisição de dados que, após processados e interpretados, são utilizados para estudos de desenvolvimento de campos [20].

Um das principais propriedades é a porosidade, que nada mais é que a característica de uma rocha poder armazenar fluidos em seus espaços interiores (poros), ou seja, é a relação entre o volume de vazios e o volume total da amostra. Este parâmetro depende do tamanho e da forma dos grãos, bem como o grau de compactação do material geológico. Outra propriedade importante é a permeabilidade que está correlacionada diretamente com a quantidade de poros que estão interconectados, fenômeno este fundamental para que o óleo se mova ao longo dos poros até o poço, permitindo a produção.

A Figura 9 ilustra cenários geológicos diferentes. As formações com alta porosidade e alta permeabilidade constituem bons reservatórios. Enquanto que uma formação rochosa com alta porosidade, mas baixa permeabilidade, pode conter uma elevada quantidade de óleo, mas este flui lentamente.

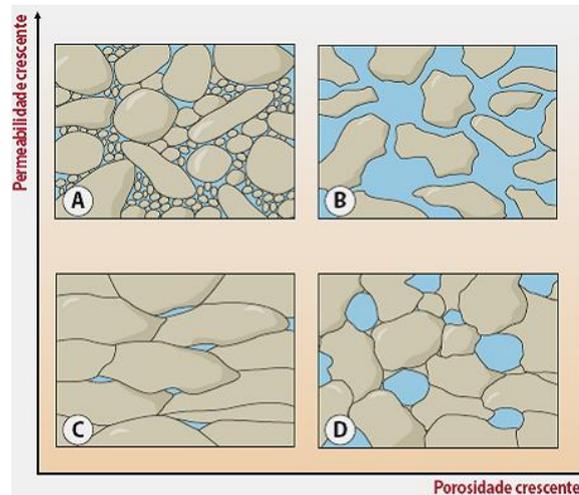


Figura 9 – Cenários com porosidade e permeabilidade diferentes [21].

2.3.2. Poços de Petróleo

O poço de petróleo é o elo entre a rocha reservatório e a superfície, assim as atividades de perfuração de poços se revestem de certa complexidade à medida que são desdobradas em subatividades. Esse desdobramento pode ser quanto ao sistema de produção, quanto à trajetória do poço, quanto à profundidade final e quanto à finalidade.

Um poço de petróleo pode ter três finalidades: exploração, exploração e especial. Os poços exploratórios são aqueles que visam à descoberta de novos campos ou jazidas de petróleo. Já os poços exploratórios servem para extrair o óleo da rocha reservatório. Por último, os especiais são todos aqueles que são perfurados sem o objetivo de procurar ou produzir petróleo.

Os poços exploratórios podem se dividir em desenvolvimento e injeção. O primeiro são os poços perfurados dentro dos limites do campo para drenar racionalmente o petróleo. O segundo são os poços perfurados com a intenção de injetar fluidos na rocha reservatório para ajudar na recuperação do petróleo [22].

2.3.3. Otimização do Plano de Desenvolvimento

No planejamento do desenvolvimento, um plano de desenvolvimento define uma alternativa. Uma alternativa é uma das tarefas mais importantes na área de reservatórios, dado que aquela afeta o comportamento do reservatório, decisões futuras, análises econômicas e, conseqüentemente, a atratividade resultante do projeto definido. Isto envolve variáveis tais como a locação, número e tipos de poços, as condições de operação características do reservatório e, inclusive, o cenário econômico. A determinação do número e localização dos poços é uma das atividades mais importantes na seleção de estratégia de produção e por isso deve ser otimizada.

A maioria dos sistemas que visam otimizar alternativas de desenvolvimento envolvem o uso de simuladores, mesmo tendo um alto custo computacional. Inicialmente, o critério de otimização utilizado no desenvolvimento de campos de petróleo era a quantidade de óleo acumulado recuperado para um dado tempo de simulação. Porém, em trabalhos posteriores, o critério de otimização passou a ser do tipo econômico, onde são procuradas configurações de produção que maximizem algum indicador econômico, sendo o valor presente líquido o indicador mais utilizado.

Neste trabalho será usado um programa resultante de uma parceria de pesquisa e desenvolvimento, entre a Petrobras e o Laboratório ICA. O Octopus é um sistema computacional desenvolvido inicialmente para a otimização de planos de drenagem baseado na simulação numérica de reservatórios. Assim, a partir da descrição de um reservatório modelo de simulação, o sistema busca encontrar, por meio de um algoritmo genético, uma configuração de poços que maximize o VPL (Valor Presente Líquido) do projeto. No processo de busca pela melhor configuração, são levados em consideração a quantidade, o tipo (injetor ou produtor), a trajetória vertical, horizontal ou direcional) e a localização dos poços.

2.3.4. Alternativas Econômicas

O desenvolvimento de um campo de óleo ou gás requer um alto investimento, principalmente em campos *off-shore*, e pode ser realizado de

diversas maneiras. Conseqüentemente, existem várias formas de aplicação de capital, onde cada alternativa requer determinados recursos e proporciona determinados retornos financeiros. Deste modo, essas alternativas devem ser comparadas para que possa ser escolhido a mais adequada. Geralmente, o indicador econômico mais usado é o valor presente líquido.

2.3.4.1. Valor Presente Líquido

O valor presente líquido é uma fórmula matemático-financeira capaz de determinar o valor presente de pagamentos futuros descontados a uma taxa de juros apropriada, menos o custo do investimento inicial. Ou seja, é o cálculo de quanto os futuros pagamentos somados a um custo inicial estariam valendo atualmente. No caso de desenvolvimento de campos petrolíferos, o valor presente vem a ser o quanto vale o campo hoje levando em consideração que os pagamentos, dados a partir da produção, só serão realizados nos anos sucessivos.

2.4. Simuladores de Reservatório

Um simulador de reservatório é um programa computacional através do qual é possível estimar características e prever o comportamento de um reservatório de petróleo sob diferentes condições de operação. O núcleo desse programa é a modelagem matemática de fluidos através de um meio poroso [23]. Essa modelagem de fluidos consiste basicamente de um conjunto de equações diferenciais que modelam os fluxos no reservatório em todas as fases.

Alguns dos modelos de fluxo mais utilizados em simulações de reservatório são os modelos *black-oil*, o composicional, os térmicos e os modelos de fluxo miscível [24].

A maioria dos simuladores atualmente é baseada em malhas devido à flexibilidade de modelar quaisquer reservatórios do mundo real. A modelagem em malha consiste em discretizar o reservatório real em blocos mínimos e em realizar o balanço de material e energia para cada um dos blocos empregando métodos de diferenças finitas. A Figura 10 ilustra a discretização de um reservatório.

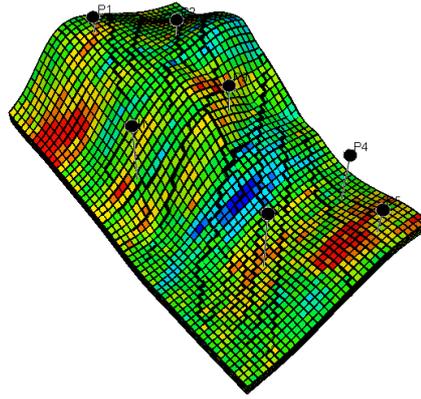


Figura 10 – Discretização de um reservatório.

Neste trabalho será usado o modelo *black-oil*, em que são consideradas a ocorrência de três fases (água, óleo e gás), também chamado de trifásico. Admite-se que cada uma das três fases presentes no reservatório seja constituída de um único componente. Assim é que, por exemplo, considera-se que a fase óleo seja formada por um único componente, denominado simplesmente óleo, embora se saiba que o óleo é constituído por diversos hidrocarbonetos. São estabelecidos esses componentes para diminuir a matriz resultante do problema já que normalmente o número de componentes é muito grande.

O tratamento matemático do modelo *black-oil* envolve funções da pressão e da temperatura do reservatório. Esse modelo pode ser útil em mais de três quartos de todas as aplicações do simulador adequadamente. No entanto, ele não é adequado para os estudos que deve levar em conta a mistura de fluidos com propriedades significativamente diferentes ou reações de combustão [24].

A principal utilização do simulador numérico de reservatório neste trabalho será prever o comportamento futuro do mesmo. Vários esquemas de exploração podem ser avaliados mudando a localização dos poços, e uma análise econômica pode ser feita com os resultados, de forma que se possa decidir pelo esquema ótimo de produção.

2.5. Revisão Bibliográfica

Dentro do tema de *proxies* para substituição de simuladores de reservatórios, a literatura apresenta diferentes abordagens, como em [25]–[35].

Embora distintos, a maioria desses trabalhos utilizou as redes neurais artificiais como técnica de computação para criar o aproximador.

Em [36], foi apresentado um estudo que mostra as vantagens e desvantagens do tema abordado. Para ajuste de histórico, otimização da produção e previsões, o uso da metodologia de *proxies* é considerado uma alternativa computacionalmente vantajosa quando comparado ao uso do simulador. Geralmente como metamodelo são usados redes neurais, regressão polinomial, krigagem e *thin-plate splines*. Em [36], é concluído que todo *proxy* mostra forte dependência na complexidade do modelo, dimensionamento do espaço de desenvolvimento e qualidade dos dados de entrada. Sobre a otimização da produção em específico, a natureza do problema requer que a solução seja melhor que a atual e não necessariamente a melhor possível, ou seja, *proxies* podem produzir resultados bons se o objetivo do projeto não for encontrar a melhor solução.

O artigo [25] investiga dois algoritmos de interpolação multivariada, krigagem e mínimos quadrados, para gerar novas realizações a partir de um número limitado de simulações a fim de prever as estratégias ótimas no cronograma de abertura dos poços e na localização desses. No estudo da localização de poços algumas limitações foram impostas como, por exemplo, a homogeneidade do reservatório sintético e a vazão de produção total considerada igual a vazão de injeção. Um esquema híbrido junto com algoritmos genéticos, cuja função objetivo é o valor presente líquido, foi utilizado para encontrar a melhor solução. Em [25] foi assumido um padrão que é composto por quatro poços produtores e um injetor, totalizando quatro variáveis de decisão para serem otimizadas. Essas variáveis são: a localização bidimensional do poço injetor, um fator que representa o formato do padrão e o tempo de injeção total, que representa o tempo de injeção total ótimo com máximo valor presente líquido para cada padrão em particular. Ainda, esse trabalho indica que simulações adicionais podem ser realizadas para melhorar o resultado final e validá-lo.

Em [26] e [27], os autores demonstram uma técnica de neuro-simulação que faz uma ponte entre a simulação precisa do reservatório e uma rede neural artificial preditiva. O estudo descreve como a união entre *soft* e *hard computing* permite uma rápida e eficiente seleção da localização dos poços mantendo uma precisão satisfatória. Nestes métodos, diversos cenários chaves de poços de um reservatório sintético homogêneo são selecionados por engenheiros ou de forma

aleatória para, em seguida, serem simulados e posteriormente usados para o treinamento da rede.

A principal diferença entre esses trabalhos é que, em [26], só um poço produtor é otimizado enquanto que em [27] mais de um poço produtor pode ser otimizado, sendo esse número definido antes do treinamento da rede neural. As entradas da rede foram divididas em duas categorias: entradas estacionárias (localização dos poços e tempo de produção) e entradas de estudos específicos (distância entre dois poços de treinamento, distância entre os poços de treinamento e poços fixos e expressões funcionais para o tempo de produção e localização dos poços). Já a saída da rede é a produção de óleo em cada novo poço no tempo sinalizado na entrada da rede. Logo, o método consiste em escolher um número de poços de treinamento de acordo com o reservatório utilizando algumas regras, construir a base de dados, treinar a rede, gerar amostras aleatórias para serem avaliadas pela rede neural. Em [27], além dessas etapas, as regiões mais bem avaliadas são selecionadas e novas amostras são geradas dentro dessa região para serem avaliadas. Também, na criação da base de dados os poços de treinamento são combinados de acordo com o número de poços que se deseja perfurar no campo.

Os autores em [28] propõem uma técnica de otimização híbrida baseada em algoritmos genéticos (AG), algoritmo polítopo, krigagem e redes neurais. A hibridização do AG com esses métodos auxiliares fazem com que o algoritmo de *hill climbing* seja inserido na procura estocástica e que proxies sejam criadas a cada geração. O desempenho dessa técnica foi avaliado para um conjunto de simulações exaustivas para o problema de locação de um poço injetor e foi observado que o número de simulações reduziu significativamente.

A estrutura do método consiste em algumas etapas. A primeira é gerar poucas alternativas com o AG com alta taxa de mutação para balancear a natureza determinística dos métodos auxiliares. Em seguida, essas alternativas são simuladas e o algoritmo polítopo é aplicado utilizando as três melhores alternativas, substituindo a pior alternativa da população caso seja encontrada uma que seja melhor avaliada. Por último, a *proxy* é construída com os pontos até então simulados e uma otimização é realizada com a superfície gerada por esse aproximador. O melhor resultado é avaliado pelo simulador e caso seja realmente

uma alternativa ótima é inserida na população. O método continua até alcançar um critério de parada.

Usando essa técnica híbrida, também foi otimizada a localização, assim como a vazão de injeção, de até quatro poços injetores verticais para um campo *offshore* no Golfo do México chamado Pompano. Nesse estudo, o valor presente líquido foi usado como função de avaliação.

Em [29] descreve-se um estudo similar ao [28], em que redes neurais foram utilizadas como *proxies* para avaliar as alternativas de injeção de água geradas por um algoritmo genético. O objetivo era o mesmo, encontrar uma solução de 1 a 4 poços injetores verticais com melhor valor presente líquido para o campo Pompano. Porém, a construção do aproximador é realizada *offline*, ou seja, o conjunto de dados de treinamento é fixo e uma vez criado o aproximador, ele não muda.

Para criar esse conjunto de treinamento, os dados são amostrados da seguinte forma: o caso com a configuração inicial do campo, 25 casos com um poço injetor (quatro configurações com o injetor substituindo um poço produtor fixo do campo e os 21 restantes com novas posições) e duas etapas são iteradas até chegar ao número limite de simulações. A primeira é escolher aleatoriamente o número de poços de 2 a 4. Já a segunda é escolher aleatoriamente a localização dos poços, tendo como base os 25 casos considerando apenas um poço injetor.

Em [30], os autores também usam o AG utilizando um aproximador com a técnica de redes neurais. Contudo, nesse estudo é otimizado o tipo, localização e trajetória de um poço não convencional. O problema se torna bastante complexo devido a novas variáveis que devem ser otimizadas, como número, localização e orientação das laterais do poço.

A construção do proxy em [30] é feita *online*, ou seja, o conjunto de treinamento muda constantemente e a rede precisa ser treinada novamente. As amostras da base de treinamento são criadas a cada geração do algoritmo genético, fazendo com que os resultados do aproximador sejam mais confiáveis em gerações posteriores. Como o objetivo é melhorar continuamente a avaliação da população, é preciso evitar situações onde a rede neural subestima a avaliação de um bom indivíduo. Por isso, os autores usufruíram do simulador durante a otimização pois as redes neurais artificiais não extrapolam com acurácia além dos

limites de treinamento. Esse novo passo é utilizado quando a rede ultrapassa um valor limiar, que vai mudando a cada geração.

O artigo em [33] apresenta uma abordagem em que uma técnica de otimização híbrida baseada novamente em algoritmo genético e sistema Neuro-Fuzzy para o *proxy* no intuito de reduzir o número de simulações dispendiosas e demoradas. O *proxy* foi construído inicialmente a partir de uma base de dados com amostras de um reservatório sintético heterogêneo simuladas previamente. A função objetivo era maximizar o VPL inserindo quatro poços produtores verticais. A cada geração do algoritmo genético, o aproximador era novamente treinado com três novas amostras originadas da simulação dos três melhores indivíduos encontrados naquela geração.

Os autores em [32] introduziram uma metodologia utilizando programação genética para construir *proxies* para os simuladores de reservatório. Porém, nesse estudo o *proxy* não é para otimização da produção. Considerando que resultados inadequados do ajuste de histórico frequentemente levam a um elevado grau de incerteza na previsão da produção, os autores construíram dois *proxies*: um para ajuste de histórico e o outro para previsão de produção.

As amostras para o treinamento foram geradas através de uma amostragem uniforme dos parâmetros do modelo do reservatório que foram passados para o simulador. A mesma base de dados é utilizada para ambos os aproximadores, porém com saídas diferentes. O *proxy* para ajuste de histórico é um classificador que separa os modelos de reservatório como aceitáveis ou não de acordo com valor limiar dado para o erro. O *proxy* de previsão faz uma regressão fornecendo como saída os valores de óleo acumulado. Previsores mais confiáveis são criados, pois são utilizados como entrada modelos classificados como aceitáveis pelo *proxy* de ajuste de histórico.

Em [35], foi apresentado um trabalho em que visa construir superfícies de respostas baseadas em funções quadráticas, multiplicativas ou radiais para expressar a produção de óleo acumulado em função da localização, direção e comprimento de apenas um poço produtor horizontal em um reservatório sintético heterogêneo (propriedades geológicas diferentes para cada bloco discretizado). Foram utilizados diversos métodos de amostragem. Dentre eles, o método seletivo foi o que melhor se ajustou ao treinamento e fez melhor previsão no teste. Nesse método, são escolhidas as localizações com maior produção de óleo acumulado de

um grupo de pontos já simulados para serem as amostras de treinamento. Já o Hipercubo Latino para a amostragem teve os melhores resultados na otimização do poço.

Nesse estudo, o processo de criação do metamodelo consiste primeiramente em escolher os pontos iniciais através de um projeto de experimentos. Após essa etapa, o *proxy* é construído por regressão e ajustado com os pontos iniciais. Uma otimização utilizando o algoritmo genético é realizada, tendo como função objetivo o óleo acumulado de um poço horizontal. Por último, é verificado se a solução ótima do algoritmo genético encontra-se repetida na população do mesmo, propondo o modelo caso afirmativo. Caso contrário, a solução ótima é adicionada aos pontos iniciais eliminando o pior ponto, recomeçando o processo.

O artigo em [31] trabalhou com duas técnicas de inteligência computacional para a criação do *proxy*. Com redes neurais e Neuro-Fuzzy hierárquico, foram desenvolvidos modelos de aproximação de curvas de produção. Para o treinamento desses modelos, duas abordagens foram seguidas. A primeira visa aproximar uma curva de óleo acumulado e a segunda pretende aproximar uma curva segmentada de razão de produção. Em ambas as abordagens, a base de dados foi criada apenas com poços verticais com número de poços produtores e injetores definidos previamente e com as completação em todas as camadas, ou seja, os poços eram vazados para a entrada do fluido em todas as camadas do reservatório). Em [31] também foi utilizado o algoritmo genético para maximizar o valor presente líquido.

Nesta dissertação, assim como em alguns trabalhos anteriores, a quantidade de poços verticais a ser otimizados é definida previamente. Porém neste trabalho, uma tentativa de criar uma metodologia universal de construções de aproximadores é desenvolvida, utilizando também como critério o menor número possível de simulações.

3. Programação Genética

3.1. Introdução

A origem da Computação Evolucionária (CE) data da década de 50, quando foi iniciado o uso dos princípios de Darwin para a resolução de problemas automaticamente. Essa área da Inteligência Computacional começou com três ramos separados (estratégias evolucionárias, programação evolutiva e algoritmos genéticos) e apenas na década de 90 eles foram unificados. A Programação Genética, termo cunhado independentemente por John R. Koza e Hugo DeGaris em trabalhos publicados também nessa década [37], surgiu como um novo ramo da Computação Evolucionária.

Quando a definição de Koza para este termo começou a predominar, a maioria dos pesquisadores passou a representar a evolução de programas por estruturas em árvore e, mais especificamente, na forma de programas em linguagem LISP (*List Processing*) [6]. Entretanto, atualmente entende-se por Programação Genética toda forma evolutiva de indução de programas [38].

A Programação Genética (PG) é uma técnica que permite computadores resolverem problemas sem que sejam explicitamente programados para tal. Assim, a PG parte de uma declaração de alto nível sobre o objetivo e cria automaticamente um programa de computador para resolver o problema.

Como todos os ramos da CE, a PG é composta por um algoritmo probabilístico inspirado no princípio de evolução das espécies. Uma população é iniciada com um conjunto de soluções aleatórias, diferente das técnicas determinísticas em que somente é possível ter uma solução em cada instante de tempo. Assim, cada indivíduo da população representa uma solução completa do problema. Como na evolução das espécies, a pressão seletiva faz com que, a cada geração, sejam gerados indivíduos iguais ou melhores que os melhores indivíduos da geração anterior [39]. A característica de métodos baseados em CE é que estes

permitem sua aplicação a uma variedade de problemas mesmo quando não se sabe a forma da solução analítica [40].

A PG diferencia dos demais ramos pois é uma técnica para evoluir processos computacionais, como programas de computador. Nesta técnica os cromossomos (indivíduos) são tratados como programas escritos em um subconjunto ou variação de uma linguagem de programação convencional [41].

De forma geral, o algoritmo básico da Programação Genética é equivalente ao algoritmo do Algoritmos Genéticos, a forma mais conhecida da CE. A busca pelo melhor indivíduo é feita avaliando iterativamente a aptidão dos indivíduos em uma população e aplicando operadores genéticos aos indivíduos mais aptos, de forma a explorar diferentes áreas promissoras do espaço de busca. Em PG, um indivíduo tem sua aptidão avaliada pela execução do programa e pelo acesso à qualidade de sua saída resultante.

O desenvolvimento de qualquer sistema de PG para resolver um problema implica na definição de algumas informações importantes: conjunto de terminais e funções, seleção, avaliação, operadores evolutivos e o algoritmo básico.

3.2. Conceitos

3.2.1. Algoritmo Básico

Há basicamente duas formas de se conduzir uma execução de PG: uma abordagem com gerações e uma abordagem denominada *steady-state*. Na PG com gerações, toda uma nova geração é criada a partir da geração anterior a cada ciclo. A nova geração substitui a antiga geração e o ciclo continua. Na PG *steady-state*, não há intervalos fixos de gerações, mas sim um fluxo contínuo de indivíduos encontrando-se, cruzando-se e produzindo descendentes. Os descendentes substituem indivíduos existentes na mesma população.

Os ciclos de execução dos diferentes tipos de PG são similares e independem da representação e dos operadores. O algoritmo básico de PG está apresentado na Figura 11 e segue os seguintes passos:

1. Gerar uma população inicial composta por programas criados aleatoriamente;
2. Avaliar individualmente os programas e determinar a aptidão para cada programa \;
3. Ordenação dos programas de acordo com a aptidão;
4. Selecionar alguns programas;
5. Aplicar os operadores evolutivos;
6. Uso dos critérios de substituição da população;
7. Repetir o processo, iniciado no passo 2, até que um critério de parada seja satisfeito;
8. Apresentar o melhor programa como solução da evolução.

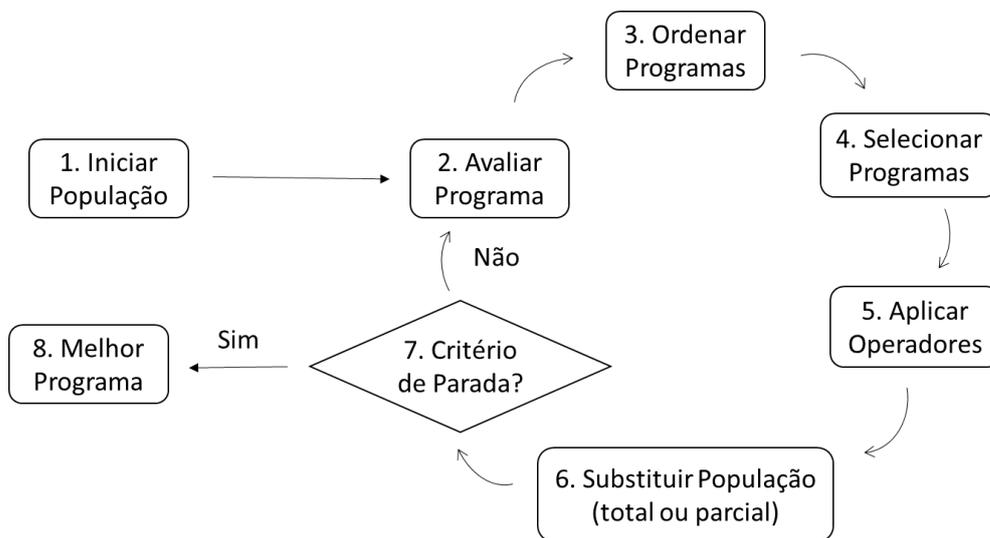


Figura 11 – Fluxograma do algoritmo básico da PG

3.2.2. Funções e Terminais

As funções e terminais são as primitivas com as quais um programa em PG é construído. Os terminais fornecem um valor ao sistema enquanto que as funções processam um valor que esteja no sistema.

As entradas do sistema e as constantes fornecidas compõem o conjunto de símbolos terminais, cuja terminologia surgiu com a evolução de programas em árvore, representação essa usada inicialmente na PG. Na PG Linear, por exemplo,

não há equivalente para a distinção entre funções e terminais. Algumas representações serão apresentadas na seção 3.3.

O conjunto de funções é composto pelas funções disponíveis para o sistema de PG. A variedade de funções disponíveis é muito grande, podendo ser constituídas por funções aritméticas, trigonométricas, booleanas, sentenças condicionais, de loop, etc.

A definição das funções e terminais acaba especificando o espaço de busca dos possíveis programas. Portanto, o espaço deve ser suficientemente amplo para conter a solução desejada. No entanto, quanto maior for este espaço, menor é a chance de encontrar a solução. Assim, é preciso ter um compromisso entre potencial de representação e complexidade do processo de busca. Essa característica é chamada propriedade de suficiência [38].

3.2.3. Avaliação e Seleção

A combinação dos elementos dos conjuntos funções e terminais definem todos os programas possíveis que podem ser construídos. Porém, ainda é necessário orientar a evolução para encontrar programas que representam uma boa solução, o que é feito através da seleção de indivíduos e definição da função objetivo.

Essa seleção de indivíduos da população será submetida aos operadores genéticos. Ao fazer essa escolha, a PG implementa uma das mais importantes partes do seu modelo de aprendizado evolucionário: a seleção baseada em aptidão, pois ela é que guiará a busca por melhores indivíduos [41].

A métrica de avaliação da PG é chamada de função de avaliação da aptidão e representa a expressão que permite ao algoritmo reconhecer sua proximidade à solução ótima, sinalizando o quão bem um programa aprendeu a prever as saídas a partir das entradas, ou seja, as características do domínio de aprendizagem. Seu objetivo é fornecer um retorno a um algoritmo de aprendizado sobre quais indivíduos tem uma maior probabilidade de persistirem na população tanto na sua forma direta como através de seus descendentes e quais indivíduos têm a maior probabilidade de serem removidos da população.

O mecanismo de seleção da PG define a influência que a função de avaliação terá na seleção dos indivíduos para os operadores genéticos [39]. A literatura identifica cinco principais mecanismos de seleção: proporcional, por torneios, com truncamento, por normalização linear e por normalização exponencial [42].

3.2.4. Operadores Genéticos

São dois os principais operadores genéticos: cruzamento e mutação. Existem diferentes formas de implementá-los porém o conceito é o mesmo. No cruzamento, o operador é responsável por trocar e combinar características dos pais durante o processo de reprodução, permitindo que as próximas gerações herdem essas características. A ideia é que os novos indivíduos descendentes poderão ser melhores que seus pais se eles herdarem as melhores características de cada pai. Na mutação, o operador terá a função de realizar modificações nas soluções de forma a evitar a estagnação delas em uma única região do espaço de busca. Com isso é possível explorar o espaço de maneira mais completa e vasta, evitando que o algoritmo fique preso a ótimos locais por exemplo.

3.2.5. População

Em algoritmos evolutivos em geral, a população de soluções individuais pode ser dividida em múltiplas subpopulações. A migração de indivíduos entre as subpopulações promove a evolução da população como um todo. Na biologia, este modelo foi inicialmente descrito em [43] como “modelo de ilha”, argumentando que em populações semi-isoladas, denominadas *demes*, a evolução progride mais rapidamente que em uma única população. Esta aceleração inerente à evolução por *demes* foi confirmada para algoritmos evolutivos [44] e, em particular, para PG [45], [46]. Uma razão para esta aceleração pode residir no fato de a diversidade genética ser melhor preservada em múltiplos *demes* com uma migração restrita de indivíduos. Por sua vez, a diversidade influencia na probabilidade da busca evolutiva encontrar um mínimo local, uma vez que um

mínimo local em um *deme* pode ser transposto por outros *demes* que contenham uma direção de busca melhor [47].

3.3. Estruturas de Representação

Diversas representações para a estrutura de dados podem ser utilizadas em PG. A estrutura mais adequada para a solução de um problema depende principalmente dos tipos de operações que serão realizadas e da linguagem dos indivíduos a serem evoluídos. Neste trabalho, as duas principais estruturas são apresentadas.

3.3.1. Programação Genética em Árvore

A representação em árvores é a estrutura mais difundida. Essa estrutura de dados caracteriza uma relação de hierarquia ou composição entre seus elementos, os nós, podendo ser facilmente avaliada de forma recursiva. Cada nó da árvore tem uma função de operador e cada nó terminal um operando. A Figura 12 ilustra um possível programa resultante na estrutura de árvore.

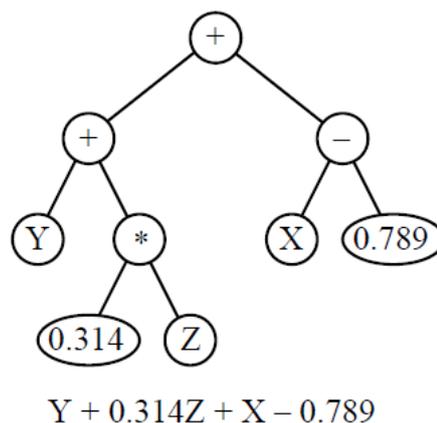


Figura 12 – Representação de um programa na estrutura de árvore [48]

A linguagem LISP foi originalmente utilizada para implementar os algoritmos da programação genética, pois utiliza o princípio da prefixação que facilita a implementação de árvores.

Os operadores de cruzamento e mutação são aplicados sobre os nós, porém a propriedade de fechamento deve ser garantida para não serem geradas inconsistências na estrutura.

3.3.2. Programação Genética Linear

Na Programação Genética Linear a representação dos programas é uma sequência de instruções, tal como mostrada na Figura 13. Na ausência de laços e desvios, a posição das instruções determina a ordem das suas execuções, diferentemente da PG com árvores onde o nó raiz é executado apenas quando suas sub-árvores tiverem sido avaliadas. Ou seja, sua principal característica quando comparada à PG baseada em árvores é que são evoluídos programas em uma linguagem imperativa ao invés de expressões de uma linguagem de programação funcional [37].

As vantagens predominantes da PG Linear são:

- A maioria das arquiteturas de computador representa seus programas de forma linear com instruções adjacentes sendo executadas em instantes de tempo consecutivos.
- Computadores não executam programas em forma de árvore naturalmente, sendo necessário compiladores e interpretadores [42]. Já a PG Linear evolui padrões de *bits* realmente obedecidos pelo computador, sendo executada mais rapidamente.

Instrução 1	Instrução 2	...	Instrução N
-------------	-------------	-----	-------------

Figura 13 – Estrutura de cromossomos da PG Linear

O número de instruções pode ser fixo, significando que todos os programas da população têm o mesmo comprimento, ou variável, o que significa que diferentes indivíduos podem ter diferentes tamanhos. Independente do número de instruções, todas tipicamente leem suas entradas de um ou mais registradores e/ou endereços de memória e armazenam os resultados de seus cálculos em um registrador. Os operadores evolutivos são aplicados nas instruções, garantindo sempre a integridade das mesmas, ou seja, que uma instrução não modifique

somente seu operador podendo resultar em um operador que não precise de argumentos contenha argumentos.

A PG Linear pode evoluir diferentes tipos de programas: a primeira é em código de máquina, onde cada instrução é diretamente executável pela CPU e a segunda é a interpretada, onde cada instrução é executável por uma máquina virtual de alto nível.

3.4. Programação Genética Linear com Inspiração Quântica

A Programação Genética Linear Com Inspiração Quântica (PGLIQ) usada neste trabalho foi desenvolvida em [6]. Esta técnica foi escolhida pois evolui programas em código de máquina. Evoluir programas dessa forma é vantajoso pelo fato das instruções serem executadas diretamente pela CPU, aumentando consideravelmente a velocidade de execução. Outra vantagem da PGLIQ é que utiliza o conceito da computação quântica da superposição de estados, detalhada na seção 3.4.1.

3.4.1. Computação Quântica

A ideia de computação quântica surgiu com as observações de Feynman de que alguns efeitos da mecânica quântica não poderiam ser simulados em computadores clássicos e que estes poderiam ser mais eficientes se usassem tais efeitos. Essa suposição foi confirmada quando os primeiros algoritmos quânticos demonstraram uma superioridade no desempenho da resolução de certos problemas [6].

Em um computador clássico, o *bit* é a menor unidade de informação. Já em um computador quântico, a unidade básica de informação é o *qubit*, que pode assumir os estados $|0\rangle$, $|1\rangle$ ou uma superposição dos dois estados, onde $|0\rangle$ representa o bit nulo e $|1\rangle$ representa o bit unitário. Esta superposição de dois estados é uma combinação linear dos estados $|0\rangle$, $|1\rangle$ e pode ser representada pela Equação (1).

$$|\psi\rangle = \alpha |0\rangle + \beta |1\rangle \quad (1)$$

sendo $|\psi\rangle$ o estado do *qubit* e $|\alpha|^2$ e $|\beta|^2$ são as probabilidades de que os estados 0 ou 1 acarretam da observação do *qubit*, sendo que $|\alpha|^2 + |\beta|^2 = 1$.

A vantagem do uso de superposição de estados é que oferece aos computadores quânticos um alto grau de paralelismo, uma característica essencial para técnicas de Computação Evolutiva [49]. A PGLIQ se baseia nesse princípio.

3.4.2. Plataforma

PGLIQ evolui programas de código de máquina para a plataforma x86 [50] usando algumas das instruções da sua unidade de ponto flutuante (FPU – *Floating Point Unit*), as quais operam com dados da memória principal (m) e/ou dos 8 registradores da UPF ($ST(i)$, onde $i = 0,1,\dots,7$). Um programa evoluído pela PGLIQ representa uma solução de um problema que lê os dados de entrada da memória principal, que são compostos pelas variáveis de entrada do problema e, opcionalmente, constantes fornecidas pelo usuário.

3.4.3. Representação

A PGLIQ trabalha com dois tipos de indivíduos: clássico e quântico. O indivíduo quântico representa a superposição de todos os programas possíveis para o espaço de busca predefinido. Quando observado, o indivíduo quântico (IQ) gera o indivíduo clássico (IC), a partir desse o programa em código de máquina é finalmente gerado.

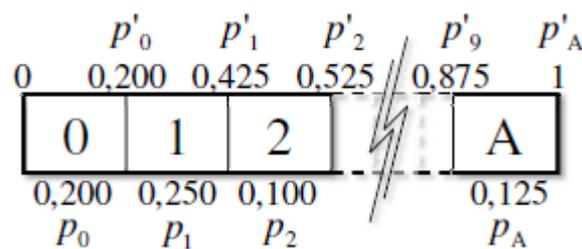
A Programação Genética Linear utiliza instruções como adição, subtração, multiplicação e outras funções ilustradas na Tabela 1, que são representadas internamente por um *token* de função (TF). Também é utilizado um *token* de terminal, que indica qual será o argumento da instrução de FPU. No caso de uma função não ter um argumento, o seu *token* de terminal correspondente tem seu valor ignorado pelo modelo.

Instrução	Descrição	Argumento
NOP	Nenhuma operação	-
FADD m	$ST(0) \leftarrow ST(0) + m$	m
FADD ST(0), ST(i)	$ST(0) \leftarrow ST(0) + ST(i)$	i
FADD ST(i), ST(0)	$ST(i) \leftarrow ST(i) + ST(0)$	i
FSUB m	$ST(0) \leftarrow ST(0) - m$	m
FSUB ST(0), ST(i)	$ST(0) \leftarrow ST(0) - ST(i)$	i
FSUB ST(i), ST(0)	$ST(i) \leftarrow ST(i) - ST(0)$	i
FMUL m	$ST(0) \leftarrow ST(0) \times m$	m
FMUL ST(0), ST(i)	$ST(0) \leftarrow ST(0) \times ST(i)$	i
FMUL ST(i), ST(0)	$ST(i) \leftarrow ST(i) \times ST(0)$	i
FDIV m	$ST(0) \leftarrow ST(0) \div m$	m
FDIV ST(0), ST(i)	$ST(0) \leftarrow ST(0) \div ST(i)$	i
FDIV ST(i), ST(0)	$ST(i) \leftarrow ST(i) \div ST(0)$	i
FXCH ST(i)	$ST(0) \rightleftharpoons ST(i)$ (troca conteúdos)	i
FABS	$ST(0) \leftarrow ST(0) $	-
FSQRT	$ST(0) \leftarrow \sqrt{ST(0)}$	-
FSIN	$ST(0) \leftarrow \text{sen } ST(0)$	-
FCOS	$ST(0) \leftarrow \text{cos } ST(0)$	-
FCOMI ST(0), ST(i)	$CF \leftarrow (ST(0) < ST(i))$	i
JB 6	Pula próxima instrução se $CF = 1$	-
JNB 6	Pula próxima instrução se $CF = 0$	-

Tabela 1 – Descrição das Instruções [6]

A PGLIQ é inspirada em sistemas quânticos multi-níveis [51]. Logo, a unidade básica de informação adotada pelo modelo é o *qudit*. Esta informação pode ser descrita por um vetor de estado em um sistema mecânico quântico de d níveis, onde d é o número de estados nos quais o *qudit* pode ser medido.

O estado de um *qudit* é dado de forma similar a Equação (1), porém com a superposição linear de d estados, como mostrado na Figura 14. Esse estado do *qudit* é implementado e armazenado em uma estrutura de dados similar a uma roleta, como representado na Figura 15. Os valores p_i indicam a probabilidade de observar o i -ésimo estado, enquanto que os valores p'_i indicam a probabilidade acumulada com os estados anteriores.

Figura 14 – Exemplo de implementação de um *qudit* [6]

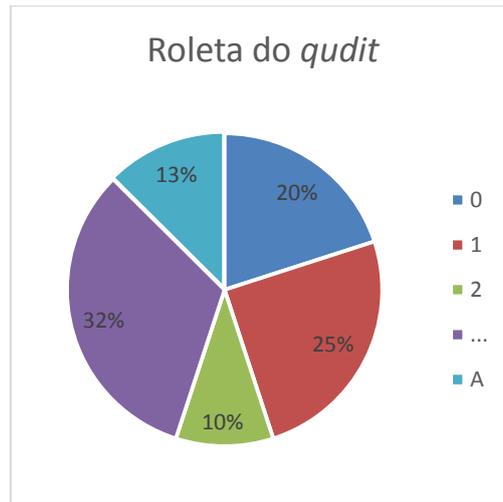


Figura 15 - Qudit representado como roleta

O processo de observação do *qudit* começa gerando aleatoriamente um valor r com distribuição inicialmente uniforme entre 0 e 1. O valor observado para o *token* será o estado cujo valor da probabilidade acumulada for o primeiro valor maior que r . Ou seja, se o valor gerado para r for 0.420, o estado observado segundo a Figura 14 será o estado 1, que de acordo com a Tabela 1 corresponde a função FADD m , caso seja um *qudit* de função.

O cromossomo dos indivíduos é representado por uma lista de estruturas chamadas genes. No caso dos genes quânticos, cada gene é representado por um *qudit* de função, que representa a superposição de todas as funções predefinidas pelo conjunto de funções, e dois *qudits* de terminal, uma vez que as funções podem utilizar dois tipos diferentes de terminais. Um dos *qudits* representa os registradores da FPU e o outro, as posições de memória que também pertencem a um conjunto de terminais predefinido.

A Figura 16 ilustra o processo de observação para a geração do indivíduo clássico. Como cada gene quântico é observado para gerar um gene do indivíduo clássico (uma instrução completa, ou seja, um *token* de função e outro de terminal), ambos os indivíduos possuem o mesmo comprimento. Para um indivíduo não crescer demasiadamente, um comprimento máximo L é definido. Esse comprimento máximo é exatamente o número de instruções máximo permitido.

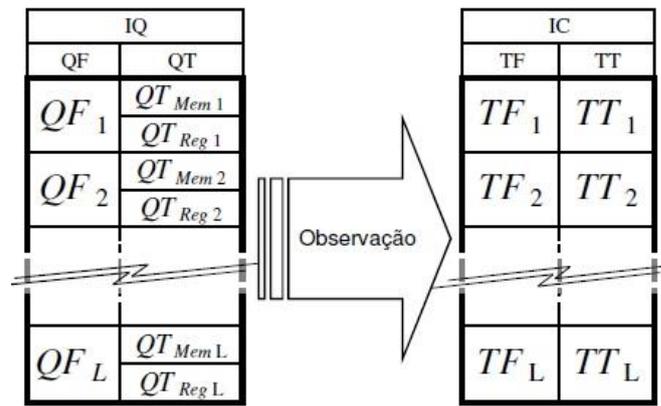


Figura 16 – Observação de um IQ gerando um IC [6]

Apesar dos indivíduos possuírem comprimento fixo L na Figura 16, o programa efetivo que ele representa possui comprimento variável. Esta variação é obtida pela inclusão da instrução NOP no conjunto de instruções, que é ignorada no processo de geração de código.

3.4.4. Programas Evoluídos

Cada programa evoluído pela PGLIQ é um programa em código de máquina assembly composto por três segmentos: cabeçalho (*header*), corpo e rodapé (*footer*). O cabeçalho inicia a FPU e carrega o valor zero em cada um dos oito registradores. O rodapé transfere o conteúdo do registrador de posição zero para a saída predefinida do programa, além de reiniciar a FPU. Ele também executa a instrução de retorno para encerrar a execução do programa e retornar ao fluxo principal do algoritmo evolutivo. O corpo é a única parte afetada pela evolução do código.

3.4.5. Avaliação

O processo de avaliação se inicia com a geração de um código de máquina a partir do IC a ser avaliado. Para isso, o cromossomo do IC é percorrido sequencialmente, gene por gene, *token* por *token*, gerando serialmente o código de máquina do programa relativo àquela IC. Assim, sua avaliação será a execução desse programa para todos os casos de aptidão do problema.

3.4.6. Operador Quântico

O operador quântico do PGLIQ, denominado operador P, atua diretamente nas probabilidades p_i de um *qudit*, satisfazendo a condição de normalização: $\sum_{i=0}^{d-1} |\alpha_i|^2 = 1$, onde d é o número de estados do *qudit* e $|\alpha_i|^2 = p_i$. Esse operador incrementa uma dada probabilidade do *qudit* através da Equação (2).

$$p_i \leftarrow p_i + s(1 - p_i) \quad (2)$$

onde s é um parâmetro denominado tamanho do passo, que pode assumir qualquer valor real entre 0 e 1. Para garantir a condição de normalização, o operador também ajusta os valores das outras probabilidades do *qudit*, dividindo as probabilidades pela nova soma das probabilidades de todos os estados.

Analisando a Equação (2), pode-se perceber que uma probabilidade nunca atinge o valor unitário. Esta é uma importante característica do operador, pois evita que uma probabilidade leve seu *qudit* ao colapso (um de seus estados com probabilidade igual a um), o que poderia provocar uma convergência prematura do processo de busca evolutiva, prejudicando o desempenho do modelo.

3.4.7. Estrutura e Funcionamento do Modelo

Com relação à estrutura, a PGLIQ possui uma população híbrida composta por uma população quântica e uma população clássica, ambas com o mesmo número de indivíduos. Também possui indivíduos clássicos auxiliares, que resultam da observação dos indivíduos quânticos.

O diagrama da Figura 17 tem como objetivo ilustrar a estrutura e o funcionamento básico do modelo. Na etapa 1, cada IQ é observado uma vez. Na etapa 2, os indivíduos da população clássica e os indivíduos observados são ordenados do melhor para o pior quanto às suas avaliações, permanecendo na população clássica os melhores indivíduos, que no caso exemplificado são os quatro melhores.

Se os indivíduos possuírem a mesma aptidão na comparação, o melhor indivíduo é aquele que possuir o menor comprimento efetivo, ou seja, será o

menor indivíduo ignorando os genes que possuam a instrução NOP. O indivíduo cujo comprimento for maior é eliminado da população clássica, promovendo a diversidade da população.

Na etapa 3, o operador P é aplicado a cada gene de cada IQ, tendo como referência seus respectivos IC. Nesta etapa é que ocorre efetivamente a evolução, pois, a cada nova geração, a aplicação do operador aumenta a probabilidade de que a observação dos IQs gerem ICs mais parecidos com os melhores encontrados até então.

Na etapa 4, caso algum dos indivíduos da população clássica, avaliados na geração atual, seja melhor que o melhor IC avaliado até então, uma cópia do mesmo é armazenada em C_m .

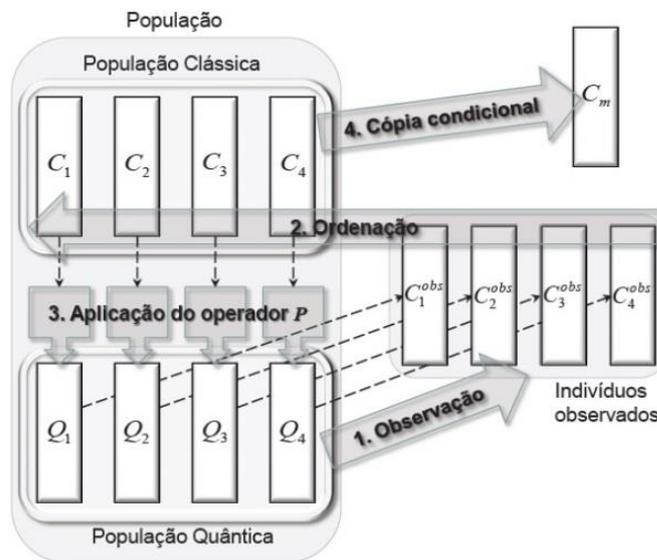


Figura 17 – Diagrama básico do modelo PGLIQ [6]

A inicialização da população quântica é feita atribuindo probabilidades para os *qudits* de função e terminal. Para o *qudit* de terminal, a mesma probabilidade é atribuída para todos os estados. Já para o *qudit* de função, um valor predeterminado é atribuído para a probabilidade da função NOP de forma a fornecer um controle de comprimento inicial sobre os primeiros programas evoluídos. O restante dos estados são iniciados com o mesmo valor, lembrando que a condição de normalização deve ser sempre satisfeita.

A evolução continua até que o número máximo de gerações seja alcançado, fornecendo como saída o melhor indivíduo encontrado C_m .

4. Modelagem do Aproximador

4.1. Introdução

A seleção de alternativas de estratégias para o desenvolvimento de um sistema de produção *offshore* consiste em um grande número de decisões através da análise técnico-econômica de uma série de possíveis cenários. Entre as variáveis de decisão que compõem essas alternativas têm-se a localização e quantidade dos poços a serem perfurados, os seus cronogramas de abertura, a localização e quantidade das Unidades Estacionárias de Produção, o dimensionamento dessas unidades, entre outras decisões. Todas essas variáveis podem ser otimizadas levando ao aumento do lucro obtido pela empresa de petróleo. A maioria dessas otimizações faz uso do simulador de reservatório.

O modelo de solução proposto nesse trabalho envolve a construção de aproximadores para substituir parcialmente o simulador de reservatório com o objetivo de reduzir o esforço computacional durante a otimização da localização de poços de petróleo. A técnica utilizada para a criação dos aproximadores de funções não lineares foi a Programação Genética Linear com Inspiração Quântica.

A Programação Genética Linear é considerada uma boa alternativa para aproximar os simuladores de reservatório de petróleo [4], pois consegue mapear a superfície de resposta do simulador, a partir de dados numéricos de entrada e saída. Esses dados de treinamento necessários para evoluir um programa de computador foram extraídos utilizando o próprio modelo que deseja ser substituído, o simulador de reservatório.

A partir desse ponto, um processo de várias etapas, não trivial, interativo e iterativo é executado até encontrar um modelo satisfatório. A Figura 18 ilustra as etapas desse processo. No pré-processamento, a compreensão do domínio do problema é realizada para criação da base de dados. Também nessa etapa, os dados gerados são analisados para eliminar ruídos da base e verificar a validade da mesma. Na mineração de dados, a técnica escolhida é adaptada para o objetivo do

trabalho, que é a criação de aproximadores, e resultados são gerados. No pós-processamento, os resultados são analisados. O processo continua, não necessariamente nessa ordem, mas sempre tentando fazer ajustes para a melhoria do modelo. Esse processo só irá terminar quando o modelo não obtiver uma melhora significativa do resultado, pois esse *loop* não tem fim.



Figura 18 – Etapas do processo de construção de aproximadores

4.2. Aproximador de Reservatório

O aproximador de função desenvolvido nesta dissertação visa a substituição do simulador de reservatório de petróleo. Sendo assim, o simulador tem que ser visto como uma função vetorial representada pela Equação (3).

$$\vec{Y}_t = \Phi(\vec{X}_t) \quad (3)$$

onde \vec{X}_t é uma configuração de poços no campo petrolífero em um dado instante de tempo, \vec{Y}_t é a curva de produção em um dado instante de tempo para a configuração de poços \vec{X}_t e $\vec{Y}_t = \Phi(\vec{X}_t)$ é a função de produção de óleo, gás ou água do reservatório.

4.2.1. Seleção de Variáveis do Aproximador

O aproximador é uma função que irá fornecer uma saída, de acordo com as entradas apresentadas. Assim, as variáveis de entrada precisam ser selecionadas cuidadosamente pois terão influência significativa nos resultados. Caso escolhas erradas sejam feitas, não há melhorias no processo de criação dos aproximadores que possam ser realizadas para que os resultados sejam satisfatórios.

O aproximador irá substituir parcialmente o simulador de reservatórios para ser usado, principalmente, na otimização da localização dos poços de petróleo.

Logo, entradas coerentes seriam justamente a posição dos poços no reservatório. Assim como o simulador, o *proxy* terá como entrada a localização I , J e K inicial e final de todos os poços.

Nesta dissertação, os aproximadores só irão trabalhar com poços verticais, portanto, as entradas serão as coordenadas I , J e K inicial e a coordenada K final de cada poço, reduzindo o número de entradas e conseqüentemente a redundância de informações para o modelo. Dado que a coordenada K é a que representa o eixo vertical, as coordenadas I e J finais serão sempre iguais as coordenadas I e J iniciais.

Além das entradas de localização dos poços, a Programação Genética Linear terá também como entrada valores de produção acumulada em três tempos anteriores ao que se quer prever. Assim, é utilizada a técnica de janela deslizante de tamanho empírico igual a três. Esse valor foi escolhido pois com três pontos já se tem uma tendência da curva a ser traçada, facilitando a previsão. A Figura 19 demonstra as variáveis de entrada externas da Programação Genética.

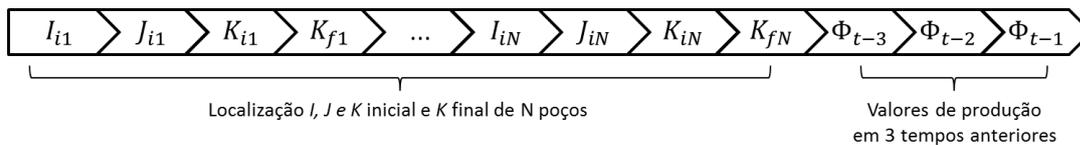


Figura 19 – Entradas externas do aproximador

A saída do aproximador será a curva de produção acumulada de óleo, gás ou água durante um período determinado. A produção anual acumulada é uma saída cuja curva é fácil de ser visualizada, além de não ser uma medida instantânea. Porém, o mais importante é que com todos esses dados é possível calcular o Valor Presente Líquido, utilizado como função de avaliação no sistema de otimização da localização dos poços.

4.2.2. Cenários de Poços

As amostras para a criação da base de treinamento são geradas utilizando o próprio simulador de reservatório. Contudo, é necessário gerar cenários de poços para serem simulados e conseqüentemente criar as amostras. Então, cenário de

poços define a posição de um determinado número de poços. Como o custo computacional do uso desse simulador para gerar esses cenários é alto, a técnica do Hipercubo Latino foi utilizada para tentar minimizar a quantidade de cenários.

4.2.2.1. Hipercubo Latino

O método do Hipercubo Latino, utilizado para geração de amostras de distribuições multivariadas, foi desenvolvido em [52]. A técnica do Hipercubo Latino é uma técnica de amostragem estratificada na qual os estratos selecionados da distribuição são representados na amostra através de um representante. Mais especificamente, é um caso particular de amostragem estratificada, pois independentemente da distribuição que a variável aleatória possua, a divisão de seu intervalo será sempre equiprovável.

Esta metodologia consiste em selecionar n diferentes valores para cada variável k (X_1, X_2, \dots, X_k) através do seguinte procedimento:

- 1 – Dividir o intervalo de cada variável k em N intervalos equiprováveis e disjuntos;
- 2 – Selecionar um valor, ou um representante, para cada intervalo de acordo com sua densidade de probabilidade;
- 3 – Depois de obtidos os N representantes de todas as variáveis, parear, ou seja, formar pares de maneira aleatória, dos N representantes de X_1 com os N representantes de X_2 , em uma relação de um para um;
- 4 – Os N pares formados pela combinação de X_1 com X_2 são então combinados com os N representantes de X_3 , formando assim trios;
- 5 – Os N trios são então combinados com os N representantes de X_4 e assim sucessivamente, até que todas as variáveis façam parte da combinação.

4.2.2.2. Geração dos Cenários

Na geração dos cenários de poços, foi utilizada a técnica do Hipercubo Latino pois foi a que mostrou melhores resultados em [35], pois representa melhor a distribuição do espaço amostral. Essa técnica seleciona os valores para as

localizações dos poços, ou seja, as $M - 3$ entradas da Programação Genética, onde M é o número total de entradas externas do modelo.

Nesta dissertação, todas as variáveis, que são discretas, foram tratadas como contínuas podendo uma coordenada em uma direção ser gerada novamente. Também, todas as variáveis possuem um limite inferior e superior. Esse limite é justamente o tamanho do grid do reservatório nas direções I , J e K .

Uma observação importante é que a técnica de Hiper-cubo Latino não impõe que a coordenada K inicial deve ser menor que a coordenada K final. Como solução para esse obstáculo, foi proposto dividir em mais intervalos, gerando mais cenários e eliminando os casos onde esse problema era identificado.

4.2.3. Simulação dos Cenários de Poços

Uma vez gerados os cenários de poços, um pré-processamento é realizado durante a simulação com o IMEX. Nesse pré-processamento, alguns cenários são eliminados porque não respeitam certas restrições e algumas condições foram fixadas. Essas restrições e condições são:

1. Distância mínima entre os poços de 400 metros;
2. Comprimento máximo dos poços de 800 metros;
3. Restrições de poços produtores:
 - a. Operate BHP min 10000 Cont;
4. Restrições de poços injetores:
 - a. Operate STW max 1000 Cont;
5. Lâmina d'água de 1000 metros;
6. O número total de poços é sempre fixo;
7. Os poços são somente verticais;
8. Não são consideradas alternativas que contenham somente poços injetores;
9. Os tipos de poços (produtor ou injetor) podem variar livremente.

As restrições de poços são restrições operacionais. Para os poços produtores é usada a restrição de pressão no fundo do poço (BHP) e para os poços injetores, a vazão da água na superfície (STW).

A última condição somente é possível porque serão criados diferentes programas com a Programação Genética Linear com Inspiração Quântica. Cada programa irá ser uma combinação de tipos de poços. No total, para esse trabalho, serão seis aproximadores pois o número de poços é fixo em seis podendo variar entre dois tipos, produtor e injetor. Essa quantidade de poços foi escolhida pois foi o resultado para as duas otimizações realizadas podendo variar livremente essa variável. A Figura 20 e a Figura 21 mostram a configuração ótima de poços encontrada e as curvas de produção acumuladas dessa configuração. A escala da curva de água é a mesma da curva de óleo.

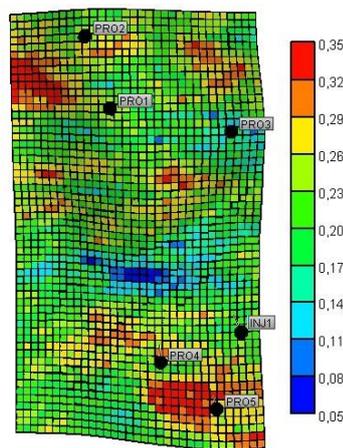


Figura 20 – Configuração de poços de uma otimização livre da quantidade

Essa abordagem foi escolhida para não aumentar o número de entradas do modelo, não sendo necessária a codificação do tipo de cada poço. Essa codificação iria aumentar o espaço de busca o que poderia levar mais tempo e teria mais dificuldade para encontrar uma boa solução.

O número de poços produtores em uma alternativa irá funcionar como um seletor, indicando qual programa deve ser executado para fornecer a curva de produção acumulada. A Figura 22 ilustra a distribuição da alternativa de acordo com o número de poços produtores que ela contém.

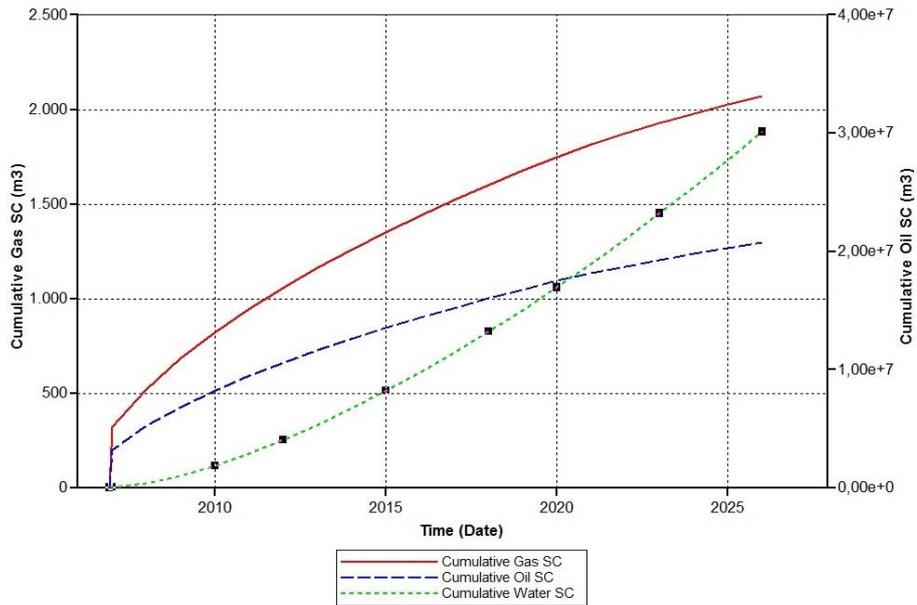


Figura 21 - Curva de óleo, gás e água acumulados da otimização

PUC-Rio - Certificação Digital Nº 1221675/CA

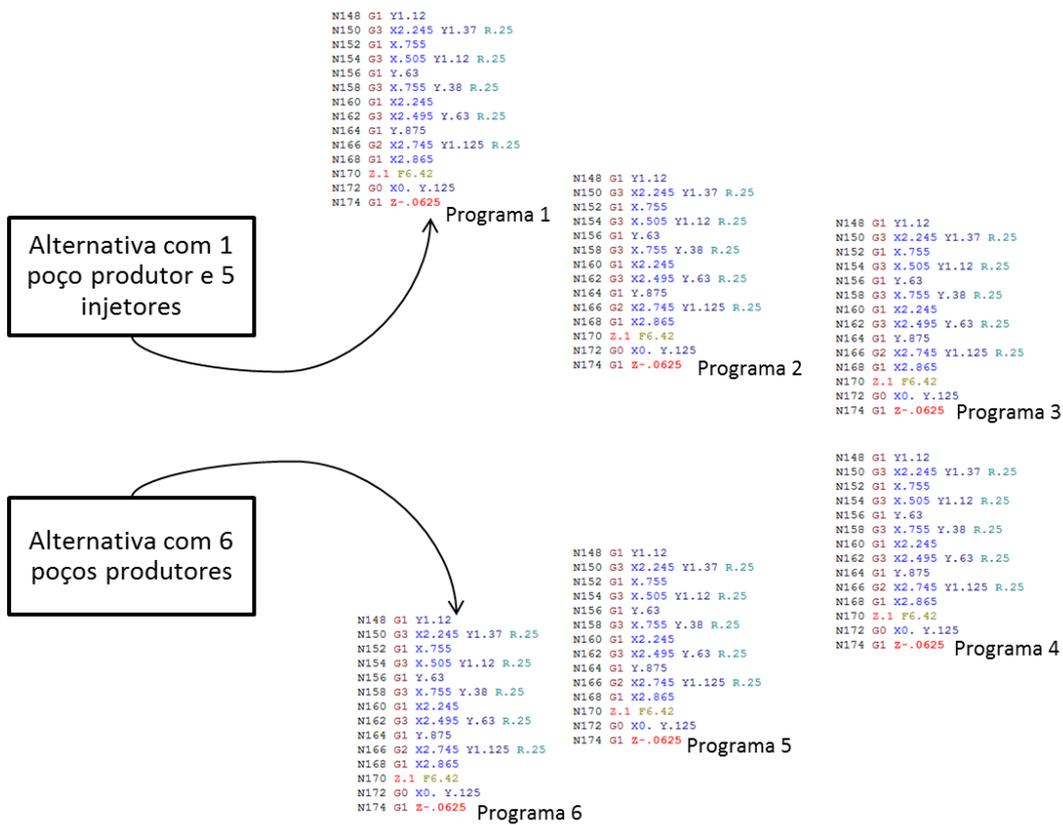


Figura 22 – Seleção do programa de acordo com a alternativa (programas meramente ilustrativos)

Serão geradas três amostragens por Hipercubo Latino com intervalos diferentes para criar as bases de treinamento, validação e teste. Esse procedimento foi realizado para que as bases tenham seus cenários de poços intercalados, podendo realmente testar o poder de generalização do modelo. A Figura 23 ilustra o conceito do entrelaçamento quando aplicada a divisão do Hipercubo Latino para diferentes intervalos para uma variável.



Figura 23 – Ideia do entrelaçamento para uma variável

Essas três amostragens serão simuladas seis vezes cada. Em cada simulação o número de poços produtores e injetores irá mudar. Ou seja, serão gerados seis conjuntos de arquivos de saída com a produção acumulada referente às amostras do Hipercubo Latino para cada base. Em todos os aproximadores gerados nesta dissertação, a curva de produção anual acumulada é para um horizonte de previsão de 20 anos.

4.2.4. Criação das Bases

Com os arquivos de saída do simulador podem ser extraídos a produção acumulada de óleo, água e gás. Como foi mostrado na Seção 4.2.1, uma janela de tamanho três será usada. Porém, no primeiro ano de previsão não se tem a produção dos anos anteriores, pois os poços acabaram de ser abertos. Então, a janela começa zerada. Conforme os anos passam, os valores da janela são preenchidos como ilustra a Figura 24, onde o horizonte de previsão para esse exemplo é de 6 anos.

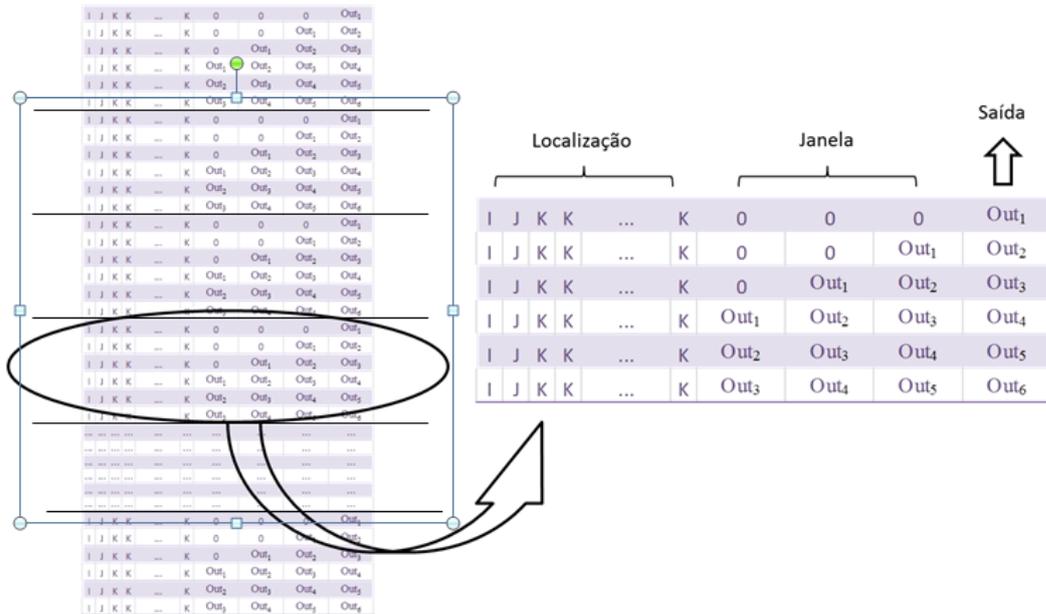


Figura 24 – Janela Deslizante para Previsão de Produção por 6 Anos

A técnica da janela deslizante é utilizada apenas dentro de um cenário de poços. Quando o cenário muda, a janela volta a ser zerada novamente. Logo, um cenário de poços irá gerar para a criação da base desta dissertação 20 amostras (horizonte de previsão).

Porém, um cenário de poços irá gerar 20 amostras de óleo, de água e de gás. Então, na verdade, cada configuração de poços terá três aproximadores, um para cada tipo de produção. Portanto, um total de 18 programas é necessário para prever a produção de óleo, gás e água considerando um número fixo de seis poços.

A criação de aproximadores para óleo, água e gás foram desenvolvidos para criar programas mais específicos, voltados só para uma tarefa. A Figura 25 mostra que uma alternativa irá necessariamente passar por três aproximadores tendo como resultado os valores essenciais para o cálculo do VPL.

Para os aproximadores de óleo, água e gás, as entradas seguem o mesmo padrão mostrado anteriormente: coordenadas I , J e K iniciais e coordenada K final de cada poço, assim como os valores de produção acumulada do respectivo fluido em três tempos anteriores ao que se quer prever.

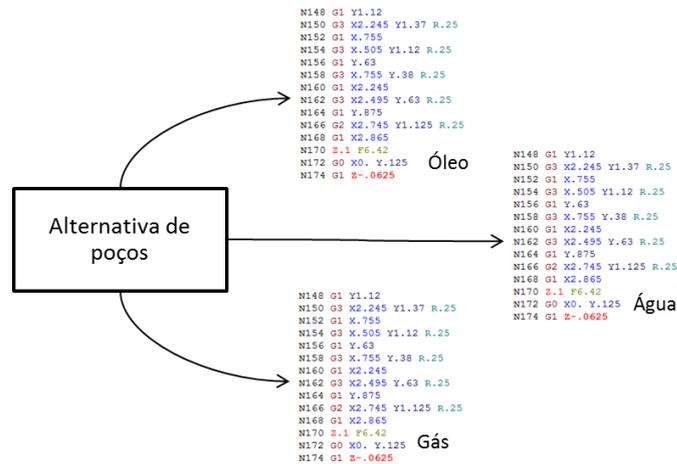


Figura 25 – Previsão da produção de uma alternativa

4.2.5. Pós-Processamento da Base

Após gerar as bases, foi necessário realizar um pós-processamento nas mesmas para que o aproximador se tornasse mais robusto. Essas alterações mantiveram a integridade do conjunto de dados.

Como a técnica da PGLIQ tem dificuldades de fazer uma previsão somente com as coordenadas de localização dos poços, ou seja, no caso onde a janela está zerada, um modelo é proposto juntando o simulador com o aproximador. Nesse modelo híbrido, os três primeiros anos serão resultantes da simulação do reservatório, enquanto que os anos restantes serão aproximados pelo programa evoluído.

A Figura 26 ilustra as amostras que irão ser retiradas de cada cenário de poços. Assim, cada cenário irá fornecer 3 X 17 amostras para as bases de treinamento, validação e teste que serão usadas para a construção das proxies. As amostras são multiplicadas pelo fator 3 devido aos três tipos de fluidos existentes.

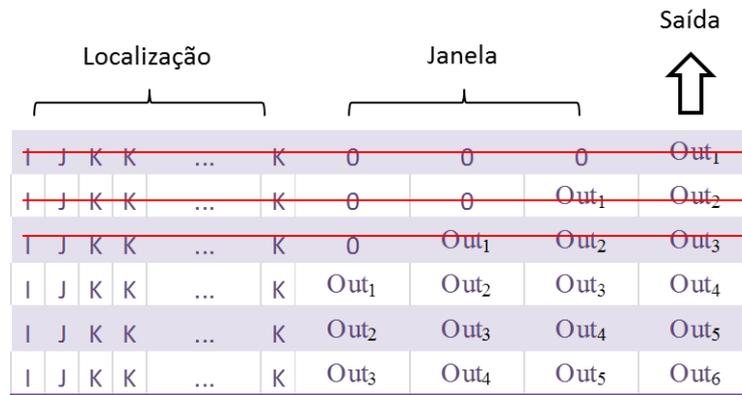


Figura 26 – Retirada dos primeiros anos

Outra alteração na base de dados que melhorou os resultados foi a ordenação dos poços, quanto ao tipo e localização. Em relação à primeira, os poços produtores ficaram nas primeiras colunas enquanto que os injetores foram concatenados após todos os poços produtores.

Já a organização quanto à localização foi realizada com cada grupo de poços (produtores e injetores) ordenando seguindo algumas comparações. A primeira é em relação à coordenada *I*, ordenando os poços de forma crescente por essa coordenada. Quando a localização *I* for igual para dois poços, o critério de desempate adotado foi comparar a coordenada *J*, ficando em primeiro o poço que possuir o menor valor.

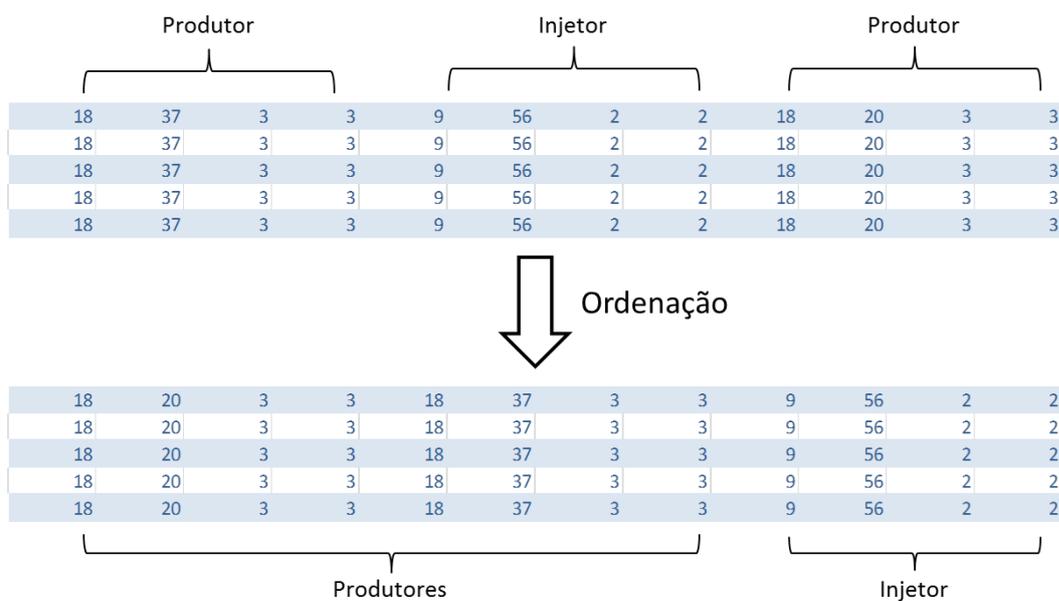


Figura 27 – Exemplo de ordenação para dois poços produtores e um injetor

4.2.6.1. Entradas Internas da Programação Genética

Além das coordenadas de localização dos poços e dos valores de produção acumulada em três tempos anteriores ao que se quer prever, a PGLIQ utiliza de constantes definidas pelo usuário. A Tabela 2 mostra as constantes utilizadas nesse modelo. Valores pequenos foram escolhidos para fazer um ajuste mais fino enquanto valores intermediários para ajustes maiores.

0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1	1.1	1.2	
1.3	1.4	1.5	1.6	1.7	1.8	1.9	2	3	4	5	6	
7	8	9	10	11	12	13	14	15	16	17	18	19

Tabela 2 – Constantes escolhidas para a PGLIQ

4.2.6.2. Instruções

Também é definido pelo usuário quais as funções que serão usadas para evoluir os aproximadores. São funções de adição, subtração, multiplicação, divisão, dentre outras mostradas na

Tabela 3. Três funções que também foram usadas e não estão na tabela são FCHS, F2XM1 e FSCALE.

A primeira apenas muda o sinal da posição zero do registrador interno (ST(0)). A F2XM1 computa o valor exponencial de 2 elevado ao ST(0) e o resultado subtraído de 1, armazenando o valor em ST(0). Por último, a FSCALE fornece rápida multiplicação e divisão por potências de 2. Para realizar essa operação, o valor de ponto flutuante ST(1) é truncado para um inteiro mais próximo de zero. Este novo valor é usado como expoente na potência de base 2, que então é multiplicado por ST(0), armazenando o valor em ST(0). A Equação (4) e (5) apresentam, respectivamente, as duas últimas instruções.

Em relação à instrução da raiz quadrada, o valor absoluto é sempre realizado antes da execução desse operador. Assim, o problema de raiz quadrada de números negativos é evitada.

$$ST(0) \leftarrow 2^{ST(0)} - 1 \quad (4)$$

$$ST(0) \leftarrow ST(0) * 2^{\text{TruncaEmDireçãoAZero}(ST(1))} \quad (5)$$

Instrução	Descrição	Argumento	token
NOP	Nenhuma operação	-	0
FADD m	$ST(0) \leftarrow ST(0) + m$	m	1
FADD $ST(0), ST(i)$	$ST(0) \leftarrow ST(0) + ST(i)$	i	2
FADD $ST(i), ST(0)$	$ST(i) \leftarrow ST(i) + ST(0)$	i	3
FSUB m	$ST(0) \leftarrow ST(0) - m$	m	4
FSUB $ST(0), ST(i)$	$ST(0) \leftarrow ST(0) - ST(i)$	i	5
FSUB $ST(i), ST(0)$	$ST(i) \leftarrow ST(i) - ST(0)$	i	6
FMUL m	$ST(0) \leftarrow ST(0) \times m$	m	7
FMUL $ST(0), ST(i)$	$ST(0) \leftarrow ST(0) \times ST(i)$	i	8
FMUL $ST(i), ST(0)$	$ST(i) \leftarrow ST(i) \times ST(0)$	i	9
FXCH $ST(i)$	$ST(0) \rightleftharpoons ST(i)$ (troca conteúdos)	i	A
FDIV m	$ST(0) \leftarrow ST(0) \div m$	m	B
FDIV $ST(0), ST(i)$	$ST(0) \leftarrow ST(0) \div ST(i)$	i	C
FDIV $ST(i), ST(0)$	$ST(i) \leftarrow ST(i) \div ST(0)$	i	D
FABS	$ST(0) \leftarrow ST(0) $	-	E
FSQRT	$ST(0) \leftarrow \sqrt{ST(0)}$	-	F
FSIN	$ST(0) \leftarrow \text{sen } ST(0)$	-	G
FCOS	$ST(0) \leftarrow \text{cos } ST(0)$	-	H

Tabela 3 – Instruções usadas para evoluir o aproximador

4.2.7. Função de Avaliação

A função de avaliação é a função que irá guiar a técnica evolutiva para melhores soluções. Nesta dissertação será usado o RMSE (*Root Mean Square Error*). A Equação (6) mostra o cálculo desse erro.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n}} \quad (6)$$

onde, \hat{y}_t : valor previsto, dado pelo aproximador;

y_t : valor real, dado pelo simulador;

n : número de amostras.

A vantagem de usar o RMSE é que, antes de ser calculada a média, os erros são elevados ao quadrado, atribuindo um peso relativamente elevado a erros maiores. Isto significa que essa métrica de erro é mais útil quando erros maiores são particularmente indesejáveis.

Para o conjunto de testes, a saída da primeira amostra de um cenário de poços é calculada com os valores da janela iguais aos simulados para os três primeiros anos. Porém, a partir do quarto ano a janela não utiliza valores simulados, uma vez que se quer substituir o simulador de reservatório. Então, um processo Multi-Step de previsão é realizado.

No processo Multi-Step, a saída gerada pelo aproximador será usada como entrada para o próximo ano daquele cenário de poços. Ao realimentar o programa com um valor previsto, um erro está se propagando para o próximo ano e assim sucessivamente até completar o horizonte de previsão. Esse fato torna o problema ainda mais complexo.

A Figura 29 ilustra o processo Multi-Step. Os valores simulados, representadas por pontos pretos, são entradas do aproximador que irá prever a produção um ano a frente. Esse valor previsto é utilizado como entrada para o mesmo aproximador junto com dois valores simulados. Esse processo se repete mesmo quando na janela só são encontrados valores previstos.

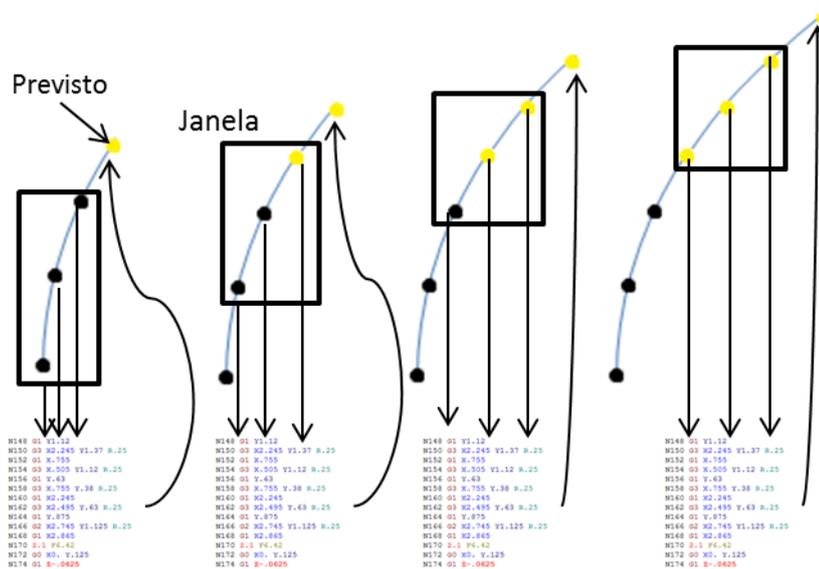


Figura 29 – Previsão Multi-Step

4.2.8. Alterações na Evolução do Aproximador

Algumas heurísticas foram criadas para que a saída tivesse erros menores. Para isso, foram analisados os erros de treinamento, validação e teste. Um padrão encontrado foi para os casos em que mesmo depois dos valores simulados de produção, a janela continuava zerada, ou seja, os poços continuavam não produzindo até o quarto ano.

Para solucionar esse obstáculo, foi considerada que as saídas dos próximos dezessete anos seriam iguais à zero. Essa suposição tem fundamento, uma vez que poços com a produção zerada nos três primeiros anos provavelmente não serão as melhores soluções na otimização da localização de poços.

Para explicar melhor esse fenômeno, a equação do VPL é apresentada na Equação (7).

$$VPL = VP - D \quad (7)$$

onde, VP : valor presente do projeto;

D : custo de desenvolvimento do projeto.

A equação do valor presente será desmembrada pois é ela que tem seu cálculo afetado pelos valores de produção. As Equações (8) – (12) mostram o cálculo do valor presente.

$$VP = (VP_r - VP_{cop}) \times (1 - I) \quad (8)$$

onde, VP_r : valor presente da receita;

VP_{cop} : valor presente do custo operacional;

I : alíquota de impostos.

$$VP_r = \sum_{t_0}^T \frac{R(t)}{1 + tma \left(\frac{d(t)}{365} \right)} \quad (9)$$

onde, $R(t)$: receita no tempo t;

T : tempo total da produção;
 tma : taxa mínima de atratividade;
 $d(t)$: dia no tempo t .

$$R(t) = [(q_o(t) \times p_o(t)) + (q_g(t) \times p_g(t))] \times (d(t) - d(t - 1)) \quad (10)$$

onde, $q_o(t)$: vazão de produção de óleo no tempo t ;
 $p_o(t)$: preço da venda de óleo no tempo t ;
 $q_g(t)$: vazão de produção de gás no tempo t ;
 $p_g(t)$: preço da venda de gás no tempo t .

$$VP_{cop} = \sum_{t=1}^T \frac{Cop(t)}{1+tma^{\left(\frac{d(t)}{365}\right)}} \quad (11)$$

onde, $Cop(t)$: custo operacional no tempo t .

$$Cop = \left[m \times n_p \times \left(\frac{d(t) - d(t-1)}{365} \right) \right] + v \times (d(t) - d(t - 1)) + R_y \times R(t) + f + [(cp_o \times q_o(t)) + (cp_g \times q_g(t)) + (cp_a \times q_a(t))] \times (d(t) - d(t - 1)) \quad (12)$$

onde, m : custo de manutenção;
 v : custos variáveis de produção;
 R_y : royalties;
 f : custos fixos;
 cp_o : custos de produção de óleo;
 $q_o(t)$: vazão de produção de óleo no tempo t ;
 cp_g : custos de produção de gás;
 $q_g(t)$: vazão de produção de gás no tempo t ;
 cp_a : custos de produção de água;
 $q_a(t)$: vazão de produção de água no tempo t .

Logo, quando a janela com valores simulados estiver com seus três valores zerados de óleo ou gás, zerando os próximos anos fará com que o VPL seja baixo, pois a receita depende desses valores, e conseqüentemente eliminando esse cenário como uma possível solução ótima.

Porém, com a produção de água acontece o contrário. Ao zerar sua produção, o custo operacional é reduzido e o VPL tende a aumentar, fazendo com que esse conjunto de poços se torne uma possível solução ótima.

5. Estudo de Casos

5.1. Descrição do reservatório

O reservatório utilizado nesse trabalho é um reservatório sintético que possui uma geometria *corner point*, com 33 X 57 X 3 blocos nas direções *I*, *J* e *K* respectivamente. Esse reservatório possui 5.643 células ativas com canais de alta permeabilidade. A simulação desse reservatório dura cerca de 20 segundos. A Figura 30 mostra esse reservatório, com a escala representando a profundidade em metros.

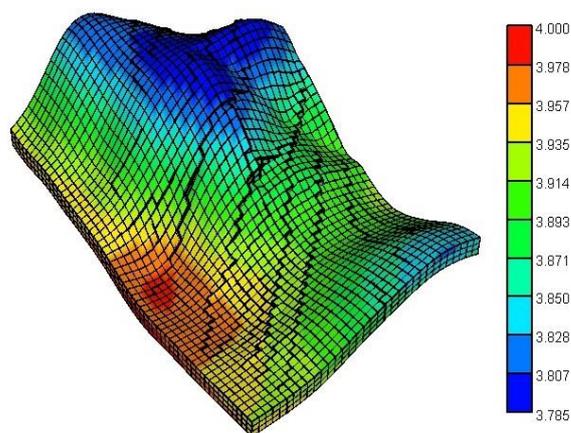


Figura 30 – Reservatório Sintético com profundidade em metros.

Também foram escolhidos para esse reservatório três diferentes cenários geológicos, com porosidades e permeabilidades diferentes. Esses cenários foram escolhidos de forma aleatória das 50 imagens geológicas disponíveis. A Figura 31 mostra a primeira camada da porosidade desses três cenários. Já a Figura 32 mostra a primeira camada da permeabilidade dos mesmos cenários. Para cada cenário geológico, aproximadores serão construídos e avaliados na tentativa de realizar uma otimização da localização de poços sob incerteza geológica.

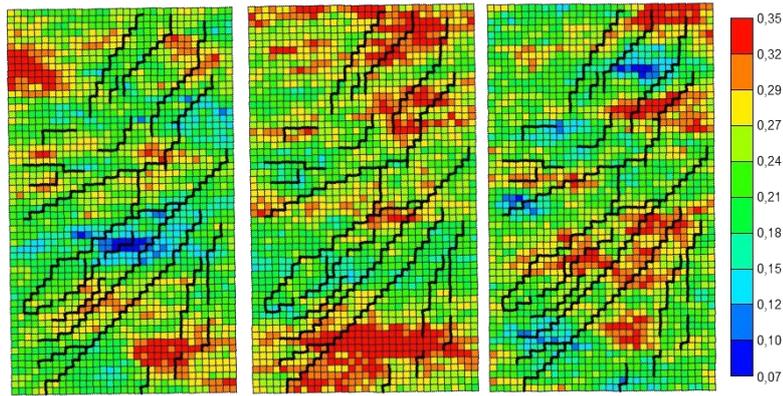


Figura 31 - Porosidade da primeira camada dos três cenários geológicos escolhidos

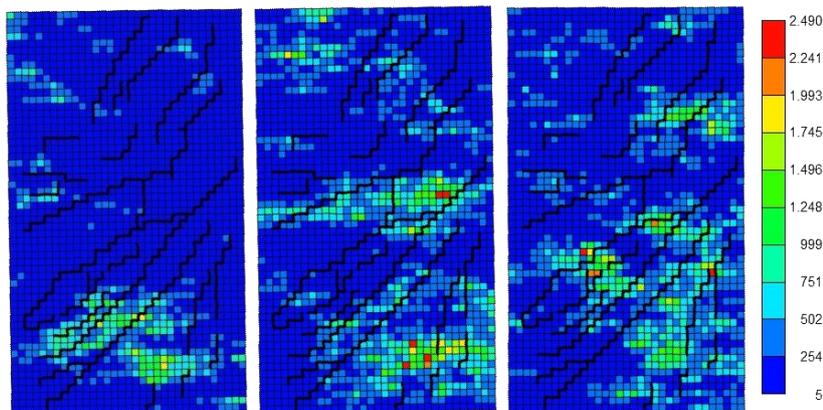


Figura 32 - Permeabilidade da primeira camada dos três cenários geológicos escolhidos

5.2. Métricas de avaliação

Diversos indicadores foram desenvolvidos para se comparar os desempenhos dos modelos. Tais ferramentas estatísticas têm valor ao permitir o julgamento isento das vantagens dos modelos. Existem indicadores de precisão, de adequação relativa e que tentam capturar a capacidade de acerto de tendência dos modelos em questão [53].

Nesta dissertação, foram utilizadas as métricas de erro RMSE, já apresentada, MAPE (*Mean Absolute Percentage Error*), SMAPE (*Symmetric Mean Absolute Percentage Error*) e R^2 (coeficiente de determinação) para a avaliação do desempenho dos aproximadores.

O RMSE fornece o erro na dimensão da variável e mede a magnitude média do erro. O MAPE tenta capturar a importância do erro relativo, fornecendo um

valor percentual. Já o SMAPE, que é outra medida em percentual, é uma métrica amplamente utilizada em trabalhos relacionados a séries temporais [54]. As Equações (13) e (14) mostram o cálculo do MAPE e SMAPE respectivamente.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{A_t} \quad (13)$$

onde, A_t : valor real, dado pelo simulador;

F_t : valor previsto, dado pelo aproximador;

n : número de amostras.

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|F_t - A_t|}{F_t + A_t} \quad (14)$$

Uma observação necessária é que o valor real pode ser zero, o que levaria a divisão por zero no erro MAPE. Para solucionar esse problema, sempre que esse caso acontecer o erro dessa amostra será de 100%, exceto quando o valor previsto também for zero, levando ao erro nulo. No SMAPE, a divisão por zero também ocorre quando o valor previsto e o real forem zero. Caso ocorra, o erro dessa amostra será zero.

O coeficiente de determinação, ou R^2 , é uma medida descritiva da qualidade do ajuste do modelo obtido em relação aos dados observados, no caso os dados simulados. O R^2 varia entre 0 e 1 e quanto maior o seu valor, mais explicativo é o modelo, ou seja, melhor ele se ajusta aos dados. O cálculo do coeficiente de determinação é apresentado na Equação (15).

$$R^2 = \frac{(\sum_{t=1}^n (F_t - \bar{F}) A_t)^2}{\sum_{t=1}^n (F_t - \bar{F})^2 \sum_{t=1}^n (A_t - \bar{A})^2} \quad (15)$$

5.3.

Parâmetros da PGLIQ e Especificações das Máquinas

Nos testes com a Programação Genética Linear com Inspiração Quântica, todos os programas evoluídos tem comprimento máximo de 128 instruções, ou seja, podem ter até 128 *tokens* de função. A probabilidade inicial de NOP foi de 90% para que um indivíduo não cresça rapidamente. Para encontrar o melhor

modelo foram realizados 10 experimentos com cada grupo de bases de treinamento, validação e teste, sendo o melhor programa aquele que apresentou menores erros no conjunto de treinamento e validação. Os parâmetros básicos da PGLIQ são apresentados na Tabela 4.

Parâmetros da PGLIQ	Valor
Tamanho da População	4
Número de Demes	2
Número de Gerações	50000
Número de Experimentos	10
Função de Avaliação	RMSE
Probabilidade Inicial de NOP	0.9
Tamanho do Passo do Operador P(s)	0.004
Comprimento máximo do programa	128
Número de registradores da FPU	8

Tabela 4 – Parâmetros da PGLIQ

Os aproximadores foram evoluídos em um PC com a seguinte configuração básica:

- Processador: AMD Phenom II X4 965;
- Frequência de *clock*: 3,41 GHz;
- Capacidade de memória: 8 GB;
- Sistema Operacional: Windows 7 Professional.

As otimizações de localização de poços foram realizadas em um PC com a seguinte configuração básica:

- Processador: Intel Core I7 X980;
- Frequência de *clock*: 3,33 GHz;
- Capacidade de memória: 6 GB;
- Sistema Operacional: Windows 7 Professional.

5.4. Teste de Conceito

Um teste de conceito foi realizado para determinar se o modelo de construção do aproximador é viável comparando a aproximação da curva acumulada de produção. Nesse teste foi gerado um programa para aproximar a

curva de produção de óleo acumulado de apenas um poço produtor, em um horizonte de previsão de 20 anos, com o primeiro cenário geológico das Figura 31 e Figura 32. Os cenários de poços foram gerados de forma aleatória. No total foram executadas 4200 simulações, divididas igualmente entre as bases de treinamento, validação e teste. A Tabela 5 mostra o resultado do teste de conceito, provando que a modelagem do aproximador é de fato viável, uma vez que os erros de teste foram considerados baixos.

Erro	Base	Média	Melhor	Desvio Padrão
RMSE	Treino	9.880562	7.931283	0.913237
	Validação	9.936465	8.237165	0.854520
	Teste	376.7515	414.3371	79.657432
SMAPE	Treino	1.06%	0.85%	0.001153
	Validação	1.03%	0.82%	0.001289
	Teste	10.57%	10.40%	0.008703
MAPE	Treino	2.06%	1.25%	0.005294
	Validação	2.60%	1.64%	0.008313
	Teste	15.96%	14.66%	0.013882

Tabela 5 – Resultados do Teste de Conceito

5.5. Teste de Sensibilidade

Um teste de sensibilidade foi realizado para tentar diminuir o número de amostras necessárias para a criação do aproximador. Nesse teste foi gerado um programa para aproximar a curva de óleo acumulado de 6 poços, sendo três produtores e três injetores, em um horizonte de previsão de 20 anos com o primeiro cenário geológico das Figura 31 e Figura 32. Nesses testes os cenários de poços também foram gerados de forma aleatória. No total foram feitos quatro experimentos para cada aproximador.

Inicialmente, foram executadas 17.000 simulações, divididas de forma que as bases de treinamento, validação e teste ficassem com o número de amostras bem próximas. A Tabela 6 apresenta os resultados para o aproximador com essas especificações.

Erro	Base	Média	Melhor	Desvio Padrão
RMSE	Treino	40.5064	21.32488	32.999799
	Validação	40.16828	21.08464	32.788968
	Teste	1176.563	753.7218	334.283890
SMAPE	Treino	0.46%	0.22%	0.003878
	Validação	0.48%	0.24%	0.003929
	Teste	8.40%	5.28%	0.021775
MAPE	Treino	0.89%	0.44%	0.007401
	Validação	0.94%	0.49%	0.007335
	Teste	15.67%	10.93%	0.032308

Tabela 6 – Resultados do Teste de Sensibilidade para 11.500 Simulações

Para reduzir o número de amostras da base mas mantendo o mesmo critério de avaliação, a base de teste não foi alterada. Ou seja, apenas as bases de treinamento e validação tiveram suas amostras reduzidas. Assim, o número de simulações considerando apenas esses dois conjuntos do primeiro caso foi de 11.500 simulações.

O processo de redução foi efetuado retirando aleatoriamente amostras de cenários de poços. Isto é, retirando 17 amostras (número de anos previsto pelo aproximador) por vez de cada base.

Na primeira tentativa, o número de simulações foi reduzido para aproximadamente metade do valor original. Então, 5.800 simulações foram efetuadas. A Tabela 7 mostra os resultados para o aproximador com essa redução de amostras, com os resultados ainda satisfatórios.

Erro	Base	Média	Melhor	Desvio Padrão
RMSE	Treino	24.19828	21.02124	2.26166216
	Validação	23.62878	20.51775	2.209110841
	Teste	1211.257	796.5391	309.3502068
SMAPE	Treino	0.29%	0.25%	0.000298156
	Validação	0.32%	0.28%	0.000403758
	Teste	8.82%	5.44%	0.031759082
MAPE	Treino	0.56%	0.52%	0.000270111
	Validação	0.66%	0.68%	0.000702799
	Teste	15.48%	11.63%	0.030782885

Tabela 7 – Resultados do Teste de Sensibilidade para 5.800 Simulações

Em uma segunda etapa, o número de simulações foi novamente reduzido para a metade, totalizando 2.900 simulações no total para as bases de treinamento e teste. A Tabela 8 apresenta os resultados para o aproximador. Houve uma melhora na média do erro de treino e validação provavelmente porque com menos amostras o modelo conseguiu se ajustar melhor. Ainda assim, os erros da base de teste continuaram baixos.

A base de treinamento e validação foi reduzida outra vez totalizando 1.500 simulações. Contudo, essa redução não foi aleatória, pois as amostras provavelmente não estão bem distribuídas pelo espaço. Uma nova amostragem por Hipercubo Latino foi realizada com essa quantidade de simulações. A Tabela 9 aponta os resultados para esse aproximador. Apesar do erro de treinamento e validação ter aumentado ligeiramente, o erro de teste continua aceitável.

A Tabela 10 e Tabela 11 continuam esse processo de redução pela metade. Apesar do melhor aproximador da Tabela 11 ainda ter um erro MAPE baixo, a média foi considerada elevada. Por isso, optou-se por utilizar o valor de 740 simulações para criar os *proxies*. Assim, cada configuração de poços terá esse mesmo número de simulações para criar um aproximador para cada fluido.

Erro	Base	Média	Melhor	Desvio Padrão
RMSE	Treino	22.92149	21.07673	2.058808812
	Validação	22.43187	20.44424	2.3588921
	Teste	1099.901	748.6915	633.182512
SMAPE	Treino	0.25%	0.21%	0.000407796
	Validação	0.29%	0.22%	0.00066346
	Teste	6.29%	5.26%	0.015129505
MAPE	Treino	0.50%	0.42%	0.000691605
	Validação	0.58%	0.42%	0.001288437
	Teste	15.17%	10.79%	0.073968948

Tabela 8 – Resultados do Teste de Sensibilidade para 2.900 Simulações

Erro	Base	Média	Melhor	Desvio Padrão
RMSE	Treino	36.26717	21.46007	13.24784061
	Validação	36.52552	21.57192	13.06558582
	Teste	998.138	728.9682	408.3421969
SMAPE	Treino	0.45%	0.27%	0.001886775
	Validação	0.41%	0.23%	0.001840915
	Teste	8.30%	5.23%	0.051322093
MAPE	Treino	0.87%	0.53%	0.003197119
	Validação	0.81%	0.46%	0.003355857
	Teste	14.25%	11.06%	0.049055929

Tabela 9 – Resultados do Teste de Sensibilidade para 1.500 Simulações

Erro	Base	Média	Melhor	Desvio Padrão
RMSE	Treino	22.11141	19.99448	2.556174137
	Validação	22.36455	20.18414	2.410170136
	Teste	940.2715	748.2313	373.0934949
SMAPE	Treino	0.24%	0.21%	0.000402962
	Validação	0.24%	0.21%	0.000425956
	Teste	6.48%	5.30%	0.021292043
MAPE	Treino	0.46%	0.40%	0.000744129
	Validação	0.48%	0.43%	0.000768023
	Teste	12.70%	10.92%	0.035125321

Tabela 10 - Resultados do Teste de Sensibilidade para 740 Simulações

Erro	Base	Média	Melhor	Desvio Padrão
RMSE	Treino	41.27767	21.54979	33.88644815
	Validação	40.25004	21.49834	33.05353524
	Teste	2.57E+34	769.7783	5.15E+34
SMAPE	Treino	0.53%	0.24%	0.004245583
	Validação	0.60%	0.26%	0.005075125
	Teste	7.31%	5.46%	0.021785511
MAPE	Treino	0.99%	0.46%	0.008106776
	Validação	1.24%	0.51%	0.01137947
	Teste	7.87E+28	11.03%	1.57E+29

Tabela 11 - Resultados do Teste de Sensibilidade para 370 Simulações

O erro para a função que aproxima a curva de óleo foi baixo na Tabela 11 se for considerado o melhor indivíduo. Porém, a média foi bem elevada e o desvio padrão maior que a média. Esse fato aconteceu pois quando se calcula o desvio padrão é suposto indevidamente que a distribuição é normal.

Analisando a distribuição dos erros, agora com 10 experimentos, para esse problema através do *BoxPlot* da Figura 33, percebe-se que dois valores causaram o aumento exagerado da média. Esses pontos provavelmente são *outliers*, que não representam satisfatoriamente o modelo.

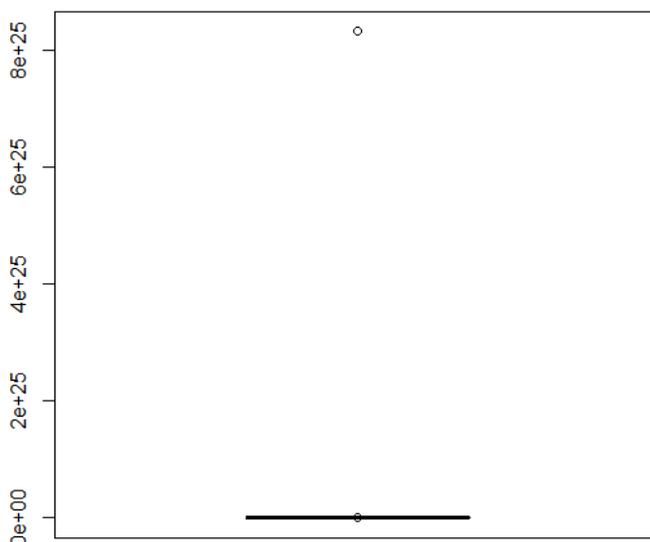


Figura 33 - BoxPlot dos Erros MAPE de Teste do Último Teste de Sensibilidade

A suposição de que a distribuição era normal está errada. Na prática, é desejado levar o erro a zero, ou seja, a maioria desses aproximadores estará tendendo para esse valor desejado. Como não se tem erros negativos pelos cálculos utilizados, a distribuição desconhecida provavelmente tem a maioria de seus valores próximos de zero e uma “cauda” formada conforme o erro aumenta.

Uma comparação da média com a mediana é realizada na **Tabela 12** para os erros na base de teste, mostrando que a diferença é grande entre essas duas medidas, o que comprova a não normalidade uma vez que a mediana e média da distribuição normal são iguais. A mediana também mostra que metade dos experimentos rodados possuem erros MAPE menores que 18.25%.

Erro	Média	Mediana
RMSE	1.11114E+11	1489.605
MAPE	8.32E+24	18.25%

Tabela 12 – Comparação entre Média e Mediana do Teste de Sensibilidade

5.6. Aproximadores

Nesta seção serão apresentados todos os aproximadores desenvolvidos para realizar a otimização, tanto determinística quanto sob incerteza, da localização de poços. Para avaliá-los, serão mostrados seus erros RMSE, SMAPE, MAPE e R^2 . Também serão exibidas algumas curvas de produção, comparando os valores simulados com os valores aproximados. Cada aproximador levou em média 23.34 minutos para ser evoluído. Como foram realizados 10 experimentos, o tempo gasto foi de 1.56 horas para que fosse possível fazer uma análise estatística. Esta seção será dividida de acordo com o cenário geológico que se está criando o *proxy*.

5.6.1. Cenário Geológico 1

Para esse cenário geológico foram criados no total 18 aproximadores, 3 (água, óleo e gás) para cada configuração de poços (6 diferentes combinações). A Tabela 13 apresenta os resultados dos aproximadores com 6 poços produtores. Os valores dos erros para os aproximadores de óleo, gás e água são considerados bons, uma vez que seus erros no conjunto de teste foram baixos.

6p		Óleo		Gás		Água	
Erro	Base	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	Treino	54.62835	23.81558	7.6404	2.2966	105.6	102.91
	Validação	54.35034	23.38275	7.69	2.2706	100.22	99.01
	Teste	925.26	721.6575	126.7	73.607	6090.6	6319
SMAPE	Treino	0.32%	0.13%	0.47%	0.12%	0.22%	0.23%
	Validação	0.32%	0.13%	0.48%	0.12%	0.22%	0.23%
	Teste	3.98%	2.96%	5.54%	2.94%	5.80%	6.28%
MAPE	Treino	0.64%	0.25%	0.95%	0.24%	1.17%	0.48%
	Validação	0.65%	0.25%	0.96%	0.24%	1.01%	0.46%
	Teste	8.39%	6.00%	12.78%	5.91%	12.19%	12.81%

Tabela 13 – Resultados dos Aproximadores para 6 Poços Produtores para o Cenário 1

Como o desvio padrão não é uma medida adequada nessa situação, o coeficiente de determinação será calculado como mais uma medida para verificar

o desempenho do aproximador. A Tabela 14 mostra os coeficientes dos aproximadores com 6 poços produtores para a base de teste das três curvas de produção.

6p		Óleo		Gás		Água	
Erro	Base	Média	Melhor	Média	Melhor	Média	Melhor
R^2	Teste	93.07%	95.39%	88.39%	95.15%	95.87%	95.51%

Tabela 14 – R^2 para os Aproximadores com 6 Poços Produtores para o Cenário 1

Como a saída dos aproximadores é o valor acumulado no ano de um fluido, pode ser traçada a curva de produção para as diversas alternativas de poços presentes na base de teste. A Figura 34 ilustra a comparação da curva de óleo acumulado para alguns cenários de poços simulados pelo IMEX e previstos pelo aproximador. Esse tipo de gráfico foi construído considerando as alternativas de poços (configurações de poços) no eixo das abscissas. Porém para cada configuração de poços o gráfico considera os 17 anos previstos pelo aproximador. Ou seja, de dezete em dezete pontos a configuração de poços é alterada. Já a Figura 35 mostra o gráfico da curva de gás dos valores reais, oriundos do simulador, e dos valores previstos, proveniente do aproximador. Por último, a Figura 36 apresenta a curva para a produção de água.

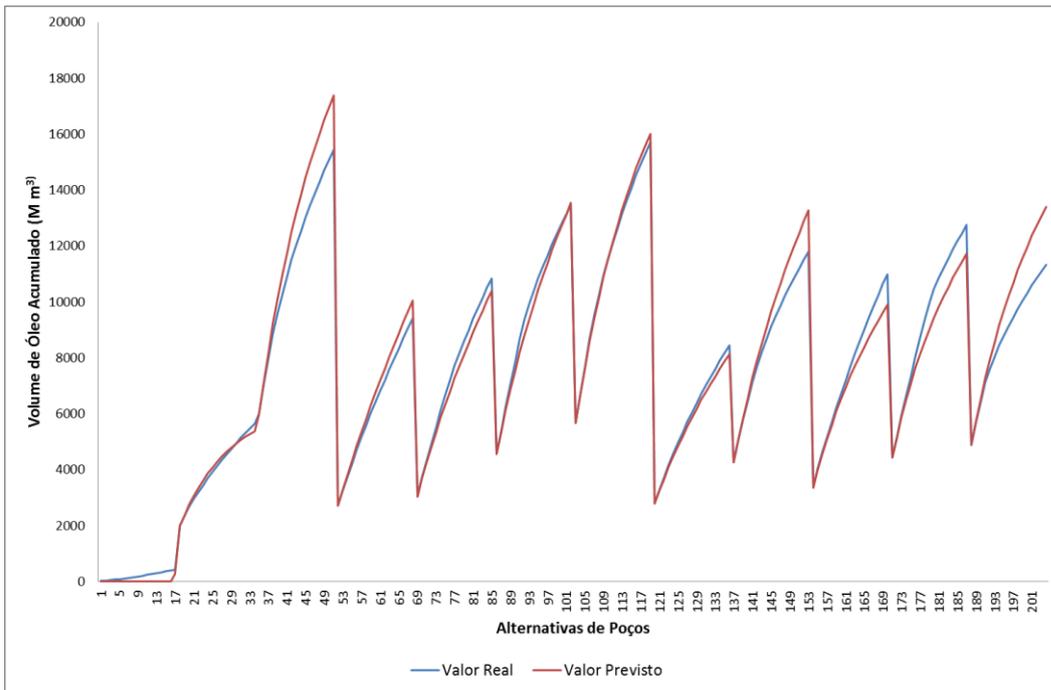


Figura 34 - Curva do Óleo Acumulado para o Aproximador com 6 Poços Produtores no Cenário 1

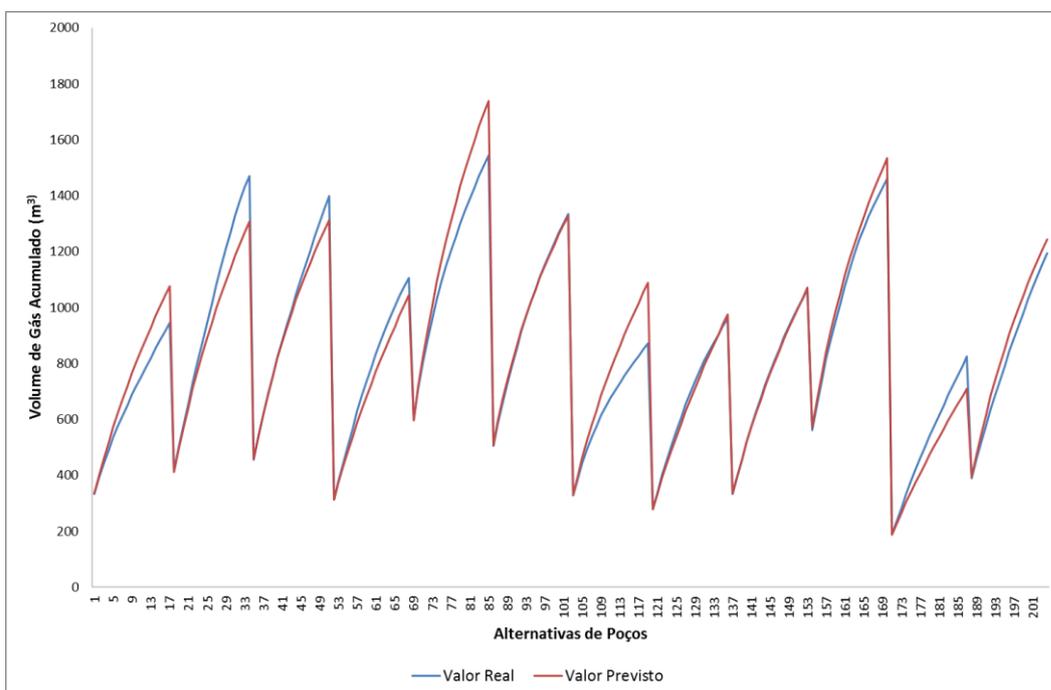


Figura 35 - Curva de Gás Acumulado para o Aproximador com 6 Poços Produtores no Cenário 1

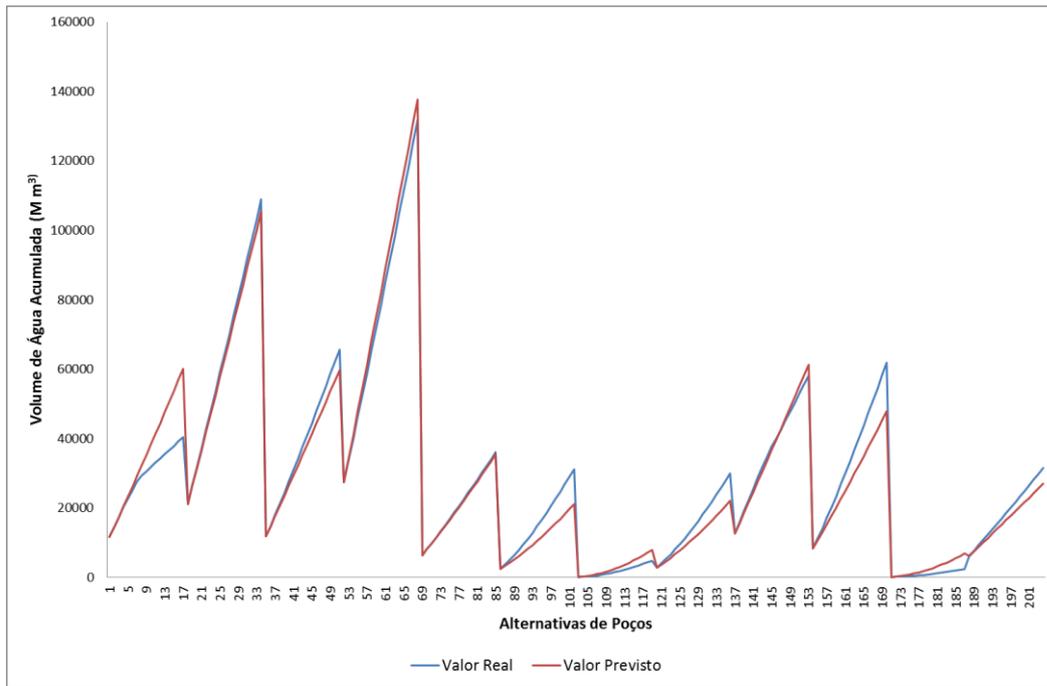


Figura 36 – Curva de Água Acumulada para o Aproximador com 6 Poços Produtores no Cenário 1

A Tabela 15, Tabela 16, Tabela 17, Tabela 18 e Tabela 19 apresentam os resultados para os aproximadores restantes desse cenário geológico. O aproximador da curva de óleo para 5 poços produtores e 1 injetor teve um valor na média do seu erro MAPE de teste um pouco mais alto do que comparado com o aproximador anterior.

5p1i		Óleo		Gás		Água	
Erro	Base	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	Treino	59.04534	21.44072	9.291	2.2907	125.86	117.27
	Validação	58.75478	21.80673	9.283	2.3106	111.62	102.32
	Teste	1934.57	808.8175	126.03	76.793	5825.7	4744
SMAPE	Treino	0.41%	0.13%	0.65%	0.14%	0.44%	0.39%
	Validação	0.41%	0.14%	0.64%	0.14%	0.41%	0.35%
	Teste	5.06%	3.72%	6.51%	3.59%	7.91%	6.63%
MAPE	Treino	0.83%	0.27%	1.30%	0.27%	1.17%	0.95%
	Validação	0.82%	0.27%	1.29%	0.28%	1.01%	0.79%
	Teste	21.45%	7.59%	13.18%	7.76%	17.52%	15.48%
R^2	Teste	78.71%	94.12%	88.24%	94.83%	94.59%	95.54%

Tabela 15 - Resultados dos Aproximadores com 5 Poços Produtores e 1 Injetor para o Cenário 1

4p2i		Óleo		Gás		Água	
Erro	Base	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	Treino	25.289	21.207	6.2159	2.5728	126.6	118.63
	Validação	25.273	21.385	6.1417	2.5149	117.96	109
	Teste	923.86	710.52	137.84	121.25	5761.1	4487.2
SMAPE	Treino	0.19%	0.16%	0.55%	0.19%	0.71%	0.67%
	Validação	0.25%	0.20%	0.63%	0.22%	0.64%	0.60%
	Teste	5.24%	4.02%	7.85%	6.46%	11.22%	9.37%
MAPE	Treino	0.39%	0.32%	1.09%	0.38%	1.78%	1.73%
	Validação	0.46%	0.42%	1.39%	0.42%	1.43%	1.39%
	Teste	10.12%	8.22%	15.66%	12.29%	22.46%	19.24%
R^2	Teste	93.25%	94.73%	87.93%	91.91%	93.41%	94.14%

Tabela 16 - Resultados dos Aproximadores com 4 Poços Produtores e 2 Injetores para o Cenário 1

3p3i		Óleo		Gás		Água	
Erro	Base	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	Treino	24.816	21.269	5.6433	1.9583	129.43	108.29
	Validação	24.841	21.442	5.6923	1.9876	128.57	108.68
	Teste	984.19	762.55	106.77	72.901	5096.3	3798.3
SMAPE	Treino	0.33%	0.34%	0.71%	0.22%	1.14%	0.97%
	Validação	0.42%	0.26%	0.66%	0.20%	1.36%	1.15%
	Teste	14.91%	6.01%	8.16%	5.30%	15.60%	14.81%
MAPE	Treino	0.63%	0.58%	1.45%	0.42%	2.72%	2.13%
	Validação	0.55%	0.46%	1.33%	0.38%	3.21%	2.41%
	Teste	14.80%	14.03%	16.93%	11.19%	35.57%	30.54%
R^2	Teste	91.57%	92.91%	87.78%	93.33%	91.32%	93.83%

Tabela 17 - Resultados dos Aproximadores com 3 Poços Produtores e 3 Injetores para o Cenário 1

2p4i		Óleo		Gás		Água	
Erro	Base	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	Treino	31.617	18.102	2.3997	1.9395	105.83	101.12
	Validação	31.896	18.521	2.4039	1.9627	105.24	101.12
	Teste	923.01	719.13	69.322	74.879	5499	4013.1
SMAPE	Treino	0.71%	0.43%	0.65%	0.62%	4.00%	3.74%
	Validação	0.68%	0.43%	0.61%	0.58%	3.21%	2.98%
	Teste	10.94%	9.24%	10.96%	9.68%	23.70%	23.32%
MAPE	Treino	1.33%	0.73%	1.17%	0.98%	6.10%	4.94%
	Validação	1.27%	0.72%	1.08%	0.90%	5.18%	4.15%
	Teste	21.30%	17.12%	20.60%	17.70%	52.31%	43.66%
R^2	Teste	89.11%	91.40%	89.34%	90.83%	94.60%	94.16%

Tabela 18 - Resultados dos Aproximadores com 2 Poços Produtores e 4 Injetores para o Cenário 1

1p5i		Óleo		Gás		Água	
Erro	Base	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	Treino	15.577	14.446	1.6327	1.4693	125.31	89.52
	Validação	15.604	14.578	1.6254	1.5106	123.19	91.388
	Teste	618.96	570.65	69.322	58.419	5863.6	5811.3
SMAPE	Treino	1.75%	1.59%	1.68%	1.65%	14.02%	13.33%
	Validação	1.54%	1.46%	1.54%	1.51%	14.26%	13.70%
	Teste	16.58%	16.20%	16.91%	16.48%	46.69%	47.16%
MAPE	Treino	4.54%	3.50%	4.44%	4.14%	19.31%	15.47%
	Validação	3.66%	2.84%	2.74%	2.65%	20.47%	16.71%
	Teste	26.85%	26.02%	27.88%	27.91%	77.41%	71.67%
R^2	Teste	89.88%	90.14%	89.27%	89.59%	95.76%	95.93%

Tabela 19 - Resultados dos Aproximadores com 1 Poço Produtor e 5 Injetores para o Cenário 1

Para as configurações de poços restantes não foi observada nenhuma diferença significativa entre os melhores aproximadores e a média dos erros. No geral, os aproximadores de óleo e gás tiveram bons resultados, pois seus erros MAPE de teste foram todos abaixo de 30%. Inclusive, em quatro configurações de poços ficou abaixo de 15%.

Os aproximadores da curva de produção de água também tiveram bons resultados. Porém, para a configuração de 1 poço produtor e 5 injetores o erro MAPE de teste foi de aproximadamente 71% para o melhor programa. O principal motivo desse erro maior comparado aos outros aproximadores foi devido ao fato de grande parte dos cenários de poços terem sua produção zerada por causa da restrição da janela inicial. Quase 50% do erro MAPE de teste foi originado pelos 100% forçados pela restrição. Essa estimativa foi feita separando os casos em que a restrição era satisfeita e calculando o erro sobre os mesmos.

Pensando no aproximador como um modelo isolado, o resultado pode não ser tão bom. Contudo, no ambiente de otimização de localização de poços, esse *proxy* pode ter um desempenho satisfatório, até porque o coeficiente de determinação foi bem elevado.

5.6.2. Cenário Geológico 2

A partir dos resultados para o cenário geológico 2 só serão apresentados os erros de teste. Para esse cenário, a geração dos aproximadores foi exatamente igual, com as mesmas amostras do Hipercubo Latino usadas no cenário anterior. A única diferença é que neste foram usadas uma imagem de permeabilidade e porosidade diferentes para o reservatório.

No aproximador com a configuração de 5 poços produtores mostrada na Tabela 21, o erro de teste da curva de produção de gás provavelmente contém um *outlier*. O que é comprovado analisando a mediana do erro MAPE, cujo valor vale 13.59%. A Tabela 20, Tabela 22, Tabela 23, Tabela 24 e Tabela 25 apresentam os resultados para as outras configurações de poços desse cenário geológico.

6p	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1823.44	949.68	175.95	91.9919	6510.08	6540.5
SMAPE	6.19%	3.12%	5.48%	3.19%	5.65%	5.50%
MAPE	11.76%	6.31%	11.06%	6.30%	11.33%	11.39%
R^2	88.39%	94.67%	88.86%	94.89%	95.03%	95.22%

Tabela 20 - Resultados dos Aproximadores com 6 Poços Produtores para o Cenário 2

5p1i	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1.6E+21	898.371	151.39	91.137	5584.09	4899.8
SMAPE	5.43%	3.61%	5.80%	3.67%	6.90%	8.49%
MAPE	6.8E+16	8.28%	19.70%	8.44%	15.38%	22.30%
R^2	78.23%	93.98%	88.74%	93.85%	93.65%	94.60%

Tabela 21 - Resultados dos Aproximadores com 5 Poços Produtores e 1 Injetor para o Cenário 2

4p2i	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1797.49	822.86	110.89	101.9	5990.64	4899.8
SMAPE	9.49%	4.05%	5.45%	4.08%	11.53%	8.49%
MAPE	16.01%	7.87%	12.50%	14.39%	27.07%	22.30%
R^2	83.38%	94.31%	89.74%	91.51%	91.90%	93.54%

Tabela 22 - Resultados dos Aproximadores para 4 Poços Produtores e 2 Injetores para o Cenário 2

3p3i	Óleo		Gás		Água	
Erro	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1345.22	837.7	117.62	82.646	5703.04	4762.8
SMAPE	7.68%	5.64%	6.98%	4.96%	14.93%	12.38%
MAPE	14.36%	10.60%	13.92%	9.96%	32.39%	28.02%
R^2	88.83%	93.22%	90.18%	93.29%	87.68%	90.34%

Tabela 23 - Resultados dos Aproximadores para 3 Poços Produtores e 3 Injetores para o Cenário 2

Na configuração com 2 poços produtores e 1 injetor, também foram apresentados *outliers* para a curva de produção de água. A Tabela 26 apresenta a mediana do erro MAPE dos experimentos do aproximador e a média desse mesmo erro caso o *outlier* tivesse sido removido. Os valores da média e da mediana ficaram bem próximos. Inclusive, ficaram perto do melhor programa.

2p4i	Óleo		Gás		Água	
Erro	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1305.06	835.863	105.35	87.893	2.7E+32	4085.6
SMAPE	11.85%	8.86%	10.35%	8.43%	22.99%	26.44%
MAPE	20.85%	15.68%	18.77%	15.88%	1.5E+27	40.04%
R^2	87.46%	90.64%	88.14%	90.48%	79.20%	89.07%

Tabela 24 - Resultados dos Aproximadores para 2 Poços Produtores e 4 Injetores para o Cenário 2

1p5i	Óleo		Gás		Água	
Erro	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	780.49	648.87	74.772	107.93	3342.6	2610.8
SMAPE	16.53%	15.09%	16.51%	18.06%	44.69%	44.37%
MAPE	26.38%	22.93%	25.60%	27.72%	71.79%	75.87%
R^2	87.70%	89.23%	87.91%	83.97%	84.55%	86.82%

Tabela 25 - Resultados dos Aproximadores com 1 Poço Produtor e 5 Injetores para o Cenário 2

2p4i		Água	
Erro	Base	Mediana	Média
MAPE	Teste	41.71%	41.70%

Tabela 26 - Análise dos Aproximadores com 4 Poços Produtores e 2 Injetores para o Cenário 2

Analisando com mais detalhes os *outliers* dos aproximadores desse cenário geológico, percebe-se que para a configuração de poços de 5 produtores e 1 injetor existe um aproximador cujo erro MAPE é $6.84E+15\%$. Estudando suas saídas, verifica-se que três alternativas possuem valores de saída considerados absurdos para o problema. A Figura 37 ilustra esse fenômeno. Se uma restrição fosse imposta de zerar a saída caso ultrapassasse um valor um limite, o erro MAPE desse aproximador passaria para 12.21%. O mesmo aconteceria com o aproximador da água para 2 poços produtores e 4 injetores.

Essa heurística não é tendenciosa, uma vez que não existem valores dessa proporção para esse reservatório. Apesar dessas alternativas, os aproximadores continuaram sendo robustos, pois para os outros cenários de poços os erros foram satisfatórios.

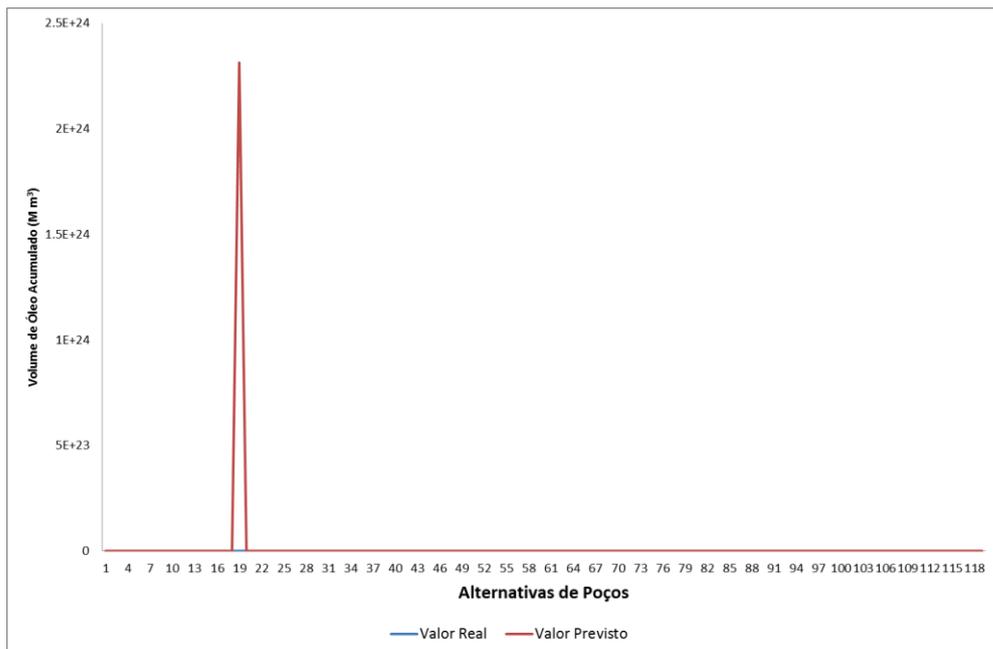


Figura 37 - Curva de Óleo Acumulado para o Aproximador com 5 Poços Produtor e 1 Injetor no Cenário 2

Os aproximadores de óleo e gás para esse cenário geológico se mostraram bastante eficientes com cinco configurações de poços com erros MAPE abaixo de 16%. Os aproximadores da curva de água também foram satisfatórios e

novamente para a configuração com 1 poço produtor e 5 injetores o erro foi elevado devido à restrição imposta para o programa na hora da evolução.

As Figura 38, Figura 39 e Figura 40 mostram os gráficos para as curvas de produção de óleo, gás e água, respectivamente. Essas curvas são dos aproximadores com 1 poço produtor e 5 injetores, ou seja, os aproximadores que tiveram os piores erros. Na Figura 40 pode ser observado claramente o efeito da restrição da janela inicial. Apesar de existir uma pequena produção de água, a saída do aproximador é zerada.

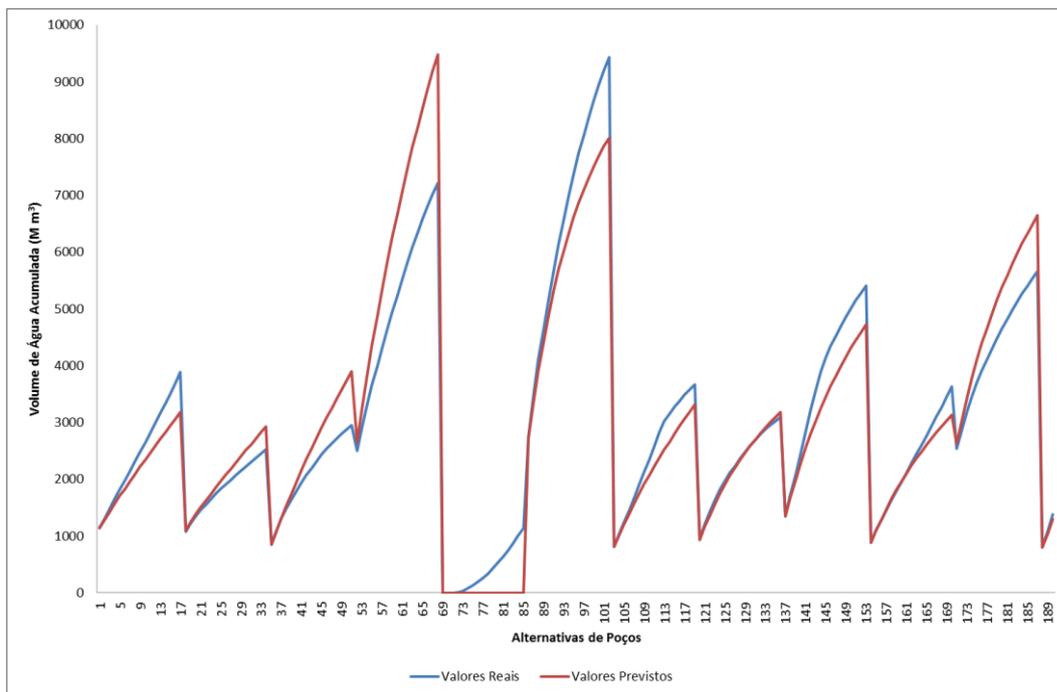


Figura 38 - Curva de Óleo Acumulado para o Aproximador com 1 Poço Produtor e 5 Injetores no Cenário 2

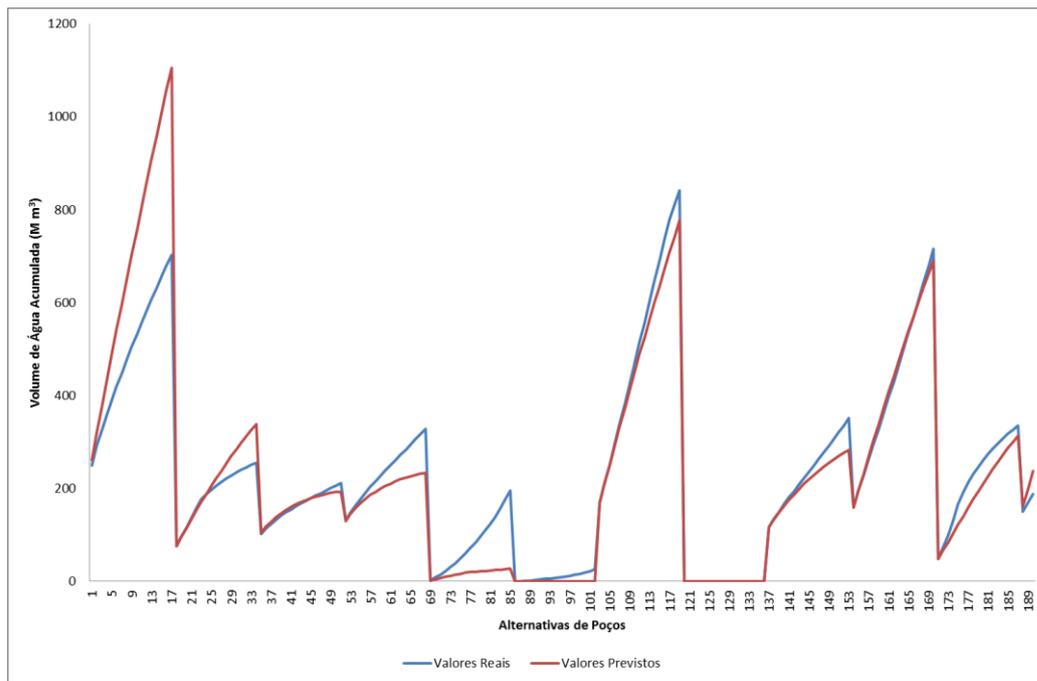


Figura 39 - Curva de Gás Acumulado para o Aproximador com 1 Poço Produtor e 5 Injetores no Cenário 2

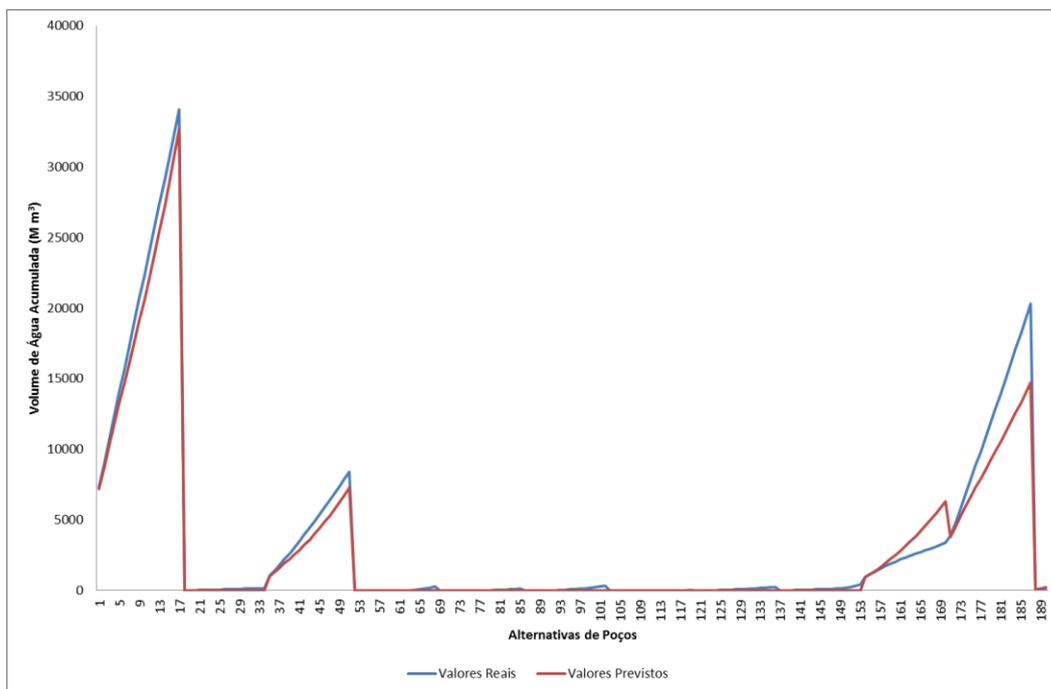


Figura 40 - Curva de Água Acumulada para o Aproximador com 1 Poço Produtor e 5 Injetores no Cenário 2

5.6.3. Cenário Geológico 3

Uma nova mudança no cenário geológico é feita para serem criados mais 18 aproximadores. A Tabela 27, Tabela 28, Tabela 29, Tabela 30, Tabela 31 e Tabela 32 mostram os resultados encontrados para as seis configurações de poços possíveis.

6p	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1689.83	777.182	123.98	82.5274	6129.1	4783.5
SMAPE	5.63%	2.88%	4.11%	2.92%	6.19%	4.65%
MAPE	11.23%	5.86%	8.26%	5.87%	12.27%	9.17%
R^2	89.38%	95.72%	92.63%	95.28%	95.46%	97.37%

Tabela 27 - Resultados dos Aproximadores com 6 Poços Produtores para o Cenário 3

5p1i	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1324.08	812.312	128.29	77.71	5879.3	5096.3
SMAPE	5.20%	3.37%	5.16%	3.33%	6.43%	5.93%
MAPE	10.57%	6.76%	10.54%	6.56%	13.54%	12.84%
R^2	90.05%	94.90%	90.61%	95.31%	96.18%	96.47%

Tabela 28 - Resultados dos Aproximadores com 5 Poços Produtores e 1 Injetor para o Cenário 3

4p2i	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1467.70	783.342	157.75	90.238	6138.4	5068
SMAPE	6.64%	4.01%	7.48%	4.35%	8.81%	8.15%
MAPE	15.42%	7.86%	15.51%	8.79%	20.04%	19.89%
R^2	88.01%	95.12%	87.03%	93.97%	95.13%	95.59%

Tabela 29 - Resultados dos Aproximadores com 4 Poços Produtores e 2 Injetores para o Cenário 3

3p3i	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1286.2	877.41	122.48	95.04	6192.7	4804.4
SMAPE	10.11%	5.67%	7.99%	5.56%	14.13%	12.28%
MAPE	19.78%	11.60%	16.80%	12.06%	30.92%	27.65%
R^2	87.56%	93.05%	88.39%	91.80%	94.03%	94.71%

Tabela 30 - Resultados dos Aproximadores com 3 Poços Produtores e 3 Injetores para o Cenário 3

2p4i	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	1142.9	870.51	131.49	84.694	4708.1	4118
SMAPE	11.33%	9.22%	11.17%	8.61%	23.81%	23.07%
MAPE	22.39%	16.98%	20.38%	16.98%	46.81%	46.65%
R^2	87.54%	90.52%	88.21%	91.01%	91.87%	92.14%

Tabela 31 - Resultados dos Aproximadores com 2 Poços Produtores e 4 Injetores para o Cenário 3

1p5i	Óleo		Gás		Água	
	Média	Melhor	Média	Melhor	Média	Melhor
RMSE	729.378	666.945	76.595	65.629	3427.7	3227.5
SMAPE	18.38%	18.23%	18.91%	17.64%	47.65%	46.70%
MAPE	28.32%	27.53%	28.65%	27.26%	70.73%	63.12%
R^2	88.79%	89.55%	88.66%	89.80%	92.94%	92.76%

Tabela 32 - Resultados dos Aproximadores com 1 Poço Produtor e 5 Injetores para o Cenário 3

Mais uma vez os aproximadores de óleo e gás tiveram seus melhores programas com erros MAPE abaixo de 30%. Sendo que em cinco configurações de poços com erros abaixo de 17%. Os aproximadores da curva de água também foram satisfatórios. Devido a restrição, a configuração para 1 poço produtor e cinco injetores foi prejudicada no valor do seu teste.

A Figura 41, Figura 42 e Figura 43 apresentam, respectivamente, os gráficos das curvas do óleo, gás e água acumulados. Nesses gráficos foram usadas as mesmas alternativas de poços. Ou seja, as primeiras amostras representam o óleo, gás e água produzidos para uma alternativa de poços e com esses valores o VPL poderia ser calculado.

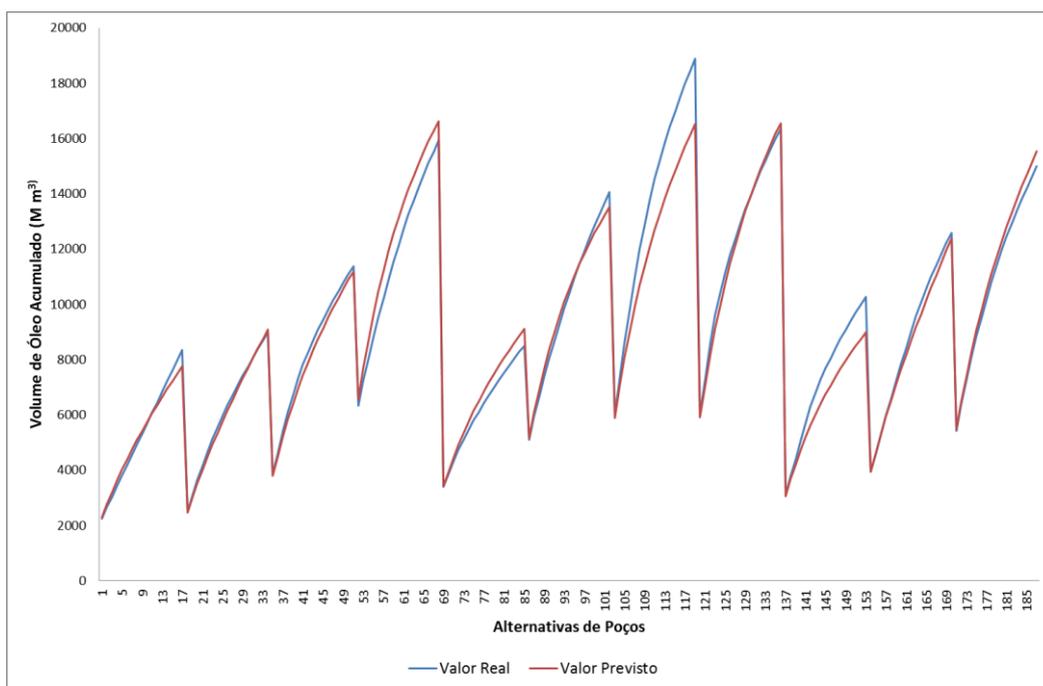


Figura 41 - Curva de Óleo Acumulado para o Aproximador com 5 Poços Produtores e 1 Injetor no Cenário 3

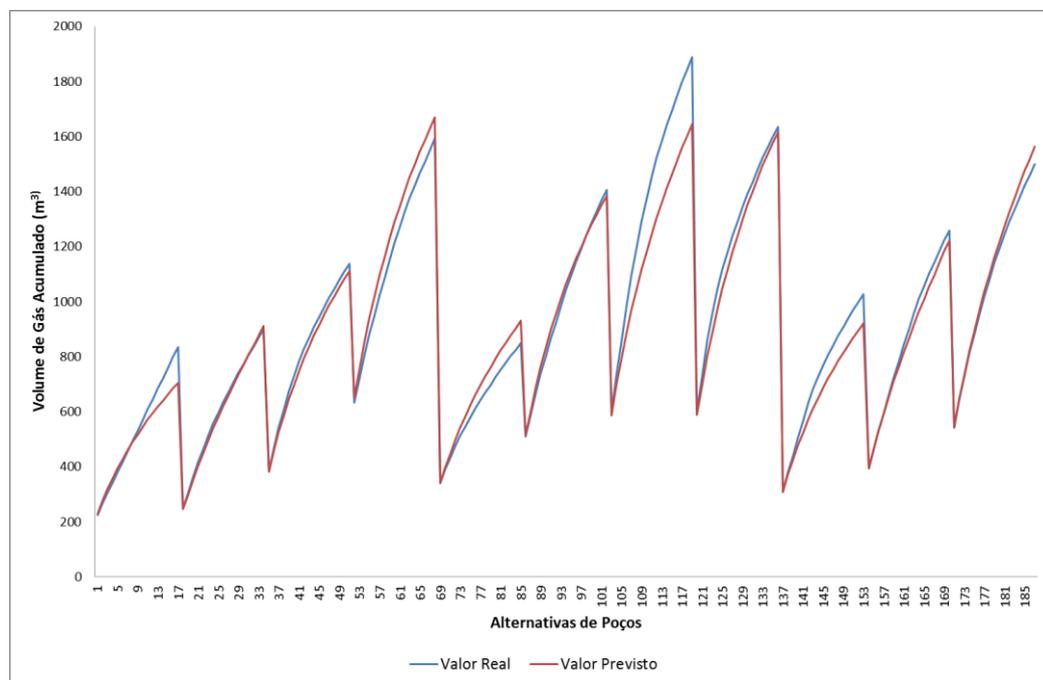


Figura 42 - Curva de Gás Acumulado para o Aproximador com 5 Poços Produtores e 1 Injetor no Cenário 3

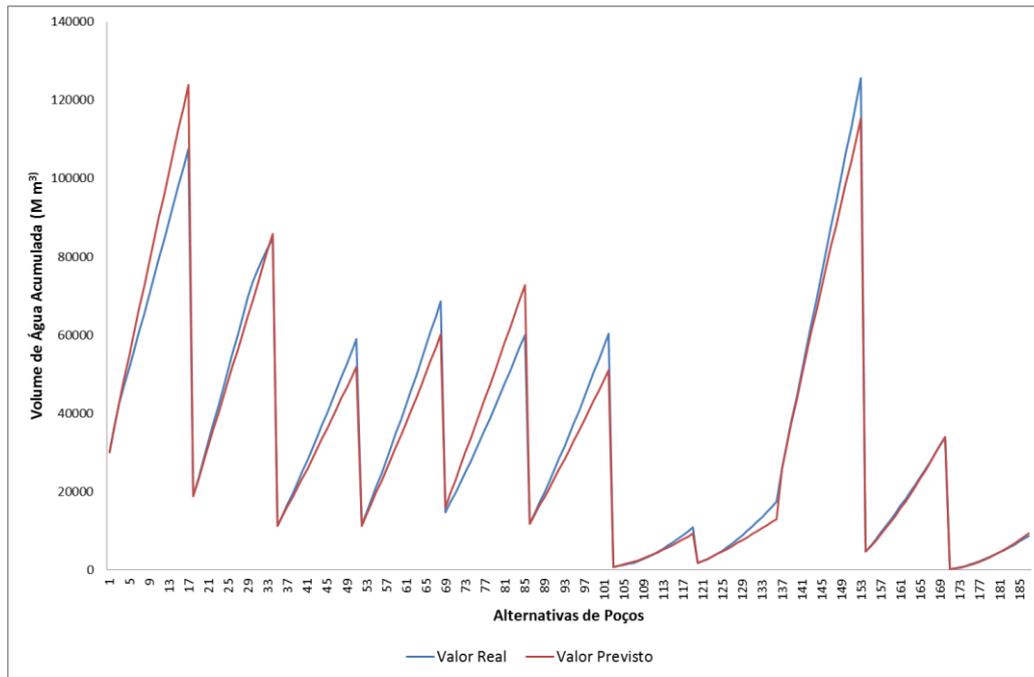


Figura 43 - Curva de Água Acumulada para o Aproximador com 5 Poços Produtores e 1 Injetor no Cenário 3

5.7. Otimização de Localização de Poços com Aproximadores

Nesta seção são apresentados os resultados relacionados ao desempenho dos aproximadores substituindo os simuladores no sistema de otimização apresentado em [55]. O sistema Octopus foi desenvolvido especificamente para a solução do problema de otimização de planos de drenagem. A partir da descrição de um reservatório, o sistema busca encontrar, por meio de um algoritmo genético, uma configuração de poços que maximize o VPL do projeto. No processo de busca pela melhor configuração, é levado em consideração a quantidade, o tipo (injetor ou produtor), a trajetória (vertical, horizontal ou direcional) e a localização dos poços.

O sistema utiliza o simulador IMEX para realizar inúmeras simulações para encontrar uma alternativa ótima de poços, o que decorre em um alto custo computacional. É então através do uso de aproximadores, que se propõe reduzir esse custo computacional. A substituição parcial ou total dos aproximadores pelo simulador proporcionaria ao sistema OCTOPUS uma ferramenta útil para acelerar o processo de otimização.

Os testes aqui apresentados foram realizados com o reservatório sintético com poços verticais. Dois tipos de otimização foram desenvolvidas, uma determinística e outra sob incerteza, considerando três cenários geológicos diferentes. Na otimização determinística, foram utilizados os aproximadores híbridos gerados para o cenário geológico 1. Comparações serão realizadas entre a otimização com o simulador IMEX e com o modelo híbrido proposto nesta dissertação, principalmente o tempo de execução e o VPL final, decidindo se o simulador pode ser substituído pelo aproximador.

5.7.1. Parâmetros

Inicialmente devem ser indicados os parâmetros utilizados para o sistema de otimização. A Tabela 33 e a Tabela 34 mostram respectivamente os parâmetros econômicos necessários para o cálculo do VPL e os parâmetros do algoritmo genético.

Parâmetros Econômicos	Valor
Preço do petróleo (US\$/bbl)	100
Preço do gás (US\$/1000m ³)	1
Plataforma (MMUS\$)	1000
Perfuração e completação (MMUS\$/poço)	120 a 130
Custo de produção de óleo (US\$/m ³)	3
Custo de produção de gás (US\$/1000m ³)	1
Custo de produção de água (US\$/m ³)	3
Alíquota de impostos	0,34
Taxa mínima de atratividade	0,10
Royalties	0,10

Tabela 33 - Parâmetros Econômicos

Parâmetros do Algoritmo Genético	Valor
Número de Gerações	80
Número de Indivíduos	50
Número de Rodadas	1
Steady State (inicial - final)	40% - 20%
Crossover (inicial - final)	65% - 8%
Mutação (inicial - final)	8% - 30%

Tabela 34 - Parâmetros do AG

5.7.2.

Comparação entre o Uso do Simulador e dos Aproximadores para a Otimização Determinística

Nesta seção serão apresentados os resultados do melhor indivíduo encontrado pelo OCTOPUS para ambos os tipos de cálculo da função de avaliação para o caso determinístico. A Tabela 35 mostra os resultados das três otimizações realizadas para cada abordagem. Inicialmente, uma comparação é realizada entre o VPL encontrado pelo aproximador e o seu valor real, ou seja, caso a alternativa tivesse sido simulada.

A Tabela 36 aponta as estatísticas dos resultados. De acordo com os valores, os resultados foram bem próximos, indicando que o simulador pode ser substituído pelo modelo proposto. O tempo de execução foi reduzido para a metade, o que é vantajoso uma vez que a simulação desse reservatório não é dispendiosa. No total, 2811 simulações foram realizadas no processo de otimização, enquanto que para a criação do aproximador foram necessárias 4.440 simulações. Apesar do número ainda maior que o necessário para a otimização inviabilizando o uso dos aproximadores, eles foram criados com um número bem reduzido quando comparados com o do trabalho desenvolvido em [7], mantendo a qualidade dos resultados.

Otimização	VPL		Tempo de Execução
	Aproximador	Simulador	
Proxy	\$ 3,259,569,314.16	\$ 2,781,699,126.03	1h:29min:25s
	\$ 3,612,314,394.79	\$ 3,203,783,146.63	1h:18min:52s
	\$ 3,567,370,565.11	\$ 3,015,529,850.00	1h:34min:45s
Simulador	-	\$ 2,740,920,599.65	2h:53min:13s
	-	\$ 3,170,388,908.77	3h:00min:08s
	-	\$ 3,081,015,717.30	3h:00min:40s

Tabela 35 - Resultados da Otimização Determinística

Tipo	Estatísticas	VPL		Tempo de Execução
		Aproximador	Real	
Proxy	Média	\$ 3,479,751,424.68	\$ 3,000,337,374.22	1h:27min:41s
	D.Padrão	1.92E+08	2.11E+08	0.13
Simulador	Média	-	\$ 2,997,441,741.91	2h:58min
	D.Padrão	-	2.27E+08	0.07

Tabela 36 - Estatísticas dos Resultados da Simulação Determinística

As curvas da evolução do processo de otimização com o simulador e com os aproximadores da melhor solução podem ser verificadas na Figura 44 e Figura 45, respectivamente. No gráfico estão as curvas *Offline*, Média e Melhor. A curva Melhor representa o melhor indivíduo encontrado em cada geração do algoritmo genético. A curva Média apresenta a média das avaliações de todos os indivíduos, permitindo verificar a rápida obtenção de boas soluções e também a visualização do grau de convergência dos indivíduos da população. Já a curva *Offline* é obtida a partir do valor médio das avaliações dos melhores indivíduos encontrados a cada passo da avaliação, mostrando a qualidade do algoritmo em encontrar soluções boas desde o início.

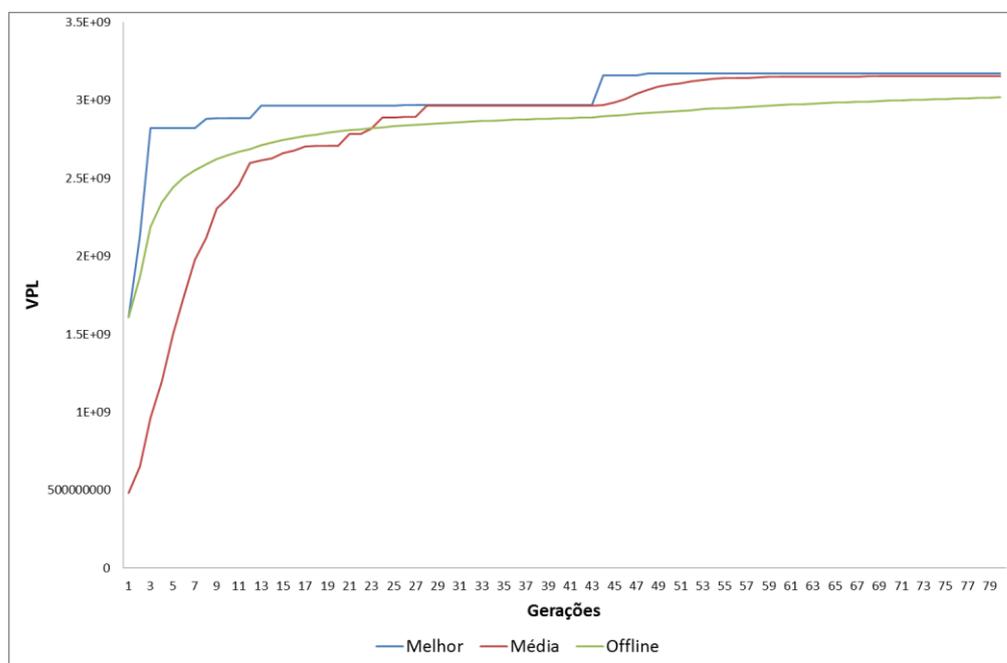


Figura 44 - Curva de Evolução da Otimização Determinística com Simulador

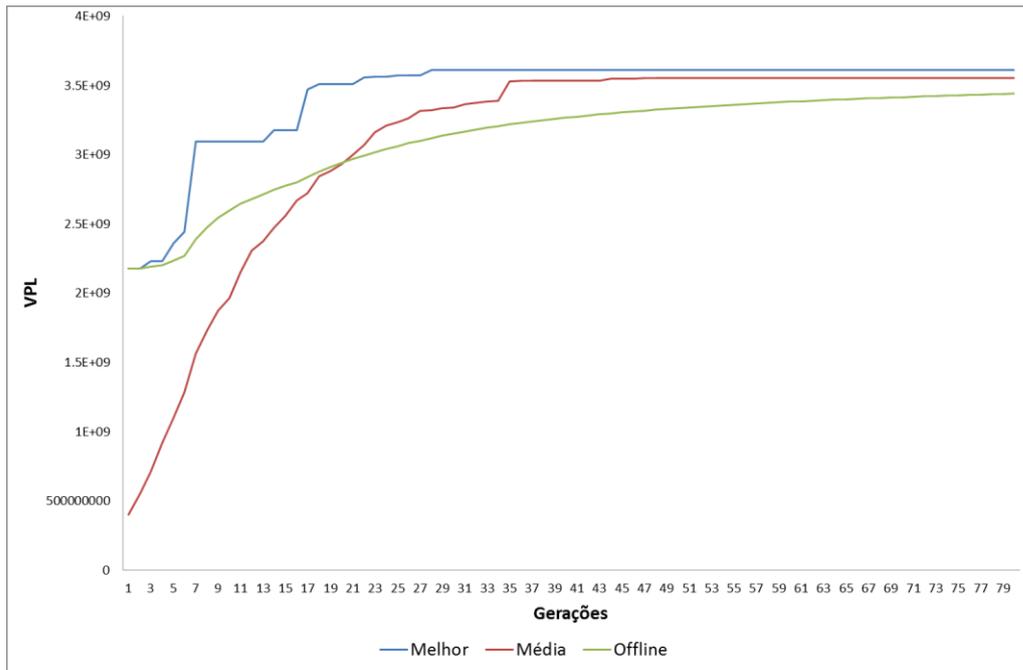


Figura 45 - Curva da Evolução da Otimização Determinística com Aproximadores

A Figura 46 mostra a configuração de poços para uma das otimizações determinísticas realizadas, em que o reservatório da esquerda é a configuração evoluída utilizando o simulador e da direita, utilizando o aproximador. Em ambas foram encontrados 6 poços produtores como configuração ótima.

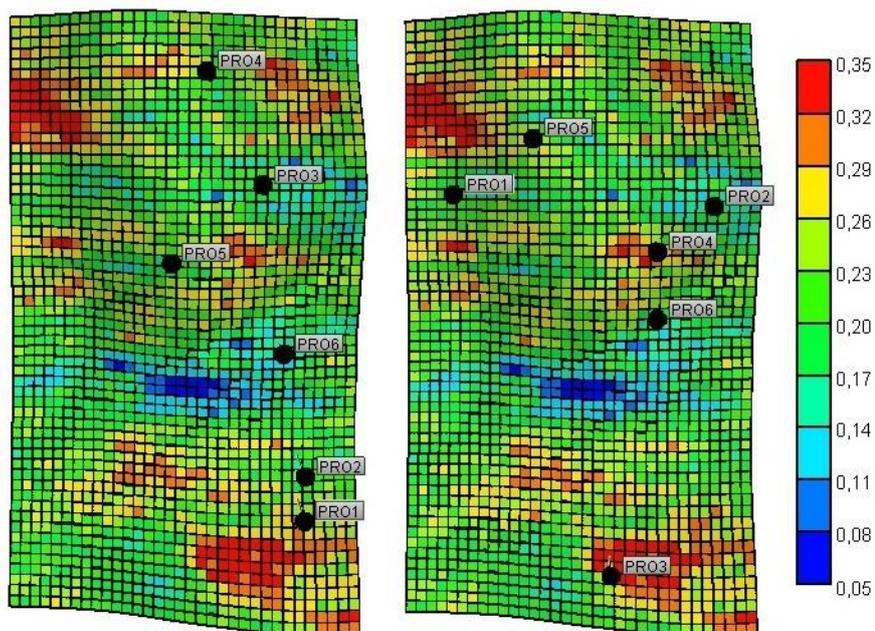


Figura 46 - Comparação das Configurações de Poços na Otimização Determinística

5.7.3.

Comparação entre o Uso do Simulador e dos Aproximadores para a Otimização Sob Incerteza

Reservatórios de petróleo, na fase de caracterização, possuem elevado número de incertezas geológicas, principalmente pelo pouco conhecimento agregado sobre o campo. A falta de conhecimento pode ser oriunda de vários atributos, como propriedades da rocha, falhas, continuidade, etc. Esse número cresce com o tamanho do campo e com a resolução do grid usado na simulação.

Considerando um modelo não coerente de reservatório, um desenvolvimento sub-ótimo estaria sendo realizado, produzindo menos que o máximo retorno econômico esperado, pois essas incertezas geológicas influenciam significativamente na recuperação de óleo e gás, e, conseqüentemente, no cálculo do valor presente líquido (VPL). Esse cenário de incertezas é mais crítico em campos marítimos, pois os investimentos são bastante elevados.

Uma maneira possível de reduzir o risco na fase de desenvolvimento seria obter informações adicionais, que poderiam reduzir determinada incerteza ou até mesmo eliminar por completo a incerteza de um determinado atributo. Porém um custo está associado à aquisição de tais informações, podendo tornar o projeto inviável economicamente.

Todavia, o especialista de E&P pode considerar um número bem reduzido de prováveis cenários para especular uma alternativa ótima de exploração, comum a estes cenários, de maneira a dar apoio à decisão dos especialistas de E&P.

Dois tipos de otimização da localização de poços considerando três cenários geológicos são realizados nesta seção, uma usando o simulador e a outra, os aproximadores. A função de avaliação para o algoritmo genético será calculada como a média dos VPLs de cada cenário. A Tabela 37 apresenta os resultados dos três experimentos para cada tipo de otimização. Os valores do VPL do aproximador e do seu real valor apresentaram uma variação média de menos de 15%.

A Tabela 38 mostra os resultados estatísticos para o VPL e tempo de execução dos modelos. Apesar da média do otimizador utilizando o simulador estar um pouco maior, os resultados podem ser considerados parecidos, uma vez que a diferença é de apenas 10%.

O tempo de execução foi reduzido em 60% usando os aproximadores. A implementação da integração da *proxy* com o sistema de otimização poderia ser mais eficiente, utilizando mais de um núcleo de processamento para calcular em paralelo os valores acumulados dos fluidos. Isso é possível, pois os valores de óleo, água e gás são independentes quando se utiliza os aproximadores, o que poderia reduzir ainda mais o tempo de execução. Inclusive, executar os programas dos aproximadores de diferentes configurações de poços em paralelo para acelerar ainda mais o processo de otimização.

Otimização	VPL		Tempo de Execução
	Aproximador	Simulador	
Proxy	\$ 3,554,088,088.72	\$ 3,085,203,605.30	3:28:12
	\$ 2,879,753,821.02	\$ 2,586,459,303.39	3:30:49
	\$ 3,809,450,217.55	\$ 3,154,248,195.92	3:28:03
Simulador	-	\$ 3,617,757,858.30	8:58:27
	-	\$ 3,198,951,734.41	8:49:55
	-	\$ 2,986,501,926.95	8:41:08

Tabela 37 - Resultados da Otimização sob Incerteza

Tipo	Estatísticas	VPL		Tempo de Execução
		Aproximador	Real	
Proxy	Média	\$ 3,414,430,709.10	\$ 2,941,970,368.21	3:29:01
	D.Padrão	4.80E+08	3.10E+08	0.03
Simulador	Média	-	\$ 3,267,737,173.22	8:49:50
	D.Padrão	-	3.21E+08	0.14

Tabela 38 - Estatísticas dos Resultados da Simulação sob Incerteza

A Figura 47 e Figura 48 ilustram as curvas do processo de otimização da melhor solução de cada tipo de otimização. Nesse caso em específico, a curva do *offline* da otimização com aproximadores foi melhor do que com o simulador, indicando que a primeira encontrou melhores soluções no início da evolução. No total, 8436 simulações foram necessárias, um número 37% menor do que para construção dos 54 aproximadores, que precisaram de 13.320 simulações.

Apesar do maior número de simulações, a construção do *proxy* compensa pois uma vez criado pode ser utilizado diversas vezes. Principalmente nesse caso

onde é utilizado uma técnica estocástica para encontrar as melhores alternativas, pois mais de um experimento deve ser conduzido.

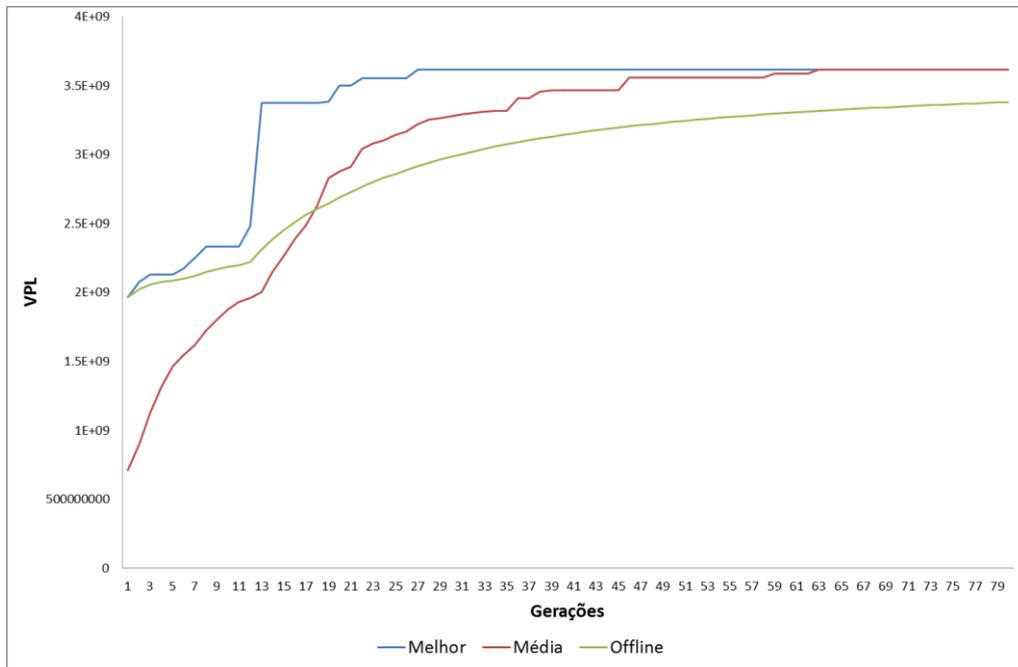


Figura 47 - Curva de Evolução da Otimização sob Incerteza com Simulador

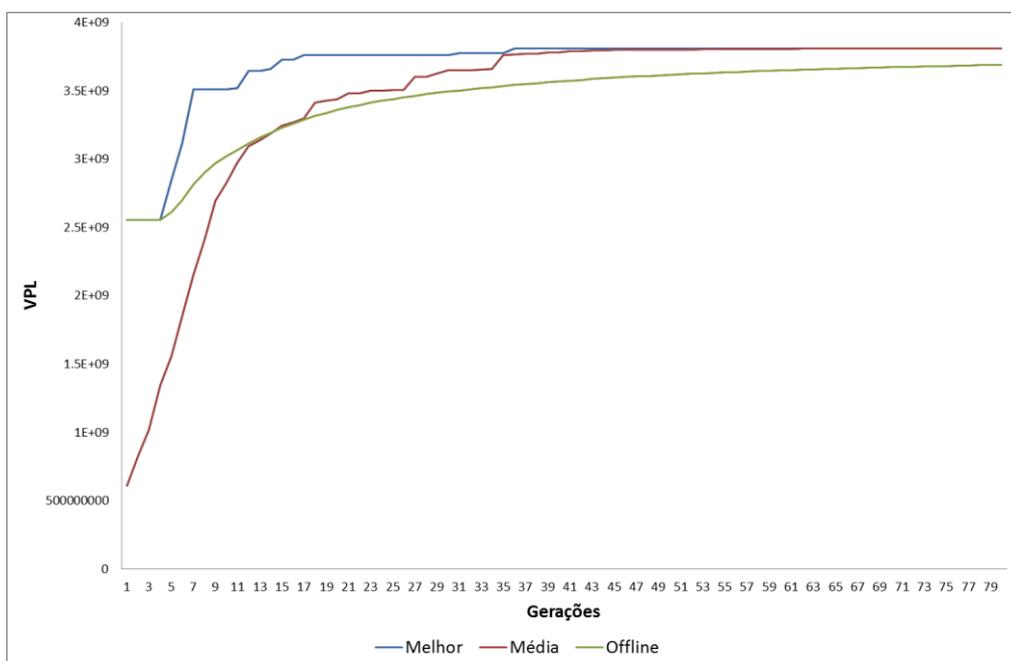


Figura 48 - Curva de Evolução da Otimização sob Incerteza com Aproximadores

A Figura 49 e a Figura 50 mostram, respectivamente, a configuração de poços para uma das otimizações sob incerteza realizada utilizando o simulador e utilizando o aproximador. As figuras apresentam a configuração de poços para os três cenários otimizados, com suas respectivas primeiras camadas de porosidade. Em ambas foram encontrados 6 poços como configuração ótima, sendo cinco poços produtores e um injetor.

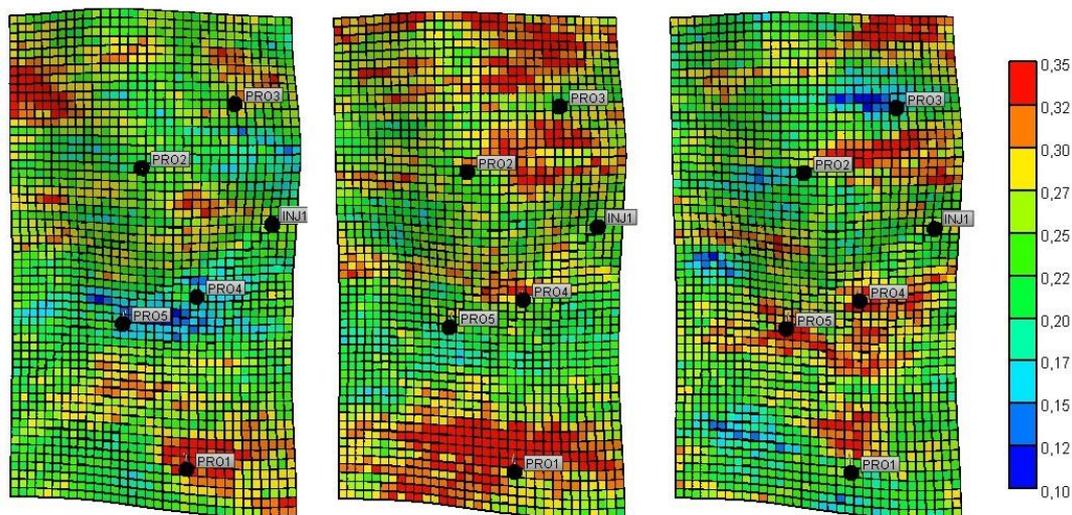


Figura 49 – Configuração de Poços para a Otimização sob Incerteza utilizando o simulador

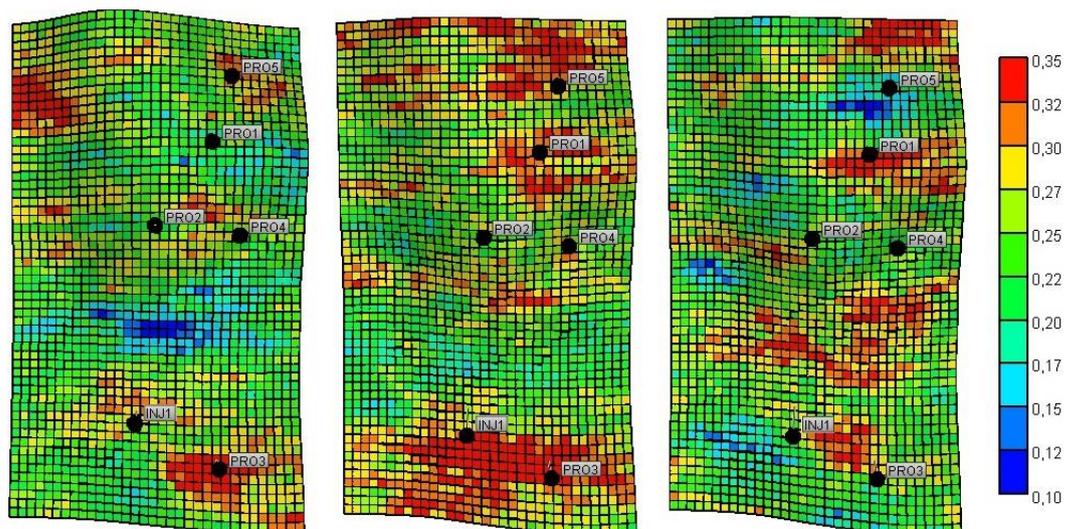


Figura 50 – Configuração de Poços para a Otimização sob Incerteza utilizando o aproximador

6. Conclusões e Trabalhos Futuros

6.1. Conclusões

Nesta dissertação foi apresentado detalhadamente o processo de construção de um aproximador de reservatório de petróleo para a aplicação na otimização da localização de poços de petróleo. Este aproximador substituiu parcialmente o simulador IMEX, fornecendo como saída a curva da produção acumulada de um fluido, seja óleo, água ou gás. Com essas curvas, o cálculo do VPL pode ser efetuado e uma alternativa pode ser avaliada.

O aproximador foi construído utilizando a Programação Genética Linear com Inspiração Quântica, uma técnica ideal para regressão simbólica. As vantagens da PGLIQ são a evolução de código de máquinas, que são executadas de forma mais rápida que outras técnicas de inteligência computacional, e a inspiração quântica que possibilita o uso de menos operadores e avaliações. As amostras para a criação desses *proxies* foi obtida do próprio simulador que se quer substituir. Esse fator aumenta a complexidade do problema, pois uma boa aproximação depende do número de amostras. Para contornar esse problema, a técnica do Hipercubo Latino foi usada para diminuir a quantidade de amostras necessárias.

Inicialmente, um estudo para tentar diminuir ainda mais o número de simulações necessárias foi realizado, mostrando que o aproximador poderia ser criado com apenas 740 simulações. Apesar da quantidade de simulações ainda não ser ideal, o *proxy* pode ser utilizado diversas vezes após ser criado, reduzindo o tempo de simulação e consequentemente o tempo de espera do especialista.

Os modelos gerados tiveram melhores resultados para as curvas de produção de óleo, gás e água do que o trabalho em [7]. Os erros das saídas do aproximador foram próximos quando comparados com a resposta do simulador. Uma limitação do modelo é a quantidade de poços que deve ser definida antes da construção dos aproximadores. Porém, a variação do tipo de cada poço é livre.

As restrições impostas são importantes para não afetar o cálculo do VPL com resultados errados, não criando máximos locais que prejudicariam o algoritmo estocástico de achar uma ótima solução. Este modelo provou que mesmo introduzindo erros, a busca por boas soluções não foi afetada para esse problema.

Por causa da rapidez na obtenção das curvas de produção, aliada ao erro reduzido do aproximador, a substituição do simulador pela *proxy* se mostrou uma estratégia interessante a ser aplicada em um modelo de otimização de localização de poços, proporcionando ao especialista uma ferramenta com resultados rápidos para apoiar suas decisões.

6.2. Trabalhos Futuros

A partir desta dissertação destacam-se os seguintes possíveis trabalhos futuros:

- Realizar testes da metodologia para outros reservatórios mais complexos que demandam mais recursos computacionais quando utilizados com o simulador para comprovar a competência do modelo e obter reduções ainda maiores do tempo de execução (Apêndice A apresenta testes preliminares para o campo UNISIM-I).
- Implementar a integração do aproximador com o sistema de otimização de maneira mais eficiente utilizando técnicas da computação paralela e/ou distribuída, acarretando em um menor tempo de execução e resultados mais rápidos para apoio à tomada de decisões.
- Desenvolver uma metodologia para correção do VPL ao longo da evolução utilizando o simulador para obter resultados com maior precisão, armazenando o resultado aproximado e simulado para comparações durante as gerações.

- Estudar novas técnicas de amostragem para reduzir o número de simulações necessárias para construção dos aproximadores com o intuito de permanecer abaixo do número necessário para realizar uma otimização.
- Evoluir os *proxies* em GPU para reduzir ainda mais o tempo exigido para criação dos mesmos. Também com essa abordagem, criar um novo modelo com mais variáveis de entrada, que podem ser adquiridas dos arquivos de definição do campo (.dat), para tentar eliminar o uso do simulador do atual modelo.

Referências Bibliográficas

- [1] E. da Silva, “Ajuste de Histórico em Modelos de Simulação de Reservatórios por Algoritmos Genéticos e Geoestatística de Múltiplos Pontos,” Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio, 2011.
- [2] J. R. Fanchi, *Principles of Applied Reservoir Simulation*. 2006, pp. 233–254.
- [3] P. J. de F. Filho, *Introdução à Modelagem e Simulação de Sistemas: com Aplicações em Arena*, 2º ed. Florianópolis: Visual Books Ltda., 2008, p. 372.
- [4] L. F. Almeida, “Sistema Híbrido de Otimização de Estratégias de Controle de Válvulas de Poços Inteligentes sob Incerteza,” Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio, 2007.
- [5] CMG, “Advanced Oil/Gas Reservoir Simulator.” Computer Modelling Group LTD., Calgary, Alberta, Canada, 2012.
- [6] D. M. Dias, “Programação Genética Linear com Inspiração Quântica,” Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio, 2010.
- [7] M. R. Kohler, “Redes Neurais Aplicadas à Construção de Aproximadores para a Simulação Integrada entre Reservatório e Sistema de Produção,” Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio, 2013.
- [8] B. P. Tissot and D. H. Welte, *Petroleum Formation and Occurrence*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1978.
- [9] R. F. Broadhead, “The origin of oil and gas,” in *New Mexico’s energy, present and future: policy, production, economics, and the environment*, B. S. Brister and L. G. Price, Eds. New Mexico Bureau Geology and Mineral Resources, 2002, pp. 41–43.
- [10] N. J. Clark, *Elements of petroleum reservoirs*. Society of Petroleum Engineers of AIME, 1969, p. 250.
- [11] “Fundamental in Oil & Gas: Series 2,” *E-Newsletter of the Malaysian Structural Steel Association*, 2014. [Online]. Available: http://www.mssa.org.my/site/index.php?option=com_content&view=article&id=107&Itemid=168.

- [12] A. J. Rosa, R. de S. Carvalho, and J. A. D. Xavier, *Engenharia de reservatórios de petróleo*. Interciência, 2006, p. 808.
- [13] C. C. Mezzomo, “Otimização de estratégias de recuperação para campos de petróleo,” Universidade Estadual de Campinas, 2001.
- [14] G. O. Queiroz, “Otimização da injeção cíclica de vapor em reservatórios de óleo pesado,” Universidade Federal do Rio Grande do Norte, 2006.
- [15] J. L. M. Barillas, “Estudo do processo de drenagem gravitacional de óleo com injeção contínua de vapor em poços horizontais,” Universidade Federal do Rio Grande do Norte, 2005.
- [16] L. P. Naveira, “Simulação de reservatórios de petróleo utilizando o método de elementos finitos para recuperação de campos maduros e marginais,” Universidade Federal do Rio de Janeiro - UFRJ, 2007.
- [17] L. M. Costa, L. J. N. Guimarães, and I. D. S. P. Filho, “Simulação de injeção de água em análogos de reservatórios em condições não isotérmicas,” 2003.
- [18] D. F. B. Oliveira, “Técnicas de otimização da produção para reservatórios de Petróleo,” Universidade Federal de Pernambuco, 2006.
- [19] G. D. Avansi, “Uso de metamodelos na seleção de estratégias de produção e avaliação econômica de campos de petróleo,” Universidade Estadual de Campinas, 2008.
- [20] A. Ayres Neto, “Uso da sísmica de reflexão de alta resolução e da sonografia na exploração mineral submarina,” *Revista Brasileira de Geofísica*, vol. 18. pp. 241–256, 2000.
- [21] L. Landau, *Fluid Mechanics*, 3rd ed. Pergamon Press, 1986.
- [22] E. E. de Souza, “Processo de Localização de Plataformas de Petróleo,” Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio, 2011.
- [23] A. A. M. Soares, “Simulação de Reservatórios de Petróleo em Arquiteturas Paralelas com Memória Distribuída,” Universidade Federal de Pernambuco - UFPE, 2002.
- [24] C. C. Mattax and R. L. Dalton, *Reservoir simulation*. 1990.
- [25] Y. Pan and R. Horne, “Improved Methods for Multivariate Optimization of Field Development Scheduling and Well Placement Design,” *Proc. SPE Annu. Tech. Conf. Exhib.*, Sep. 1998.
- [26] H. Doraisamy, T. Ertekin, and A. Grader, “Field development studies by neuro-simulation: an effective coupling of soft and hard computing protocols,” *Comput. Geosci.*, vol. 26, pp. 963–973, 2000.

- [27] B. Centilmen, T. Ertekin, and A. Grader, “Applications of neural networks in multiwell field development,” *SPE Annu. Tech. Conf.*, 1999.
- [28] B. Guyaguler and R. Horne, “Optimization of well placement in a Gulf of Mexico waterflooding project,” *SPE Annu. Tech. ...*, vol. 63, pp. 1–10, 2000.
- [29] V. M. Johnson and L. L. Rogers, “Applying soft computing methods to improve the computational tractability of a subsurface simulation–optimization problem,” *J. Pet. Sci. Eng.*, vol. 29, no. 3–4, pp. 153–175, May 2001.
- [30] B. Yeten, L. Durlofsky, and A. Khalid, “Optimization of Nonconventional Well Type, Location and Trajectory,” *Proc. SPE Annu. Tech. Conf. Exhib.*, Sep. 2002.
- [31] Y. J. T. Valdivia, “Sistema Inteligente de Otimização de Alternativas de Desenvolvimento de Campos Petrolíferos,” Pontificia Universidade Católica do Rio de Janeiro - PUC-Rio, 2005.
- [32] T. Yu, D. Wilkinson, and A. Castellini, “Constructing Reservoir Flow Simulator Proxies Using Genetic Programming for History Matching and Production Forecast Uncertainty Analysis,” *J. Artif. Evol. Appl.*, vol. 2008, no. i, pp. 1–13, 2008.
- [33] F. Zarei, A. Daliri, and N. Alizadeh, “The use of neuro-fuzzy proxy in well placement optimization,” *Intell. Energy Conf. Exhib.*, no. February, pp. 25–27, 2008.
- [34] J. Jalali, S. Mohaghegh, and R. Gaskari, “Coalbed Methane Reservoir Simulation and Uncertainty Analysis with Artificial Neural Networks,” *Sci. Iran. Trans. C Chem. ...*, vol. 17, no. 1, 2010.
- [35] H. Hassani and H. Sarkheil, “A proxy modeling approach to optimization horizontal well placement,” *45th US Rock Mech. ...*, no. 1999, 2011.
- [36] D. Zubarev, “Pros and Cons of Applying Proxy-Models as a Substitute for Full Reservoir Simulations,” *Proc. SPE Annu. Tech. Conf. Exhib.*, Oct. 2009.
- [37] J. R. Koza, “Genetic programming as a means for programming computers by natural selection,” *Stat. Comput.*, vol. 4, no. 2, pp. 87–112, 1994.
- [38] W. Banzhaf, P. Nordin, R. E. Keller, and F. D. Francone, *Genetic Programming. An Introduction On the Automatic Evolution of Computer Programs and Its Applications*. 1998.
- [39] E. Nunez, E. R. Banks, P. Agarwal, M. McBride, and R. Liedel, “High Performance Evolutionary Computation,” in *2005 Users Group Conference (DOD-UGC’05)*, 2005, pp. 308–313.

- [40] C. S. Pereira, “Otimização Multiobjetivo da Programação de Petróleo em Refinaria por Programação Genética em Linguagem Específica de Domínio,” Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio, 2012.
- [41] D. M. Dias, “Síntese Automática de Programas para Microcontroladores Digitais por Programação Genética,” Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio, 2005.
- [42] R. Poli, W. Langdon, and N. McPhee, “A field guide to genetic programming,” *books.google.com*, 2008.
- [43] S. Wright, “Isolation by Distance,” *Genetics*, vol. 28, no. 2, pp. 114–138, 1943.
- [44] R. Tanese, “Distributed Genetic Algorithms,” pp. 434–439, Jun. 1989.
- [45] W. A. Tackett, “Recombination, Selection, and the Genetic Construction of Computer Programs,” in *Foundations of Genetic Algorithms 3*, 1994, pp. 271–297.
- [46] D. Andre and J. R. Koza, “Parallel Genetic Programming: {A} Scalable Implementation Using The Transputer Network Architecture,” in *Advances in Genetic Programming 2*, P. J. Angeline and K. E. Kinnear, Jr., Eds. MIT Press, 1996, pp. 317–337.
- [47] W. Banzhaf and M. Brameier, “Effective Linear Genetic Programming,” *dspace.hrz.uni-dortmund.de*, 2001.
- [48] J. R. Koza, “Introduction to genetic programming tutorial,” in *Proceedings of the 12th annual conference comp on Genetic and evolutionary computation - GECCO '10*, 2010, p. 2137.
- [49] A. Narayanan and M. Moore, “Quantum-inspired genetic algorithms,” *Proc. IEEE Int. Conf. Evol. Comput.*, 1996.
- [50] Intel, “Intel® 64 and IA-32 Architectures Software Developer’s Manual: Volume 2B,” *Order A J. Theory Ordered Sets Its Appl.*, vol. 2, no. 253666, 2009.
- [51] B. P. Lanyon, M. Barbieri, M. P. Almeida, T. Jennewein, T. C. Ralph, K. J. Resch, G. J. Pryde, J. L. O’Brien, A. Gilchrist, and A. G. White, “Quantum computing using shortcuts through higher dimensions,” 2008.
- [52] M. D. McKay, R. J. Beckman, and W. J. Conover, “A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code,” *Technometrics*, vol. 42, no. 1, pp. 55–61, 2000.
- [53] F. X. Diebold and J. A. Lopez, “8 Forecast evaluation and combination,” *Handbook of Statistics*, vol. 14, pp. 241–268, 1996.

- [54] S. Makridakis and M. Hibon, “Exponential smoothing: The effect of initial values and loss functions on post-sample forecasting accuracy,” *International Journal of Forecasting*, vol. 7, no. 3. pp. 317–330, 1991.
- [55] A. A. Emerick, E. Silva, B. Messer, L. F. Almeida, D. Szwarcman, M. A. C. Pacheco, and M. M. B. R. Vellasco, “Well Placement Optimization Using a Genetic Algorithm With Nonlinear Constraints,” *SPE Reservoir Simulation Symposium*. Society of Petroleum Engineers, 2009.
- [56] A. T. et al. GASPAR, “Study Case for Reservoir Exploitation Strategy Selection based on UNISIM-I Field,” Campinas, 2013.

Apêndice A

Esta seção apresenta a metodologia criada nesta dissertação sendo aplicada em um reservatório baseado em um campo real. O mesmo processo de geração dos aproximadores para os casos estudados foi seguido. Porém, para esse reservatório foram criados quatro aproximadores para a produção acumulada anual de quatro poços para um horizonte de previsão de 20 anos. O mesmo número de simulações foram utilizadas, totalizando 740 simulações para a criação do *proxy*.

A.1. Modelo de reservatório

O modelo de reservatório utilizado, chamado UNISIM-I Determinístico, é baseado em um reservatório real localizado no campo de Namorado (lâmina d'água de 160 metros) na Bacia de Campos. A Figura 51 mostra o modelo utilizado que foi fornecido pela UNICAMP e possui sua documentação descrita em [56].

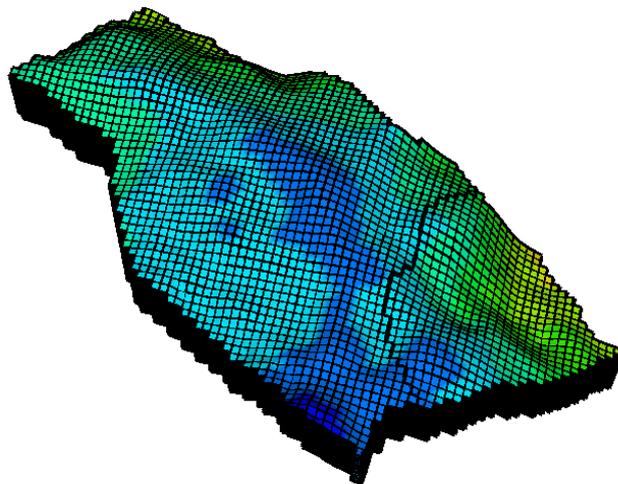


Figura 51 - Modelo de Reservatório UNISIM-I

A.2. Resultados do Aproximador

Também foram realizados 10 experimentos para a obtenção dos resultados mostrados nas Tabela 39, Tabela 40 e Tabela 41. Os erros encontrados indicam que a metodologia também se aplica nesse caso, podendo ser estendida para testes em outras configurações de poços para esse tipo de reservatório.

Poços	Erro	Óleo		
		Cenário 1	Cenário 2	Cenário 3
1p3i	RMSE	2,613,402	2,431,053	3,311,621
	SMAPE	3,69%	3,61%	6,06%
	MAPE	7,30%	7,26%	12,32%
	R^2	96,26%	96,49%	94,93%
2p2i	RMSE	1,118,513	1,091,421	1,085,913
	SMAPE	9,98%	9,77%	10,89%
	MAPE	21,23%	19,90%	22,40%
	R^2	84,91%	86,92%	86,73%
3p1i	RMSE	8,088,655	8,956,475	9,160,875
	SMAPE	8,21%	11,13%	13,25%
	MAPE	17,20%	20,66%	28,23%
	R^2	92,55%	91,60%	90,57%
4p	RMSE	6,406,985	6,289,053	5,752,935
	SMAPE	14,60%	16,94%	15,16%
	MAPE	23,70%	26,96%	92,98%
	R^2	93,25%	94,11%	93,74%

Tabela 39 - Resultados do Aproximador de Óleo para 4 Poços

Poços	Erro	Gás		
		Cenário 1	Cenário 2	Cenário 3
1p3i	RMSE	3,729,586	2,831,627	3,753,077
	SMAPE	4,57%	4,14%	5,25%
	MAPE	9,73%	8,40%	10,99%
	R^2	94,18%	96,25%	94,00%
2p2i	RMSE	1,128,614	1,218,034	1,372,684
	SMAPE	9,64%	9,45%	12,54%
	MAPE	18,48%	19,21%	26,10%
	R^2	87,20%	86,17%	83,79%
3p1i	RMSE	1,020,751	1,002,228	101,077
	SMAPE	9,98%	10,38%	11,00%
	MAPE	18,01%	26,84%	21,32%
	R^2	91,36%	91,67%	90,09%
4p	RMSE	7,218,348	6,788,422	7,242,781
	SMAPE	14,27%	15,18%	15,83%
	MAPE	39,15%	26,15%	78,51%
	R^2	93,52%	94,43%	93,07%

Tabela 40 - Resultados do Aproximador de Gás para 4 Poços

Poços	Erro	Água		
		Cenário 1	Cenário 2	Cenário 3
1p3i	RMSE	395,958	4,275,625	530,074
	SMAPE	10,41%	11,24%	9,94%
	MAPE	18,10%	15,98%	25,32%
	R^2	96,03%	96,62%	94,52%
2p2i	RMSE	1,283,529	1,815,316	1648,7
	SMAPE	20,34%	18,99%	22,47%
	MAPE	49,42%	34,67%	49,21%
	R^2	86,71%	84,39%	86,83%
3p1i	RMSE	1,189,294	1,404,067	1,406,111
	SMAPE	25,28%	24,76%	24,12%
	MAPE	43,17%	43,52%	37,58%
	R^2	88,86%	90,52%	90,27%
4p	RMSE	7,373,053	7,472,218	8,007,448
	SMAPE	25,77%	25,47%	23,71%
	MAPE	39,74%	35,08%	32,24%
	R^2	93,92%	94,92%	94,52%

Tabela 41 - Resultados do Aproximador de Água para 4 Poços

Apêndice B

Um dos programas evoluídos pela Programação Genética Linear com Inspiração Quântica para prever a curva de óleo acumulado com 6 poços produtores.

```

__declspec(dllexport)
float asmOut(float *_input, int _len)
{
    float *input;
    float outProgram;
    int len,i;
    float *output;
    unsigned int input_adr;
    unsigned int output_adr;

    len = _len;
    input = malloc(64*sizeof(float));
    output = malloc(8*sizeof(float));

    for (i = 0; i < len; i++)
    {
        input[i] = _input[i];
    }

    input[27] = 0.100000;
    input[28] = 0.200000;
    input[29] = 0.300000;
    input[30] = 0.400000;
    input[31] = 0.500000;
    input[32] = 0.600000;
    input[33] = 0.700000;
    input[34] = 0.800000;
    input[35] = 0.900000;
    input[36] = 1.000000;
    input[37] = 1.100000;
    input[38] = 1.200000;
    input[39] = 1.300000;
    input[40] = 1.400000;
    input[41] = 1.500000;
    input[42] = 1.600000;
    input[43] = 1.700000;
    input[44] = 1.800000;
}

```

```

input[45] = 1.900000;
input[46] = 2.000000;
input[47] = 3.000000;
input[48] = 4.000000;
input[49] = 5.000000;
input[50] = 6.000000;
input[51] = 7.000000;
input[52] = 8.000000;
input[53] = 9.000000;
input[54] = 10.000000;
input[55] = 11.000000;
input[56] = 12.000000;
input[57] = 13.000000;
input[58] = 14.000000;
input[59] = 15.000000;
input[60] = 16.000000;
input[61] = 17.000000;
input[62] = 18.000000;
input[63] = 19.000000;

```

```

input_adr=(unsigned int)input;
output_adr=(unsigned int)output;

```

```

__asm
{
    MOV    ESI, input_adr;
    FNINIT;
    FLDZ;
    FLDZ;
    FLDZ;
    FLDZ;
    FLDZ;
    FLDZ;
    FLDZ;
    FLDZ;
    FLDZ;
    FCOMI ST,ST(0);

    FCOS;
    FSUB ST(4),ST(0);
    FCOS;
    FSCALE;
    FCHS;
    FSUB ST(6),ST(0);
    FDIV dword ptr [ESI+248];
    FSUB ST(0),ST(7);
    F2XM1;
    FADD ST(1),ST(0);
    FMUL dword ptr [ESI+80];
    FDIV ST(5),ST(0);
    FSUB ST(2),ST(0);
    FXCH ST(3);

```

```
FSIN;
F2XM1;
FCOS;
FADD ST(0),ST(6);
FADD ST(5),ST(0);
FMUL ST(0),ST(7);
FSUB ST(0),ST(4);
FSCALE;
FADD dword ptr [ESI+148];
FMUL dword ptr [ESI+68];
F2XM1;
FADD ST(0),ST(7);
FMUL ST(0),ST(4);
FADD ST(2),ST(0);
FSUB dword ptr [ESI+92];
FADD ST(5),ST(0);
FABS; FSQRT;
FSUB ST(0),ST(6);
FABS; FSQRT;
FMUL dword ptr [ESI+156];
FADD ST(3),ST(0);
FSIN;
FXCH ST(6);
FABS;
FMUL dword ptr [ESI+28];
FMUL ST(0),ST(4);
FSIN;
FSCALE;
FDIV ST(2),ST(0);
FSUB ST(3),ST(0);
FADD ST(0),ST(6);
FSUB ST(0),ST(3);
F2XM1;
FXCH ST(7);
FCHS;
FMUL ST(3),ST(0);
FADD ST(3),ST(0);
FABS; FSQRT;
FCOS;
FMUL dword ptr [ESI+160];
FCOS;
FDIV ST(1),ST(0);
FSUB dword ptr [ESI+88];
FABS;
F2XM1;
FSUB dword ptr [ESI+56];
FSUB dword ptr [ESI+80];
FABS; FSQRT;
FADD ST(0),ST(6);
FSCALE;
```

```

FADD dword ptr [ESI+152];
FDIV dword ptr [ESI+132];
FADD ST(0),ST(0);
FSCALE;
FSUB dword ptr [ESI+100];
FADD ST(0),ST(7);
FADD dword ptr [ESI+56];
FADD dword ptr [ESI+104];
FMUL ST(1),ST(0);
FSUB dword ptr [ESI+156];
FADD dword ptr [ESI+48];
FADD ST(0),ST(7);
FABS;
FADD ST(0),ST(1);
FADD dword ptr [ESI+104];

```

```

MOV    ESI, output_adr;
FSTP  dword ptr [ESI+0];
MOV    EAX, [ESI];
AND    EAX, 0x7F800000;
SUB    EAX, 0x7F800000;
JNZ    end;
MOV    [esi], EAX;
end: FINIT;

```

```

}
free(input);
outProgram = *((float *) output_adr);
free(output);
return outProgram;

```

```

}

```